主管单位：中华人民共和国工业和信息化部
主办单位：北京航空航天大学

ISSN 1001-5965
CN 11-2625/V

北京航空航天大學学报

JOURNAL OF BEIJING UNIVERSITY OF AERONAUTICS AND ASTRONAUTICS



ADS-B 异常检测研究综述

杨宏宇　赵子文　朱友文　胡慧玲　胡俊成

11 2026
Vol.52

北京航空航天大学学报

第 52 卷　第 11 期　（总第 405 期）　2026 年 11 月

目　　次

ADS-B 异常检测研究综述 …… 杨宏宇，赵子文，朱友文，胡慧玲，胡俊成（3677）

改进轻量高效 EHH-YOLOv8s 的带钢表面缺陷检测算法 ……
…… 梁礼明，龙鹏威，卢宝贺，欧燕燕，曾璐（3699）

民机大尺寸全机缩比模型机体噪声风洞试验研究 …… 周国成，孙一峰，包安宇，丁存伟（3712）

基于情感表征校准的图文情感分析模型 …… 张顺香，刘佳佳，焦熠璇，张玉雷，李自亮（3724）

融合注意力机制的飞机蒙皮损伤 LHN-YOLO 小目标检测算法 …… 李耀华，陈杰（3735）

基于改进时空模型的终端区多航班航迹预测方法 …… 贺怀清，史小爽，刘浩翰，惠康华（3745）

Al-CFRP 复合结构黏接界面固化过程的超声透射检测 ……
…… 卜繁强，刘勇，王兴国，李晓高，沈国浪，马成文（3758）

面向垂直轴风力发电机的柔性叶片结构优化 …… 王晓喆，王钰博，吴坤，万志强（3770）

基于低光实例的无人机航拍低光照图像增强算法 …… 王殿伟，赵五林，房杰，李苑青，许志杰（3779）

面向飞机舱门检测的改进 RT-DETR 模型 …… 张长勇，张轩铖，乔亚海，李铮（3790）

雷达低信噪比旋翼无人机与飞鸟分类方法 …… 王晓亮，王聪生，施宇翔，何炜琨（3801）

基于多策略高尔夫优化算法的无人机三维航迹规划 …… 孙博，章文鹏，吴泽萱，苏烨博，魏明（3814）

自由空域环境下多旋翼无人机进场三维航迹规划 …… 王建忠，梁飞达（3824）

基于状态空间模型的航拍图像小目标检测算法 …… 滕尚志，龚曦，李宝安，吕学强（3832）

基于 Swin Transformer 的模分语义图像传输 …… 彭艺，孙畅，杨青青，李辉，王健明（3842）

基于多模态时空特征融合的终端区交通拥堵精细化预测 ……
…… 李善梅，宋思霓，王红勇，王端阳，赵末（3852）

融合双通道注意力和时间编码的图神经网络推荐算法 …… 白鹤，李钰，郝明，徐婷婷（3864）

面向集群的工业 CFD 软件交互设计与实现 ……
…… 张凡，丁明松，陈坚强，刘婉，江涛，李鹏，蒋军（3879）

基于时空特征提取的 GTA-Seq2Seq 多步 4D 航迹预测模型 …… 石庆研，赵婉彤，韩萍（3894）

空间机动目标跟踪任务中 IMM 算法的稳态增强设计 …… 张世源，卢山，李晴（3907）

上下文注意力引导的航拍图像语义分割算法 …… 刘露露，谢荣磊，姬嘉驰（3918）

基于无迹模型预测静态规划的可回收火箭着陆段鲁棒制导方法 ……
…… 张永华，王铮，王时雨，白云飞，仇理宽（3929）

不确定环境下基于 POMDP 和参数化 MPC 的无人机在线路径规划 ……
…… 院金彪，刘海艳，马博迪，赵玏洋，高红岗，刘贞报（3941）

基于风险约束的城市空域无人机安全路径规划 …… 朱元军，李妍，张学军，张维东（3958）
基于 YOLOv11 的舰船关键部位检测算法 …… 王瑶，曹司磊，刘明刚，王颖颖（3969）
基于 AR-PPO 的端到端无人机自主导航方法 … 李涵玮，李新凯，张海，姜凌峰，孟月，张宏立（3982）
自适应斥力势场的无人机航迹规划 …… 郭靖，鲜勇，任乐亮，李少朋（3995）
基于分布式电推进概念的飞机横侧向控制 … 王斌，杨佑绪，付军泉，段屹蔚，沈骏辉，吴逸飞（4009）
基于改进 Transformer 的视觉语言模型 …… 金泽辉，陈凯，唐敦兵，方国宇，温菲霞（4019）
基于熵权-TOPSIS 的多机悬吊系统工作空间稳定性评价 ……
…… 李威，赵志刚，赵祥堂，李子轩，江政（4029）
轻量级多尺度特征融合增强的空间非合作小目标检测算法 ……
…… 刘振江，张会娟，姬森鑫，卢涛，张弛，余远金（4040）
多核上下文特征引导下的无人机航拍图像可信检测算法 …… 张志豪，杜丽霞，郝紫微，侯越（4051）
基于 BN 的民机驾驶舱显示界面可用性综合评价模型 …… 肖瑶，陈登凯，周垚，肖江浩，侯玉宏（4063）
一种复杂动态场景实时视觉 SLAM 算法 …… 赵舶廷，刘军，柴宏旭，张健烨，吴睿彬（4075）
基于支持向量机的飞行任务识别和动作划分 …… 李博雯，雷小永（4090）
基于 IGWO-STCKF 的目标跟踪算法 …… 王威，宫淑丽，李晓明（4098）
多源数据驱动的城市低空出行公共航路网络双层规划方法 ……
…… 王炜文，包杰，陈方骁，周君，羊钊（4107）
基于轻量化 YOLOv8n 的无人机视角目标检测算法 …… 宋骏宇，庞岩（4122）

期刊基本参数：CN 11-2625/V * 1956 * m * A4 * 458 * zh * P * ￥50.00 * 400 * 38 * 2026-11

（**编　辑**　张　嵘　孙　芳　万玉敏　卞欢欢　王　茜　李亚泰）

JOURNAL OF BEIJING UNIVERSITY OF
AERONAUTICS AND ASTRONAUTICS

Vol. 52 No. 11 (Sum 405) November 2026

CONTENTS

Review of ADS-B anomaly detection research
…… YANG Hongyu, ZHAO Ziwen, ZHU Youwen, HU Huiling, HU Juncheng (3677)

Improved lightweight and efficient EHH-YOLOv8s algorithm for strip steel surface defect detection
…… LIANG Liming, LONG Pengwei, LU Baohe, OU Yanyan, ZENG Lu (3699)

Experimental research on airframe noise of large-scale full-scaled civil aircraft model in wind tunnel
…… ZHOU Guocheng, SUN Yifeng, BAO Anyu, DING Cunwei (3712)

Sentiment representation calibration-based model for image-text sentiment analysis
…… ZHANG Shunxiang, LIU Jiajia, JIAO Yixuan, ZHANG Yulei, LI Ziliang (3724)

Aircraft skin damage LHN-YOLO small target detection algorithm incorporating attention mechanisms
…… LI Yaohua, CHEN Jie (3735)

Multi-flight trajectory prediction method in terminal area based on an improved spatio-temporal model
…… HE Huaiqing, SHI Xiaoshuang, LIU Haohan, HUI Kanghua (3745)

Ultrasonic transmission testing of bonding interface curing process in Al-CFRP composite structures
…… BU Fanqiang, LIU Yong, WANG Xingguo, LI Xiaogao, SHEN Guolang, MA Chengwen (3758)

Structural optimization of flexible blades for vertical axis wind turbines
…… WANG Xiaozhe, WANG Yubo, WU Kun, WAN Zhiqiang (3770)

Low-light image enhancement algorithm for UAV aerial photography base on low-light instances
…… WANG Dianwei, ZHAO Wulin, FANG Jie, LI Yuanqing, XU Zhijie (3779)

Improved RT-DETR model for aircraft door detection
…… ZHANG Changyong, ZHANG Xuancheng, QIAO Yahai, LI Zheng (3790)

Classification method of rotor drones and flying birds under low signal-to-noise ratio for radar
…… WANG Xiaoliang, WANG Congsheng, SHI Yuxiang, HE Weikun (3801)

Three-dimensional path planning of UAVs based on multi-strategy golf optimization algorithm
…… SUN Bo, ZHANG Wenpeng, WU Zexuan, SU Yebo, WEI Ming (3814)

Three-dimensional track planning for multi-UAV approach in free airspace environment
…… WANG Jianzhong, LIANG Feida (3824)

Aerial image small object detection algorithm based on state space model
…… TENG Shangzhi, GONG Xi, LI Baoan, LYU Xueqiang (3832)

Swin Transformer-based semantic image transmission with model division multiplexing
…… PENG Yi, SUN Chang, YANG Qingqing, LI Hui, WANG Jianming (3842)

Refined prediction of terminal area traffic congestion based on multimodal spatio-temporal feature fusion
…… LI Shanmei, SONG Sini, WANG Hongyong, WANG Duanyang, ZHAO Mo (3852)

Graph neural network recommendation algorithm fused with dual-channel attention and time encoding
…… BAI He, LI Yu, HAO Ming, XU Tingting (3864)

Interactive design and implementation of cluster-oriented industrial CFD software
…… ZHANG Fan, DING Mingsong, CHEN Jianqiang, LIU Wan, JIANG Tao, LI Peng, JIANG Jun (3879)

GTA-Seq2Seq multi-step 4D trajectory prediction model based on spatio-temporal feature extraction
…… SHI Qingyan, ZHAO Wantong, HAN Ping (3894)

Steady-state enhancement design of IMM algorithm for space maneuvering target tracking
…… ZHANG Shiyuan, LU Shan, LI Qing (3907)

Semantic segmentation algorithms of aerial images via context-aware attention guidance
…… LIU Lulu, XIE Ronglei, JI Jiachi (3918)

A robust guidance method for reusable rocket landing phase based on UMPSP
…… ZHANG Yonghua, WANG Zheng, WANG Shiyu, BAI Yunfei, QIU Likuan (3929)

UAV online path planning based on POMDP and parameterized MPC in uncertain environments
…… YUAN Jinbiao，LIU Haiyan，MA Bodi，ZHAO Leyang，GAO Honggang，LIU Zhenbao （3941）

Risk-constrained safe path planning for unmanned aerial vehicles in urban airspace
…… ZHU Yuanjun，LI Yan，ZHANG Xuejun，ZHANG Weidong （3958）

Detection algorithm of ship key parts based on YOLOv11
…… WANG Yao，CAO Silei，LIU Minggang，WANG Yingying （3969）

End-to-end autonomous navigation method for drones based on AR-PPO
…… LI Hanwei，LI Xinkai，ZHANG Hai，JIANG Lingfeng，MENG Yue，ZHANG Hongli （3982）

Adaptive repulsive potential field for UAV trajectory planning
…… GUO Jing，XIAN Yong，REN Leliang，LI Shaopeng （3995）

Lateral directional control of aircraft based on distributed electric propulsion concept
…… WANG Bin，YANG Youxu，FU Junquan，DUAN Yiwei，SHEN Junhui，WU Yifei （4009）

Visual language model based on improved Transformer
…… JIN Zehui，CHEN Kai，TANG Dunbing，FANG Guoyu，WEN Feixia （4019）

Workspace stability evaluation of multi-engine suspension system based on EWM-TOPSIS
…… LI Wei，ZHAO Zhigang，ZHAO Xiangtang，LI Zixuan，GANG Zheng （4029）

Lightweight multi-scale feature fusion enhancement algorithm for spatial non-cooperative small target detection
…… LIU Zhenjiang，ZHANG Huijuan，JI Miaoxin，LU Tao，ZHANG Chi，YU Yuanjin （4040）

Multi-core contextual feature-guided algorithm for trusted detection of UAV aerial images
…… ZHANG Zhihao，DU Lixia，HAO Ziwei，HOU Yue （4051）

BN-based comprehensive evaluation model for display interface usability in civil aircraft cockpit
…… XIAO Yao，CHEN Dengkai，ZHOU Yao，XIAO Jianghao，HOU Yuhong （4063）

A real-time visual SLAM algorithm for complex dynamic scenarios
…… ZHAO Boting，LIU Jun，CHAI Hongxu，ZHANG Jianye，WU Ruibin （4075）

Flight task recognition and action segmentation based on SVM
…… LI Bowen，LEI Xiaoyong （4090）

Target tracking algorithm based on IGWO-STCKF
…… WANG Wei，GONG Shuli，LI Xiaoming （4098）

A bi-level programming method for urban low-altitude travel public air route network driven by multi-source data
…… WANG Weiwen，BAO Jie，CHEN Fangxiao，ZHOU Jun，YANG Zhao （4107）

UAV perspective target detection algorithm based on lightweight YOLOv8n
…… SONG Junyu，PANG Yan （4122）

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2025.0600

ADS-B 异常检测研究综述

杨宏宇[1,2,*]，赵子文[1]，朱友文[3]，胡慧玲[4]，胡俊成[5]

(1. 中国民航大学 安全科学与工程学院，天津 300300；2. 中国民航大学 计算机与人工智能学院，天津 300300；
3. 南京航空航天大学 计算机科学与技术学院，南京 211106；4. 中国民用航空中南地区空中交通管理局 空管部，广州 510440；
5. 吉林大学 计算机科学与技术学院，长春 130012)

摘 要：广播式自动相关监视 (ADS-B) 系统作为航空监视技术的重要组成部分，已得到广泛部署应用，显著提高了空中交通监视的覆盖范围和定位精度，但开放的广播通信机制使该系统易受数据篡改、恶意报文注入和干扰攻击等多种安全威胁，严重影响空中交通安全与管制决策，针对ADS-B系统的异常检测成为研究热点。基于此，系统总结并分析了当前国内外ADS-B系统异常检测的研究现状。对导致ADS-B系统出现异常数据的原因进行分析，总结该系统易遭受的攻击类型及其影响；从基于一致性检验的方法和基于深度学习的方法深入探讨ADS-B异常检测研究现状，分析各类方法在检测精度、泛化性与实际部署中的优缺点，并结合相应的应用场景对当前ADS-B异常检测产品进行分析总结；在总结已有研究成果的基础上，深入讨论当前面向ADS-B的异常检测方法所面临的主要挑战，并提出未来的研究方向与发展趋势。

关 键 词：广播式自动相关监视；异常检测；空中交通监视；一致性检验；深度学习
中图分类号：TP393
文献标志码：A **文章编号**：1001-5965(2026)11-3677-22

随着美国新一代航空运输系统项目及欧洲单一天空空中交通管理研究项目的启动[1]，航空电子基础设施开始更新，这些项目旨在设计高性能、低成本和更安全的航空电子系统。在过去的十几年中，航空电子系统已逐步实现了空中运行管理与监视的自动化，并与地面站、雷达等形成相互依存的结构，但随着系统日益复杂，系统自身产生了新的安全漏洞。因此，加强航空电子系统的安全性、可靠性和可持续性逐渐成为研究热点。

广播式自动相关监视 (automatic dependent surveillance broadcast, ADS-B) 系统作为新一代空中交通监视技术的重要组成部分，可由机载设备实时广播航空器的位置信息、速度和航向等数据，显著提升空中交通管理 (air traffic management, ATM) 的态势感知能力与运行安全性。2020年，美国联邦航空管理局表示，攻击者可以窃听ADS-B系统以对该系统进行中间人攻击[2]，利用ADS-B的安全漏洞，攻击者可以注入“幽灵飞机”信号或篡改实际航空器的定位信息，给空中交通管制 (air traffic control, ATC) 带来潜在风险。

为应对日益严重的ADS-B安全威胁，国内外研究者提出多种异常检测方法，主要分为基于一致性检验的ADS-B异常检测方法和基于深度学习的ADS-B异常检测方法。早期的一致性检验方法包括基于位置或信号时间到达差的检测[3]，该类方法通过将ADS-B报文广播的位置信息与雷达或多点定位系统所测量的独立位置信息进行交叉验证，并使用基于飞行动力学的模型分析轨迹的合理性，从

收稿日期：2025-08-26；**录用日期**：2025-11-07；**网络出版时间**：2025-11-20 12:16
网络出版地址：link.cnki.net/urlid/11.2625.V.20251119.1820.004
基金项目：国家自然科学基金民航联合基金重点项目 (U2433205)
*通信作者. E-mail：yhyxlx@hotmail.com

引用格式：杨宏宇，赵子文，朱友文，等. ADS-B 异常检测研究综述 [J]. 北京航空航天大学学报，2026，52（11）：3677-3698.
Yang H Y，Zhao Z W，Zhu Y W，et al. Review of ADS-B anomaly detection research [J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：3677-3698（in Chinese）.

而判断报文数据的真实性和一致性。该类方法依赖额外的传感器信息和人为设定的阈值,难以全面覆盖复杂场景。2020年以后,基于密码学的一致性检验方法为ADS-B提供了更严格的完整性保证,通过在ADS-B通信中引入对称加密、数字签名、消息认证码和区块链等手段[4],对广播报文进行验证和防篡改保护。该类方法可确保只有授权方才能解读并验证报文来源,防止数据被伪造或中途篡改,从而确保ADS-B报文的完整性与来源的真实性。然而,该类方法在实际部署过程中仍存在密钥分发机制复杂、通信资源开销较大等问题,制约了其在广域航空监视场景中的大规模应用。

与此同时,基于深度学习的ADS-B异常检测方法[2]也逐渐得到了广泛应用,该类方法能够从海量正常飞行数据中自动学习正常航迹模式,当出现偏离正常模式的ADS-B报文时予以检测。但是,目前基于深度学习的异常检测方法高度依赖特征选择算法的设计及训练数据的质量,在应对未知环境和新型威胁时泛化能力不足。

综合上述问题,本文聚焦面向ADS-B的异常检测方法,通过梳理ADS-B异常检测方法的研究进展,深入分析各类方法在检测不同空域、机型、飞行模式和各类攻击方式时存在的优势与不足。同时,本文系统总结了ADS-B遭受的各类攻击方式,并深入分析了不同攻击方式造成的影响。在总结目前研究成果的基础上,针对实际应用中面临的挑战和技术瓶颈,提出包括对抗性抵御、大语言模型部署在内的具体研究方向,以期为推进异常检测技术在ADS-B系统中的进一步研究与实际应用提供参考依据。

在深入探讨具体的异常检测方法之前,有必要对本文的核心概念进行界定。“异常”是一个广义术语,指任何偏离预期正常模式的数据点或序列,其成因既包括设备故障、信号衰减等非恶意因素,也涵盖了由恶意实体发起的“攻击”。攻击是异常的一个关键子集,特指旨在破坏系统完整性、可用性或真实性的蓄意行为。本文的定位是ADS-B异常检测研究综述,该技术是保障航空安全的重要防线,其目标是识别所有异常模式,并重点关注对各类恶意攻击行为的检测能力与挑战。

1 ADS-B系统概述

ADS-B系统作为新一代空中交通监视技术[5],航空器通过无线电周期性广播自身的位置、速度、航向、识别号等信息,由地面站和其他航空器接收用于空管监视与碰撞预防。作为“下一代”空管系统的核心组成,ADS-B系统相较传统雷达具有诸多优势,包括态势感知能力提升、监视覆盖范围扩大、目标定位精度提高及运行成本降低等[5]。然而,ADS-B系统在设计上缺乏必要的安全机制,其广播报文为明文且无加密认证,这意味着任何人都可以在该系统所用频段发送格式规范的ADS-B信号而被接收端接收。本节将详细阐述ADS-B运行过程和ADS-B异常数据产生机理。

1.1 ADS-B运行过程

ADS-B系统的核心模块由ADS-B接收端和ADS-B输出端2个关键部分组成。ADS-B输出端设备安装在航空器或地面站,通过全球导航卫星系统(global navigation satellite system, GNSS)接收机获取航空器的实时位置信息、速度、航向等飞行数据,飞行管理系统(flight management system, FMS)处理这些数据后,由机载Mode S应答机将其转换为广播报文,并通过指定的数据链路定期广播出去,这些信息被地面站和其他运行航班ADS-B接收端设备所接收并进行解码,将提取到的飞行状态信息在地面站及飞行员的驾驶舱显示交通信息(cockpit display of traffic information, CDTI)界面进行展示,实现实时监控和空中交通管理,确保航班之间的安全距离并进行必要的避让,从而有效提升空中交通运行的安全性和空域资源利用的效率。ADS-B系统架构如图1所示。

1.2 ADS-B异常数据产生机理

ADS-B系统在实际运行过程中接收到的广播报文,除常规飞行数据外,往往还包含一定比例的异常数据。这些异常数据的产生,部分源于硬件精度、气象环境等非恶意因素[6-7],但更严峻的挑战来自其开放通信协议所固有的安全漏洞[8]。为了系统性地分析这些由恶意攻击导致的异常来源,本文引入业界权威的微软STRIDE威胁模型[9],该模型从欺骗、数据篡改、信息泄露、拒绝服务、权限提升和抵赖6个维度对安全威胁进行分类。ADS-B系统的异常数据产生机理可映射至该框架进行深入分析。

1.2.1 拒绝服务

拒绝服务攻击旨在破坏ADS-B通信的可用性,主要表现为信号干扰。攻击者可通过大功率噪声发射装置阻塞1 090 MHz信道,淹没合法信号,导致特定空域内的航空器信号“消失”或间歇性丢失,造成航班位置信息无法更新、轨迹不连续等异常[10-11]。这直接破坏了空管的态势感知能力。

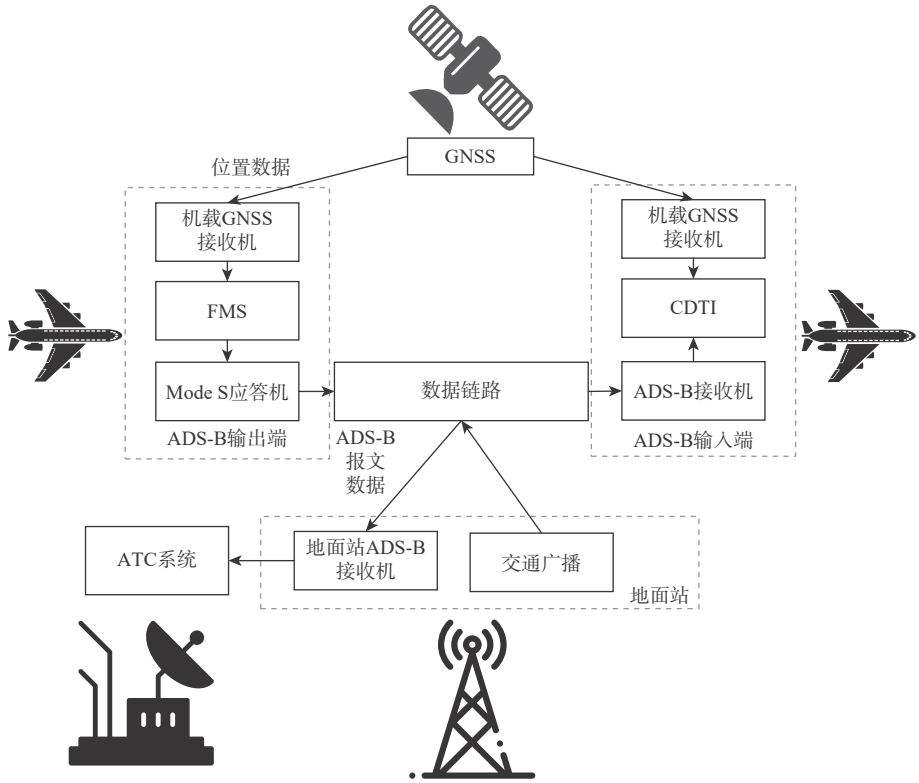


图 1　ADS-B 系统架构

Fig. 1　Architecture of ADS-B system

1.2.2　数据篡改

数据篡改攻击指合法 ADS-B 报文在传输过程中被恶意修改, 导致接收方获取不准确的状态信息。研究表明, 攻击者可通过信号叠加技术翻转报文中的比特位, 将真实信息篡改为虚假数据[12-13]。此类异常的特征是航班目标持续存在, 但其报告的轨迹、高度等信息与实际严重不符, 可能干扰空管决策, 引发安全隐患。

1.2.3　欺骗与信息泄露

由于 ADS-B 自身的特点, 使得所有相关数据流都会导致信息泄露。由于无法改变其本身的核心属性, 针对信息泄露, 只能通过后期对各类攻击进行精准检测与防御, 来维护该系统的正常运转。欺骗攻击是指非法航空器发出的虚假 ADS-B 广播信息出现在监视系统中, 通常由攻击者恶意生成。这类异常的数据源并非真实航空器, 而是攻击者利用无线发射设备伪造的“幽灵飞机”航班信号[14-16]。欺骗攻击的典型表现是监视显示出现额外的未知航迹: 空管雷达或接收站检测到一些并不存在于空域中的航空器目标。这些“幽灵飞机”航迹可能包含看似合理的识别号、位置和高度等数据, 但实际上没有对应的真实航空器。此类异常会对空管员和飞行员造成极大困扰, 需分辨哪些目标是真实的, 哪些是伪造的。如果攻击者生成的虚假目标与真实航空器航路接近, 甚至可能迫使空管采取不必要的分流措施, 影响正常航班调度。

1.2.4　权限提升与抵赖

在 ADS-B 场景下, 权限提升表现为攻击者通过广播虚假紧急代码, 使其伪造信息获得不成比例的关注和系统优先响应, 间接影响空管决策流程。而抵赖指的是 ADS-B 协议无法提供报文来源的不可否认性, 使得攻击者在实施了上述所有攻击后难以被追溯, 构成了系统性的安全短板。同时, 抵赖通常表现为攻击者伪装真实航班发送假位置或速度信息, 干扰 ATC 监控后删除或隐藏发送记录。由于 ADS-B 报文为明文广播且无签名机制, 任何软件无线电设备 (software defined radio, SDR) 都可发送报文, 系统无法追溯真实发射者。

综上, 基于 STRIDE 威胁模型, ADS-B 的异常数据来源可被系统性地归纳为: 由拒绝服务攻击导致的信号干扰与数据缺失; 由数据篡改攻击造成的报文内容失真; 由欺骗攻击引入的虚假“幽灵飞机”目标或身份冒用; 以及作为多种攻击前提的信息泄露。这一系统性的分类框架, 为后续深入分析 ADS-B 攻击技术和构建有效的防护方法奠定了坚实的理论基础。STRIDE 威胁模型在 ADS-B 领域的映射如表 1 所示。

表1 STRIDE威胁模型在ADS-B领域的映射

Table 1 Mapping of STRIDE threat model in ADS-B domain

元素	交互	在ADS-B系统中的具体表现形式和攻击示例	S (欺骗)	T (数据篡改)	R (抵赖)	I (信息泄露)	D (拒绝服务)	E (权限提升)
航空器	广播ADS-B报文给地面站或邻机	“幽灵飞机”注入,伪造航班或位置广播导致错误感知	★		★			
航空器	从进程接收ADS-B报文	伪装为地面服务下发错误情报;接收方日志被篡改后无法追溯	★	★				
进程	地面站监视系统获取航空器报文并处理	中间处理被篡改影响告警;处理日志被删除;接收缓存泄露	★	★		★	★	★
进程	地面站监视系统向航空器广播报文	下发被篡改的交通/天气信息	★	★			★	★
进程	ATC系统与数据库接口	中间报文或响应被篡改;审计记录被擦除		★	★			
进程	写入或读取飞行日志与数据库	写入端被回写假轨迹;数据库敏感字段被泄露		★	★	★		
数据流	航空器向地面站广播	广播被仿冒或重放;广播可被任何接收机窃听		★		★	★	
数据流	地面站向航空器回传	地面注入错误情报		★		★	★	
数据流	空对空广播	空对空“幽灵飞机”广播;广播被重放或延迟		★		★	★	

注:★表示对应交互中可能遭受的攻击类型。

2 ADS-B攻击技术

随着ADS-B系统大面积部署在各国民航系统中,其设计时所蕴含的问题逐渐暴露出来,通信链路未采用任何加密或认证手段,接收端对报文来源身份不做校验。这一架构上的弱点使得ADS-B易受到多种网络攻击的威胁,如被动窃听、虚假数据、干扰等。事实上,攻击者只需成本较低的软件无线电设备,便可在1 090 MHz信道上拦截或伪造ADS-B报文[17]。这些安全漏洞引发了对航空安全的严重担忧:攻击者可能利用ADS-B系统的弱点获取敏感航班信息、注入虚假目标、干扰正常通信,直接影响空管决策和飞行安全。因此,深入研究ADS-B的攻击模式与分类方法,对制定有效的防御策略至关重要。本节将详细阐述当前ADS-B系统所遭受的主要攻击方式,并对其进行分类总结。面向ADS-B主要攻击方式如图2所示。

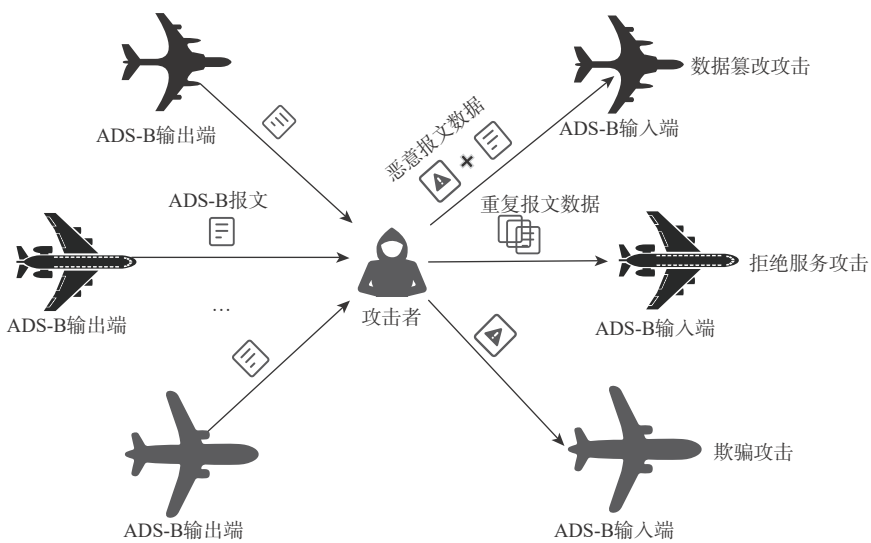


图2 ADS-B主要攻击方式

Fig. 2 Primary attack modes against ADS-B

2.1 被动窃听攻击

被动窃听是最基础的ADS-B攻击方式,属于被动信息获取。攻击者使用ADS-B接收机或软件无线电设备,调谐至1 090 MHz或其常用ADS-B频段,便可接收附近广播的ADS-B报文[18]。由于所有信息均为非加密,攻击者可以毫不费力地截获并解析这些广播内容。通过获取的ADS-B飞行数据,攻击者可以实现对航空器隐私侵犯、航迹跟踪,甚至对特定航班实施后续攻击。虽然该攻击方式对航空器运行造成的影响较小,但被动窃听攻击往往是其他主动攻击的前奏,攻击者在掌握目标航空器的飞机识别号、飞行高度、飞行速度等重要数据

后, 利用这些信息执行欺骗或干扰攻击。因此, 被动窃听攻击虽然不会直接干扰 ADS-B 运行, 但为后续其他高危攻击打开了大门[19]。由于 ADS-B 设计时便拥有的开放性质, 目前对被动窃听攻击本身缺乏有效的防御手段, 只有通过隐私保护机制在一定程度上缓解数据暴露。

2.2　虚假数据攻击

虚假数据攻击是目前 ADS-B 最具威胁的主动攻击方式, 主要包括欺骗攻击、注入攻击、数据篡改攻击。尽管 3 种攻击方式都涉及伪造或修改 ADS-B 数据, 干扰航空监视系统和空管决策, 但三者在攻击目标、技术实现及影响范围等方面存在显著区别。

2.2.1　欺骗攻击

欺骗攻击主要针对个别航班, 通过伪造已有航班的数据, 可能会导致空管人员误判航班位置, 从而影响航空安全。

GNSS 欺骗攻击向机载 GNSS 设备发送伪造全球定位系统 (global positioning system, GPS) 信号, 使航空器得到错误的位置数据并通过 ADS-B 广播, 影响空管的决策, 导致航班延误或误入管制空域[20-21]; 速度欺骗攻击针对获取后的 ADS-B 报文中速度字段的格式进行伪造, 生成新的速度数据, 来制造虚假的速度漂移趋势, 误导地面空管或机载防撞系统对航空器航迹的预测, 产生错误的判断[22-24]; ADS-B 身份欺骗攻击指的是攻击者通过伪造已有合法航空器的身份标识, 如 ICAO 地址, 并以此身份向 ADS-B 地面站或其他航空器广播虚假的位置、速度、高度等数据, 实现对 ADS-B 系统的误导或干扰[25-27], 此类攻击不仅会导致航空器身份混乱, 增加空中事故的发生, 还可能被用于掩盖其他非法行为, 如军用侦察机伪装民航客机对他国空域进行侵犯[28]; 重放攻击指的是攻击者截获合法 ADS-B 报文后, 在不同位置或时间重新广播这些报文, 使得空管人员或其他航空器误以为此类报文为实时数据, 由于 ADS-B 缺乏身份认证和时间同步机制, ADS-B 接收端无法区分原始报文与重放报文, 因此, 此类攻击极具隐蔽性[29-30]。

2.2.2　注入攻击

注入攻击主要用于系统攻击, 通过伪造大量新目标或错误警报来干扰空管系统的正常运行, 容易导致空管系统过载。

地面站目标注入攻击是攻击者专门针对地面站发送大量虚假的 ADS-B 地面目标报文, 造成大量虚假目标填满机场地面监视系统, 使空管人员对机场跑道或其他区域的使用情况出现误判, 影响航班起降安排[24]; “幽灵飞机”注入攻击[14-16] 是攻击者利用软件无线电设备, 向空管站点发送格式合法但虚假的 ADS-B 报文, 生成大量未运行航空器, 即“幽灵飞机”, 这些“幽灵飞机”可能具有虚假的 ICAO 代码、随机轨迹、非运行航班识别号等, 使得空管人员难以分辨真假, 最后需要花费大量时间排查“幽灵飞机”, 对航班管理造成重大影响; 错误警报注入攻击[31] 指的是攻击者广播伪造的 ADS-B 紧急代码, 如 7500(劫机代码)、7600(失联代码) 等, 导致空管系统对运行航空器产生误判, 最终导致航班被迫备降或空中紧急事件; 轨迹伪造攻击是攻击者通过主动注入伪造的 ADS-B 航迹数据或修改部分真实航迹数据[32-34], 使地面监视系统显示的轨迹与实际飞行轨迹严重不符, 造成空管决策失误或空中交通预警系统误报。

2.2.3　数据篡改攻击

数据篡改攻击较前 2 种攻击方式的不同点在于其攻击方式是对原始合法 ADS-B 报文进行获取并修改后进行重播, 所广播的内容中不包含未出现的航班信息, 只针对已有航班数据中的特定信息字段进行修改。

ADS-B 报文篡改是攻击者在截取合法 ADS-B 报文后, 通过对报文中特定数据(如位置、高度、速度等信息)进行实时修改或延迟广播当前航班的报文, 造成飞行员或空管人员对航空器实时状况的误判, 导致空中冲突警报、错误避让等情况发生[35-36]; 在此基础上, 攻击者对攻击方式进行改进, 通过物理层信号叠加实现数据比特位的反转, 精确篡改消息中某些特定字段, 使 ADS-B 接收端误以为消息未被篡改而接收虚假数据, 虽然此类攻击单次影响较小, 但累积后可能会造成空管决策混乱甚至发生事故[12-13]; 时序篡改攻击是攻击者在截获合法的 ADS-B 报文后篡改报文时间戳, 使 ADS-B 接收端设备在当前时刻接收到过去随机时刻报文[19]; 机载设备篡改攻击指的是攻击者未经授权或内部人员恶意接入 ADS-B 接收机和 GNSS 接收机, 直接修改设备数据, 广播虚假 ADS-B 报文, 此类攻击方式难以通过外部检测发现其虚假性[37]; 信号特征篡改攻击是攻击者利用 ADS-B 输出端所采用的射频指纹识别技术漏洞, 通过模拟合法航空器 ADS-B 输出端的射频特征, 篡改或伪造原始指纹, 使基于指纹识别的安全防护失效, 此类攻击不仅会导致 ADS-B 身份认证失效, 更会导致攻击者长期冒充合法航空器进行虚假数据广播, 严重扰乱空域监视和管理的可靠性[38-41]。

2.3　干扰攻击

干扰攻击指的是攻击者利用特定设备向 ADS-B 系统的通信信道发送大功率的干扰信号, 以阻断

ADS-B与地面站或其他航空器之间的正常通信。此类攻击通常利用连续高功率波形或特定频率的信号来实现干扰，从而使目标的ADS-B信号接收部分或完全失效。

无线电干扰攻击指的是攻击者在ADS-B标准通信频段，利用高功率射频干扰器增大攻击范围内ADS-B接收端的噪声水平，使得合法ADS-B报文被干扰或淹没，无法得到解析，造成监视服务短期甚至长期瘫痪的风险[27]；GNSS干扰攻击是攻击者针对GPS频段，通过高功率干扰信号，使航空器GNSS接收端无法正常接收正确位置信号，导致航空器无法获取精确定位，进而造成飞行员误入禁飞区或增加相邻航空器碰撞风险[42]；二次雷达(secondary surveillance radar, SSR)应答干扰攻击指的是攻击者发送大量格式相似或相同的ADS-B报文，使接收端无法分辨真实航空器信息与干扰信息，从而降低信息处理效率[43]；此外，ADS-B中最为常见的干扰攻击方式为分布式拒绝服务(distributed denial of service, DDoS)攻击，通过对其ADS-B所运行的频段持续发射强功率无线信号，如ADS-B报文前导码或随机噪声信号，使ADS-B输出端的完整正常报文严重干扰或完全被淹没，从而造成ADS-B通信服务的中断[4]。此外，攻击者采用数据泛洪攻击，利用ADS-B开放的通信特性，大量生成和发送虚假的ADS-B报文，使地面站或航空器接收端在短时间内处理大量的信息，导致设备处理能力过载甚至瘫痪，或者通过发送与ADS-B报文信号频率相同但相位相反的信号以完全抵消合法信号，阻止任何ADS-B报文的传输和解析，导致管制屏幕上目标完全丢失，形成区域性通信盲区，如在繁忙航线区域则可能引发严重飞行事故[44]。ADS-B攻击方式分类如表2所示。

表2 ADS-B攻击方式分类

Table 2 ADS-B attack modes classification

攻击方式	攻击层次	所属攻击类型	攻击手段	技术难度	影响范围	检测难度	攻击数据组成	典型危害	参考文献
无线电干扰	物理层	干扰攻击	频谱干扰	中等	区域性	中等	无报文数据	区域通信瘫痪	[27]
GNSS干扰	物理层	干扰攻击	GNSS频段干扰	中等	广泛	中等	无报文数据	导航失效	[42]
信号特征篡改	物理层	数据篡改攻击	无线电信号伪造	高	单一目标	高	虚假报文与真实报文	指纹识别失效	[38-41]
比特位反转篡改	物理层	数据篡改攻击	信号叠加造成数据位反转	高	单一目标	高	虚假报文与真实报文	误导性数据传播	[12-13]
机载设备篡改	物理层	数据篡改攻击	内部设备篡改	高	单一目标	高	虚假报文与真实报文	破坏设备	[37]
被动窃听	数据链路层	被动窃听攻击	ADS-B信号截获	低	单一目标	高	真实报文	信息泄露	[18-19]
ADS-B身份欺骗	数据链路层	欺骗攻击	伪造ICAO代码	中等	单一目标	中等	虚假报文与真实报文	身份识别混乱	[25-28]
SSR应答干扰	数据链路层	干扰攻击	大量类似报文干扰	中等	广泛	高	虚假报文与真实报文	真实目标识别困难	[43]
GNSS欺骗	数据链路层	欺骗攻击	伪造GNSS信号	高	单一目标	高	虚假报文与真实报文	位置错误	[20-21]
错误警报注入	数据链路层	注入攻击	伪造ADS-B广播	低	广泛	中等	虚假报文	管制决策混乱	[31]
“幽灵飞机”注入	数据链路层	注入攻击	大量虚假航迹注入	低	广泛	中等	虚假报文	空管超载	[14-16]
时序篡改	数据链路层	数据篡改攻击	延迟合法报文传播	中等	单一目标	高	真实报文	时序错误导致决策混乱	[19]
ADS-B报文篡改	数据链路层	数据篡改攻击	截获并篡改真实报文	高	单一目标	高	虚假报文与真实报文	数据误导	[35-36]
轨迹伪造	数据链路层	注入攻击	轨迹生成算法	高	单一目标	高	虚假报文与真实报文	位置误判	[32-34]
速度欺骗	数据链路层	欺骗攻击	伪造速度数据	中等	单一目标	中等	虚假报文与真实报文	错误避让决策	[22-24]
重放	数据链路层	欺骗攻击	报文重播	中等	单一目标	中等	虚假报文与真实报文	数据时间混乱	[29-31]
数据泛洪	网络层	干扰攻击	报文泛洪	较低	广泛	高	虚假报文	系统瘫痪	[44]
分布式拒绝服务	网络层	干扰攻击	多点伪造信息	中等	广泛	高	虚假报文	全面服务中断	[4]
地面站目标注入	网络层	注入攻击	伪造信息格式	低	区域性	中等	虚假报文	虚假目标干扰	[24]

2.4 异常检测问题形式化定义与评估指标

为了系统性地评述后续的异常检测方法，本节先对该问题进行形式化定义，并介绍通用的性能评估指标。

ADS-B数据本质上是多变量时空间序列。一条飞机的航迹可被表示为一个时间序列$T=\{\boldsymbol{x}_1,\boldsymbol{x}_2,\cdots,\boldsymbol{x}_n\}$。其中，$\boldsymbol{x}_n$为在时间戳$n$观测到的状态向量，该向量通常包含多个维度的信息，可以归纳为运动学状态(经度、纬度、高度、速度)、身份标识(ICAO地址、呼号)，即$\boldsymbol{x}_n=(J_n,W_n,G_n,V_n,\cdots,I)$，$J$为经度，$W$为纬度，$G$为高度，$V$为速度，$I$为身份标识。

基于此，ADS-B异常检测任务可以被形式化地描述为：构建一个判别模型$f(\cdot)$，该模型对时刻t下输入的单个数据点y_t(逐点检测)或一个包含上下文信息的航迹片段S_{sub}(序列检测)进行评估。模型的输出通常是一个连续的异常分数$s=f(y_t \text{ or } S_{\text{sub}})$，该

分数衡量了输入数据偏离正常模式的程度。最终，通过将该分数与一个预设或动态调整的阈值θ进行比较作出判断: 当$s>0$时，该数据点或航迹段被标记为异常。阈值θ的选择至关重要，其通常在验证集上根据可接受的误报率凭经验设定。

根据训练数据的不同，该任务可分为监督学习、半监督学习和无监督学习。由于真实攻击数据的稀缺性，无监督学习在 ADS-B 异常检测中尤为常见。

为定量评估检测模型$f(\cdot)$的性能，通常基于混淆矩阵计算一系列指标，混淆矩阵中的元素包括真正例 T_{P}、假正例 F_{P}、真反例 T_{N} 和假反例 F_{N}。常用评估指标包括精确率 P、召回率 R、F_1 分数及误报率 (false alarm rate, FAR)。评估指标的计算公式如下:

$$P=\frac{T_{\mathrm{P}}}{T_{\mathrm{P}}+F_{\mathrm{P}}} \tag{1}$$

$$R=\frac{T_{\mathrm{P}}}{T_{\mathrm{P}}+F_{\mathrm{N}}} \tag{2}$$

$$F_1=2\frac{PR}{P+R} \tag{3}$$

$$E=\frac{F_{\mathrm{P}}}{F_{\mathrm{P}}+T_{\mathrm{N}}} \tag{4}$$

式中: E为误报率。

2.5　ADS-B 数据特性与检测数据集构建

理解 ADS-B 数据的基本特性与评测数据集的构建方式，是评估和设计异常检测方法的前提。ADS-B 数据作为一种典型的多变量时空间序列，其关键特点给检测带来了挑战与机遇: 数据以秒级或亚秒级高频采样，形成了高密度序列; 其内容融合了时间戳、三维空间坐标与速度等多维属性，呈现出强烈的时空耦合性; 同时，飞机轨迹遵循物理规律，为模型提供了强运动学约束作为先验知识; 数据的统计特性会随飞行阶段变化而呈现非平稳性，对算法的泛化能力提出了更高要求。鉴于已标记的真实攻击数据在学术研究中极为稀缺，研究者通常采用模拟攻击注入的方式，在真实的正常数据集基础上构建评测基准。这些数据构造方法与本节讨论的攻击类型紧密呼应。具体而言，对于轨迹伪造攻击，当前的研究已经从简单的静态位置偏移，演变为动态和智能化的攻击模拟。例如, Panda 等[22]利用强化学习来训练一个攻击智能体，该智能体通过不断试探与学习，能够自主发现目标防御系统(如空中交通冲突解脱算法) 的决策边界和弱点，从而生成一系列经过精心设计、以诱发安全冲突为最终目的的欺骗性飞行动作作为序列。这种方法生成的攻击数据不再是孤立的随机异常点，而是在整个时序上具有连贯性和高度对抗性的恶意轨迹，更能考验检测系统的极限性能。在“幽灵飞机”注入攻击方面，近期的研究焦点也从模拟单个虚假目标转向了大规模、协同化的攻击场景。例如, Melvyn 等[30]针对低空监控环境，深入研究了“幽灵飞机”泛洪攻击的数据生成与检测，攻击者并非注入一个孤立的假目标，而是同时生成大量看似合理但并不存在的飞行轨迹，旨在通过信息过载的方式，耗尽自动化系统的处理资源或造成人类操作员 (如管制员) 的认知饱和与决策困难。这种模拟生成协同飞行的虚假编队，比注入单个、无关联的“幽灵飞机”，对整个监视系统的韧性提出了严峻得多的挑战。此外，其他关键的数据构造方法也愈发精细。重放攻击的模拟通过截获一段真实的历史航迹数据，将其时间戳篡改为当前时刻后重新注入数据流，其目的在于制造一个位置完全错误但轨迹动态极为逼真的“时空错位”目标，这对缺乏消息新鲜性验证的系统是巨大威胁。而 ADS-B 身份欺骗攻击的模拟则通过全局替换航迹中的 ICAO 地址来实现，这不仅会造成空中态势图上的身份混淆，还可能被用于掩盖非法飞行活动或对特定合法航空器进行嫁祸式干扰。

3　ADS-B 异常检测方法

ADS-B 系统在设计之初未考虑系统级的安全防护机制，其开放式广播通信结构导致该系统在实际运行中面临严重的安全风险。上述攻击手段普遍技术门槛低、实施成本小，并具有较强的隐蔽性和破坏性，能够在短时间内对空管系统的稳定性与航班运行的安全性造成严重威胁。此外，不同攻击方式在影响范围、检测难度及所造成的危害呈现出显著差异，亟须系统地构建有效的安全防护体系。针对 ADS-B 系统脆弱的安全特性，异常检测作为重要的防御手段，在保障飞行信息完整性与系统运行可靠性方面发挥着关键作用。在深入探讨各类异常检测方法之前，理解 ADS-B 数据的基本特性与评测数据集的构建方式是研究的基础。ADS-B 数据是一种典型的多维时空序列，其关键特点包括: 由秒级广播形成的高频采样; 融合空间、时间与速度等多维属性的多维时空性; 遵循物理规律的强运动学约束; 随飞行阶段变化的非平稳性，这对模型的泛化构成了挑战。鉴于真实攻击数据的稀缺性，学术研究普遍采用模拟攻击注入的方式构建评测数据集，即在真实的正常数据基础上，通过恶意修改实现轨迹伪造、生成虚构航迹注入“幽灵飞机”、重播历史数据模拟重放攻击或篡改 ICAO 地址进行 ADS-B 身份欺骗。

3.1 基于一致性检验的ADS-B异常检测方法

基于一致性检验的ADS-B异常检测方法通过引入独立的观测数据源或其他可信信息，采用物理测量或数学计算方式，将ADS-B广播的报文与这些独立数据源进行交叉验证，以确定广播报文的真实性与一致性。当ADS-B广播报文与独立测量数据之间的差异超出预定阈值时，即可快速有效地识别出系统中存在的报文异常或遭受的恶意攻击，从而判断报文的完整性和真实性。

自2017年开始，基于独立定位技术的异常检测方法被用于ADS-B的异常检测，该类方法通过对ADS-B广播报文中的航空器位置信息与地面站独立测量的实际位置进行比对，检验ADS-B发送报文的真实性[43]。然而，此类方法对地面传感器布局的条件要求较高，且易受到同步误差及环境噪声的影响，导致单一数据源的定位精度下降，难以有效识别日益复杂的攻击方式。因此，国内外学者开始提出基于多源数据融合的方法，即综合ADS-B报文、一次雷达、SSR等多种独立监视数据源，通过交叉验证的方式提高异常检测的鲁棒性和精度[45]。同时，为了有效防范更为复杂的ADS-B报文篡改攻击，在之前2种方法的基础上提出了密码学的方法，通过添加数字签名或时间戳来验证当前ADS-B报文的真实性[4]。

本节将系统综述基于独立定位技术、多源数据融合、密码学方向在ADS-B异常检测中的应用，分析各类异常检测方法在检测精度、泛化能力方面的优势与不足。

3.1.1 基于独立定位的异常检测方法

基于独立定位的异常检测方法的检测过程为：首先，由多个地面站或接收机接收来自目标航空器的ADS-B广播报文；其次，利用接收到的报文，通过物理测量技术独立计算出航空器的实际位置，并与ADS-B广播的位置数据进行实时或准实时的对比分析；然后，计算这2种位置数据之间的偏差或误差，并与事先确定的阈值进行比较；最后，如果偏差超出正常容许范围，则将ADS-B报文判定为异常数据并触发警报。

针对ADS-B依赖航空器主动报告位置，容易受到攻击者发送虚假ADS-B报文的攻击，Naganawa等[43]提出了使用广域多点定位(wide area multilateration, WAM)系统的扇区天线阵列接收ADS-B信号，通过幅度单脉冲技术测量信号的入射角度和解码ADS-B信号获取到的航空器位置信息计算得到的期望到达角度做差，并将差值与预先设定好的阈值进行比对，判定该信号是否异常，但该方法的准确性严重依赖扇区天线的方向校准精度，使得检测效果受环境影响较大。在此基础上，Leonardi[19]提出了利用信号到达时间差(time difference of arrival, TDOA)结合K近邻(K-nearest neighbor, KNN)算法的方法，在离线状态下建立覆盖监视区域的二维网格，并计算网格中各点到多地面站的预期TDOA，将结果保存到数据库中，实时接收航空器的ADS-B广播报文以计算实际TDOA数据，并利用KNN算法在数据库中匹配与实时数据最近的k个点来估计航空器的实时位置进行比对，该方法不需要复杂的接收设备，也无需对传感器精度有较高的要求，但在复杂环境下会导致数据库数据频繁更新及在线实时处理时延增大。针对此问题，Leonardi等[14]将两步拓展卡尔曼滤波(two-step extended Kalman filter, TEKF)引入对ADS-B异常检测的方向中，将当前ADS-B报文与根据历史飞行状态预测得到的数据进行对比，执行第一次卡尔曼滤波更新，实现初步异常检测，利用众包传感器网络测量的TDOA数据进行二次卡尔曼滤波更新以检测精细轨迹欺骗攻击。同时，Zhao等[46]通过融合TDOA、AOA测量信息，并采用交互多模型(interacting multiple model, IMM)算法实现对ADS-B航路多点定位的监视方法，提高了ADS-B报文的检测精度。

为解决多源空中交通监视环境中无人机参与协作时难以识别ADS-B虚假报文的问题，Chai等[47]提出一种将到达时间总和(time sum of arrival, TSOA)与TDOA、AOA数据协同定位的异常检测方法，其架构如图3所示。首先，采用Chan算法对目标位置进行初步估计；然后，通过改进Taylor算法进行迭代修正，提升定位精度并消除传统方法中“二解”歧义问题；最后，将ADS-B广播位置与联合

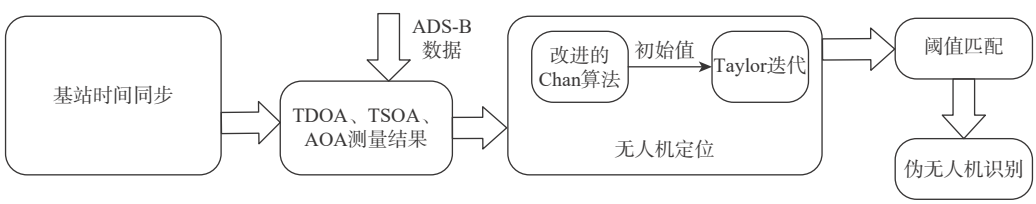


图3 数据协同定位方法架构[47]

Fig. 3 Architecture of data collaborative positioning method[47]

定位结果进行对比, 确定该报文真实性。近年来, 随着攻击手段不断增强, 攻击者开始针对地面站时间同步误差不敏感作为突破口, 使得之前的方法检测精度大幅下降。针对上述问题, 刘海涛等[21] 提出了一种到达时间间隔差 (interval difference of arrival, IDOA) 的方法, 与上述方法相比, IDOA 方法不需部署传感器或复杂的天线阵列, 仅需地面站接收到的相邻 2 条 ADS-B 报文位置消息的时间间隔差与理论位置计算得到的时间间隔差构造检验统计量, 以此判断 ADS-B 报文的真实性。

近年来, 基于独立定位的 ADS-B 异常检测方法的研究总体主要体现为“工程可解释、场景制约显著”。一方面, 依托外部空间测量与时间观测构建的独立位置估计, 为广播位置提供了可复核的物理证据, 因不依赖深度模型训练而具备较低的数据门槛、较强的可解释性与可迁移性, 且在身份伪装、轨迹伪造与报文篡改等高风险场景中显示出稳定的核验效能; 但另一方面, 现有成果普遍受制于传感器几何布设、站间时间同步与设备标定等工程条件, 易受地形遮挡、多径干扰与电磁环境波动影响, 导致在广域稀疏网络中定位精度下降, 阈值敏感性增加。综上, 研究前沿正由“单一独立核验”走向“多源协同与自适应阈值”的体系化方向, 同时亟须标准化评测数据、可复现实验流程与面向大规模运行环境的工程化验证。基于独立定位的异常检测方法总结如表 3 所示。

表 3　基于独立定位的异常检测方法总结

Table 3　Summary of anomaly detection methods based on independent positioning

检测方法	数据集	针对攻击/异常类型	应用场景	优点	缺点
AOA[43]	Beechcraft B300飞机航行实验数据集	欺骗攻击	扇区天线部署区域	在WAM系统空域背景下, 抗欺骗水平高	严重依赖扇区天线方向校准, 偏差过大时抗欺骗效果降低
KNN+TDOA[19]	OpenSky+自建仿真数据集	欺骗攻击	传感器分布稀疏区域	无需部署高精度接收设备, 非理想几何条件下定位精度高	网格划分较细的情况下, 计算复杂度变高, 实时处理时延增加
TEKF+TDOA[14]	OpenSky	GNSS干扰攻击	多个TDOA传感器部署区域	无需求解非线性多点问题, 检测范围更广	受网络布局影响较大, 容易导致TDOA精度下降
IMM+TDOA[46]	CCA1516航班数据集+自建仿真数据集	GNSS欺骗攻击、轨迹伪造攻击	GNSS信号易受攻击区域	在复杂航路下定位精度较高	受实时性影响较大, 大范围部署难度较大, 泛化性较差
TSOA+TDOA+AOA[47]	自建仿真数据集	欺骗攻击、轨迹伪造攻击	无人机参与的协作监视区域	定位精度高, 适用于复杂场景	对硬件要求较高, 更适用于军事或管制场景, 泛化性较差
IDOA[21]	自建仿真数据集	轨迹伪造攻击	时钟同步不理想区域	不再依赖地面站时间同步, 计算复杂度更低	对ADS-B报文中水平和垂直位置数据要求较高, 仍需多个地面站协调工作

3.1.2　基于多源数据融合的异常检测方法

基于多源数据融合的异常检测过程为: 首先, 系统同步地收集多个独立监视系统所观测到的同一目标航空器的数据信息, 包括 ADS-B 广播报文、雷达测量数据、SSR 数据及多边测量数据; 其次, 将来自不同数据源的飞行数据进行统一的时间轴匹配与对齐; 然后, 依据具体的融合策略对各数据源提供的位置、速度、高度等关键飞行参数进行一致性或相似性分析, 确定不同来源数据之间的残差; 再者, 针对这些残差建立通用或动态阈值, 并进行实时比对; 最后, 当来自不同数据源的同一飞行参数之间的差异持续超出阈值范围时, 判定 ADS-B 数据存在异常。

为解决传统多点定位方法要求 4 个及其以上地面接收机才能验证报文这一局限性, Darabseh 等[45] 提出了一种基于最少地面传感器 (minimal numbers of on-ground sensors, MNOS) 的 ADS-B 验证协议, 该方法在仅有 1～3 个地面接收机的情况下根据历史航线数据、飞机标识号、航班号分别构建概率矩阵, 并将最近可信 ADS-B 报文设为锚点, 与当前待检测 ADS-B 报文中的数据分别进行核验, 得到对应的比对结果并给出相应的分数, 将所有核验分数按预先固定好的权重进行加权计算, 判断该报文可信度, 但该方法对历史数据依赖较大, 同时对实时处理能力要求较高。针对此问题, 王布宏等[48] 提出了基于粒子群优化 (particle swarm optimization, PSO) 多核支持向量数据描述 (multi-kernel support vector data description, MKSVDD) 的 ADS-B 异常检测方法, 通过获取 ADS-B 报文数据与 SSR 数据并将其做差作为特征, 训练超球体分类器, 利用多核核函数提高分类精度, 采用 PSO 算法对惩罚因子、核参数进行自动优化, 提高检查性能, 实验结果表明, 遇到新航线时, 也可通过已有模型进行判断, 提高了对突发状况的检测精度。当前, ADS-B 报文常采用 1 090 MHz 扩展消息格式, 虽然其具有 24 bit 循环冗余校验机制, 但在数据传输或解析过程中仍存在错误, 导致接收到与正常轨迹偏离过远的位置, 影响可靠性。为解决此问题, Lukeš等[49] 提出了一种基于密度的

噪声应用空间聚类 (density based spatial clustering of applications with noise, DBSCAN) 异常检测方法，使用 ICAO 代码对待检测航班进行分组，将经纬度及飞行高度转换为地心固定 (Earth centered Earth fixed, ECEF) 坐标系，通过计算每个数据点的邻近点个数与预先规定好的阈值进行比对，判定是否为离群点，该方法适用于大规模数据处理，同时可以快速处理大偏差异常点。针对 ADS-B 身份欺骗攻击，Li 等[50]提出了一种基于轨迹数据 (track data, TD) 的异常检测方法，利用地面接收机解析 ADS-B 报文并提取其频率漂移特征，记录所接收到的 ADS-B 报文的中心频率与 1 090 MHz 频率的偏差，形成频率漂移曲线，同时通过多站点 ADS-B 数据比对，计算同一报文在不同接收站的信号相位差和幅度变化，结合 ADS-B 历史轨迹数据，与当前轨迹进行相似度匹配，输出轨迹评分，综合上述 3 种检测结果得出该航班是否存在异常数据或遭受恶意攻击。此类方法通过多种独立观测源的冗余信息来提升检测可靠性和鲁棒性，但对数据质量和同步性有一定的要求。

近年来，基于多源数据融合的 ADS-B 异常检测研究呈现出由“单一信号核验”向“跨模态协同感知”的体系化演进，同时涵盖数据层、特征层与决策层 3 类融合范式。总体上，多源融合显著提升了对身份伪装、轨迹篡改与环境诱发异常的可辨识性，并在复杂空域与极端工况下增强了鲁棒性，降低了误报或漏报。然而，现有工作仍受限于异构源的时间同步与空间匹配误差、传感器覆盖不均与缺失数据、跨域分布漂移及高维关联带来的计算开销。综上，当前研究方向亟须标准化数据集、统一评测协议与面向运行级别验证的工程实践。基于多源数据融合的异常检测方法总结如表 4 所示。

表 4　基于多源数据融合的异常检测方法总结

Table 4　Summary of anomaly detection methods based on multi-source data fusion

检测方法	数据集	针对攻击/异常类型	应用场景	优点	缺点
MNOS[45]	OpenSky	轨迹伪造攻击、ADS-B 身份欺骗攻击	地面站少，低资源环境	无需额外传感器，适用于低资源环境	对历史数据依赖较大，所用算法对实时性要求较高
MKSVDD[48]	OpenSky+SSR	拒绝服务攻击	高安全空域，具有SSR区域	适用于复杂空域，适应新航线能力较强	计算复杂度较大，异常数据解释性较弱
DBSCAN[49]	OpenSky	轨迹伪造攻击	航班密度大，海量轨迹数据	适用于大批量数据分析	需人工设定参数，对小幅异常位置检测能力有限
TD[50]		欺骗攻击	禁飞空域、机场周边	误报率低，对欺骗攻击检测精确度较高	依赖多地面站，对短时欺骗信号检测能力有限

3.1.3　基于密码学的完整性与真实性验证方法

与前述基于数据模式分析的异常检测方法不同，密码学技术本质上是一种主动的安全防御机制，其核心目标是通过加密、数字签名等手段从源头保证数据的完整性和来源的真实性。虽然其主要功能是预防和验证，而非传统意义上的“检测”，但它们构成了最确定的一种异常识别手段：任何未能通过密码学验证的报文都会被直接、确定性地判定为异常。因此，本节将其作为一种基于验证的确定性异常识别方法进行综述。

基于密码学的异常检测方法检测过程为：首先，消息发送端在广播 ADS-B 报文之前，使用事先约定或分配的密钥对报文内容进行认证处理，生成签名或哈希消息认证码；其次，将此认证码或签名附加在 ADS-B 广播报文中发送，接收端收到 ADS-B 报文后，依据共享的密钥或已知的公钥信息，对接收到的报文重新进行认证计算，验证报文的完整性和真实性；然后，比较接收端计算的认证码或签名与报文携带的认证码或签名是否一致；最后，若认证结果不一致，则认定该消息为伪造或篡改，判定为异常。

由于 ADS-B 报文仅提供明文广播，缺乏验证发送者身份及数据完整性的机制，针对此问题，Khan 等[51]提出了一种 ADS-B 安全认证框架，通过可信第三方基于椭圆曲线算法生成区域性的非对称公私钥对，并分发给相关区域地面站，航空器在飞行过程中随机生成对称密钥，同时利用分发好的公钥进行加密并对其进行拆分，形成若干片段，接收端重组片段后，利用接收报文中的校验字段生成初始向量，再将上述生成的密钥和初始向量在航空器端与地面端利用 AES-GCM 算法，对每条 ADS-B 报文生成安全认证标签，通过二者标签值比对对该报文进行判别，实验结果表明，该方法在不修改原始协议结构和硬件设备的前提下，带宽利用率与检测结果准确率较高，但并未考虑大规模密钥分发、证书管理等复杂场景。

在此基础上，Dabit 等[52]提出了一种面向全球的 ADS-B 安全区域认证框架，与之前方法相比，该方法通过椭圆曲线狄菲-赫尔曼 (elliptic curve Diffie-Hellman, ECDH) 协议计算共享密钥并进一步衍生出 AES-256 对称会话密钥，航空器端在发送 ADS-B 报文前，使用 AES-256 对报文内容进行加密，并

通过私钥对报文生成数字签名后一并广播, 地面端在收到报文后, 利用共享的 AES 会话密钥解密, 并以发送端的公钥验证数字签名, 实现对报文完整性与真实性的实时校验, 在实验仿真与分析中证明了对中等规模攻击具有明显的抵御效果且成本较低。

为解决大规模部署中证书管理负担过大的问题, Chen 等[53] 提出了一种基于分层身份签名 (based on hierarchical identity signature, BHIS) 的 ADS-B 安全框架, 其方法架构如图 4 所示, 由顶层密钥生成中心 (key generation center, KGC) 生成主密钥对, 并分发给下级航空公司服务器 (airline server, ALS), 为每架航空器进行身份密钥生成分配, 航空器利用自身私钥对广播报文进行签名, 地面端接收到报文后, 通过双线性配对运算重构签名, 并利用批量验证机制汇总多个航空器签名, 进行一致性校验, 该方法在消息处理效率与安全性方面有较大提升, 但并未对报文丢包问题进行研究。

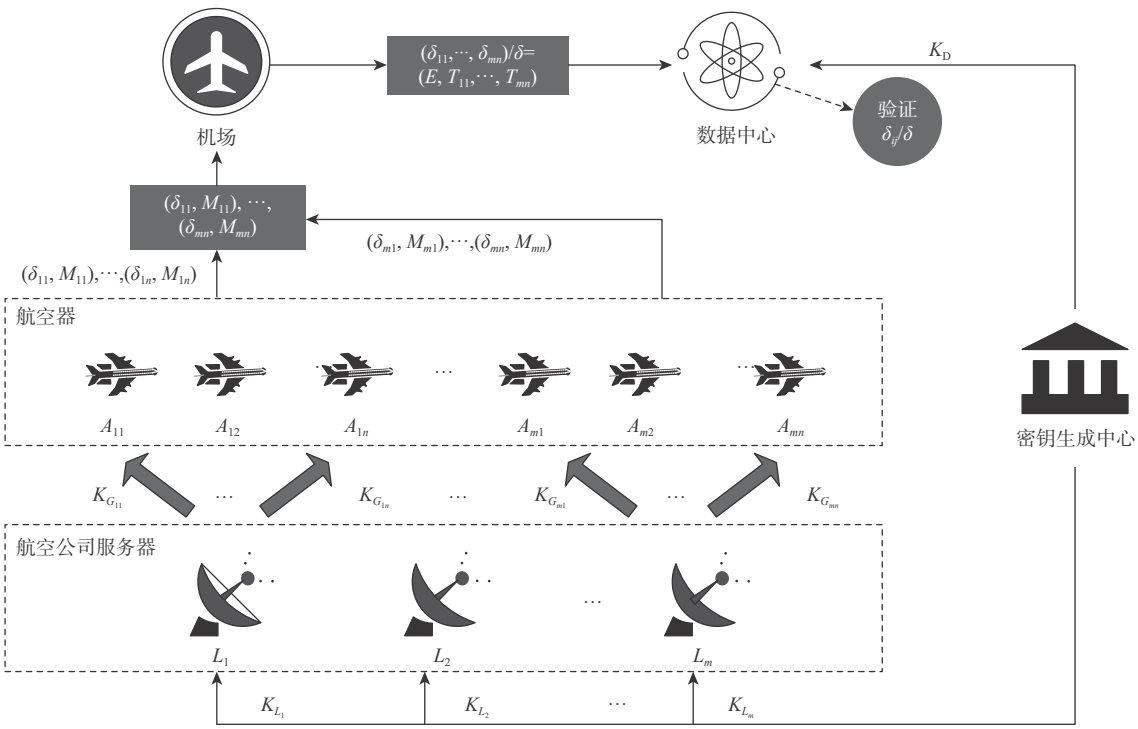


图 4　BHIS 系统架构[53]

Fig. 4　BHIS system architecture[53]

为解决上述问题, Yao 等[54] 提出了利用区块链与无证书签名结合的 ADS-B 认证方案, 通过 KGC 生成系统参数与部分私钥, 同时航空器端据此生成自身密钥对并将公钥上传至区块链, 航空器端用私钥签名 ADS-B 报文并添加时间戳, 并以纠删码分组传输, 地面端恢复签名后检查时间戳有效性, 并从区块链获取公钥进行批量签名验证。该类方法通过消息认证机制从源头识别异常, 避免伪造、篡改和重放等复杂攻击, 但密钥管理与通信开销是其普遍存在的挑战。

近年来, 基于密码学的完整性与真实性验证方法研究呈现出由通信链路被动监测到“源端认证-链路保护-接收端可追溯”的体系化演进。总体上, 此类方法以加密校验与身份绑定为核心, 通过在协议层提供报文完整性、消息新鲜性与发送方实体性证明, 显著降低了伪装、篡改与重放导致的误报或漏报, 具备强可解释性与形式化安全边界, 并在多站融合时能以密钥域为锚点实现跨网络一致性核验。然而, 现有工作同样受制于密钥生命周期管理与撤销机制、跨域信任根与证书基础设施的可扩展部署、航空适航与实时性约束下的时延或带宽开销, 并在复杂电磁和拥塞场景中, 时钟同步与丢包也会放大认证失败率并引入告警折中。面向此研究方向前沿, 亟须围绕标准化数据集、统一评测协议与运行级别试验场完成从安全性证明到工程化落地的闭环验证。基于密码学的异常检测方法总结如表 5 所示。

以上 3 种基于一致性检验的 ADS-B 异常检测方法优缺点如表 6 所示。此外, 一致性检验方法拓展了 ADS-B 异常检测的适用范围与适应能力, 为 ADS-B 提供了身份级、系统级的异常识别能力。

3.2　基于深度学习的 ADS-B 异常检测方法

随着 ADS-B 系统面临的攻击类型日趋复杂和多样化, 基于一致性检验的 ADS-B 异常检测方法

表5 基于密码学的异常检测方法总结

Table 5 Summary of anomaly detection methods based on cryptography

检测方法	数据集	针对攻击/异常类型	应用场景	优点	缺点
AES-GCM[51]	自采集数据集	ADS-B身份欺骗、ADS-B报文篡改、重放攻击	区域广播环境	不改变ADS-B原协议,实时性好,运算高效,低带宽占用	仍需密钥分发管理,丢包严重
ECDH[52]		数据篡改攻击、重放攻击	全球/洲际级广播环境	区域化分级密钥管理,实时性较好,性能开销适中	对跨区域管理场景关注不足,未处理丢包严重问题
BHIS[53]		数据篡改攻击	大规模/分层结构广播环境	有效解决跨区域管理场景下报文传输效率问题	计算开销相对较高,未有效处理消息丢包问题
ECB-CLS[54]	自采集数据集	欺骗攻击、数据篡改攻击、重放攻击、数据丢包	分布式/资源受限广播环境	无需证书管理,具备区块链透明性与抗丢包性,批量验证高效	系统复杂度高,区块链部署成本较高,增加通信开销

表6 基于一致性检验的ADS-B异常检测方法总结

Table 6 Summary of ADS-B anomaly detection methods based on conformance test

检测方法	主要针对的攻击类型	方法描述	优点	缺点
基于独立定位的异常检测方法	GNSS干扰攻击、欺骗攻击、轨迹伪造攻击	将独立物理测量量与广播信息对齐,构建检测统计量与误差度量,并与预设阈值比较进行检验	算法机制透明,可解释性强,且具有独立验证能力	依赖多站协同测量,部署与维护成本高,对测量误差及噪声较敏感
基于多源数据融合的异常检测方法	拒绝服务攻击、欺骗攻击	通过融合多源特征对正常轨迹进行建模,并计算当前轨迹与正常轨迹模型之间的偏差,实现异常检测	支持无监督学习,适应场景广泛,泛化性较好	计算复杂度较高,依赖大量训练数据,可解释性较差
基于密码学的完整性与真实性验证方法	重放攻击、数据篡改攻击、欺骗攻击	利用对称密钥或无证书签名算法对ADS-B报文进行加密,接收端获取公钥对报文进行验证	无需改变当前ADS-B协议格式,具有较好的向后部署性,并且具备批量验证与抗丢包能力	密钥分发管理需要消耗额外的资源,同时受限于ADS-B报文长度,嵌入认证信息具有一定负担

在实际应用中逐渐暴露自身存在的问题:外部独立测量资源的高度依赖、传感器部署成本高、密钥认证机制开销较大、实时响应能力弱及对复杂欺骗攻击识别能力不足等。这些问题在动态环境或资源受限区域中尤为突出,难以满足高密度空域下对安全性和实时性的双重需求。因此,研究重心逐步转向基于深度学习的ADS-B异常检测方法。

基于深度学习的ADS-B异常检测方法具有较强的数据学习能力和特征提取能力,能够适应海量高维度数据,从而在大规模数据场景下保持较好的性能与拓展性,同时能够捕捉复杂的时序关系,提高对缓慢偏移性异常数据或突发性异常数据的检测精度,有效提高了异常检测的泛化能力。

自2018年起,基于时序预测的思想开始被广泛应用于ADS-B异常检测领域中,其中,代表性模型包括长短期记忆网络(long short-term memory, LSTM)、卷积神经网络(convolutional neural network, CNN)、生成对抗网络(generative adversarial network, GAN)等,此类模型通常以正常样本训练,在推理时通过预测残差判别异常,适用于长期趋势与周期性变化的场景。但随着攻击方式愈发复杂,对时间序列数据检测的难度也随之增大,国内外研究者进一步引入了基于分类的思想,以射频指纹识别技术为代表,该技术借助深度网络从射频链路的硬件微差中学习设备身份表征,在有标签数据下直接输出正常、具体攻击类型、未知设备等类别,同时也发展出自监督或无监督学习以降低标签依赖,提升对未知设备的适应性。与此同时,基于数据重构的方法在缺乏标注时尤为有效:以自编码器(autoencoder, AE)等在正常数据上学习重构能力,检测阶段以重构误差为分数、无需先验异常知识即可发现潜在异常。

本节将系统综述基于时序预测思想、分类思想及数据重构思想在ADS-B异常检测中的应用,并分析各类基于深度学习的异常检测方法在特征提取、检测精度和泛化能力方面的优势与不足。

3.2.1 基于时序预测思想的异常检测方法

基于时序预测思想的异常检测过程为:首先,对连续的ADS-B报文进行滑动窗口切片与归一化预处理;然后,利用训练集学习窗口内的时间依赖,并对下一时刻或未来若干步的特征进行点预测;最后,依据正常数据的预测残差统计构建阈值,在检测阶段以预测残差与该阈值进行比较,实现对异常样本的判定。其中,LSTM模型多用于该思想的方法。

针对多航空器空间关联性不足的问题,Shabtai等[55]提出了一种基于空域状态序列(sequences of airspace states, SAS)的ADS-B异常检测方法,通过将提取到的区域特征与航空器特征组合成时序矩阵,利用编码器对时序矩阵进行特征编码,并将这些信息压缩为一个固定维度的隐状态向量,经过解码器将隐状态信息逐步生成预测序列并与真实序列对比,通过判别2个序列之间的相似度进行异常分类,该方法引入SHAP框架,增强了模型的可解释性,且实验结果表明,误报率低于0.15%,极大提

高了检测精度。

针对轨迹数据维度高、人工特征提取负担较大的问题, Ji 等[56] 提出了一种基于 LSTM 序列预测网络 (prediction network, PN) 的方法, 使用 Hausdorff 距离衡量待检测轨迹与正常轨迹模型的最大空间距离并设定评分, 构建轨迹语义兴趣序列, 计算待测轨迹与轨迹模型之间的语义相似度并输出评分, 通过阈值判别模块, 将 Hausdorff 距离评分、语义相似度评分分别与预设阈值进行比对, 判断该轨迹是否存在异常。

近年来, 商业航空受到严格的飞行规则限制, 在此情况下, 现有的异常检测方法对隐蔽性攻击检测精度不高。针对此类问题, Yue 等[57] 提出了一种基于 GAN-LSTM 的 ADS-B 异常检测方法, 其结构如图 5 所示, 通过关联飞行计划数据与 ADS-B 数据来构造空域飞行情景图像, 采用标准化相关函数对实时图像与预测图像进行对比, 并利用滑动窗口统计可疑图像数量进行分类。该方法解决了目前 ADS-B 异常检测方法未考虑 ATC 飞行规则而导致的检测精度低的问题, 能够有效捕捉飞行轨迹、速度等数据随时间演化的动态规律, 适用于识别缓慢漂移、突变或周期性异常等具有时序特征的攻击行为, 但对计算资源要求较高且在实时性要求较高的场景中应用受限。

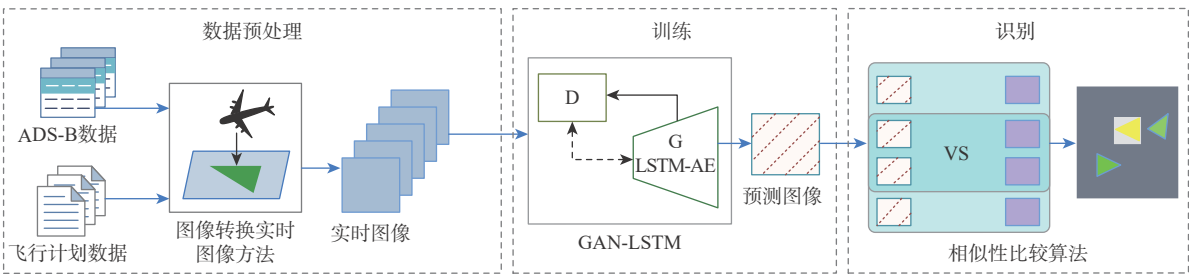


图 5　GAN-LSTM 结构[57]

Fig. 5　GAN-LSTM structure[57]

基于时序预测的 ADS-B 异常检测近年呈“单机轨迹点预测-区域多机场景预测”的演进。总体来看, 方法从单目标点预测走向多目标场景预测, 并与阈值学习深度耦合, 其优势在于对时序攻击的灵敏性和对业务规则的可融性。面向此研究方向前沿, 亟须围绕计算与时延约束、多机耦合与域漂移下阈值稳定及跨航线泛化与在线解释的权衡。基于时序预测思想的异常检测方法总结如表 7 所示。

表 7　基于时序预测思想的异常检测方法总结

Table 7　Summary of anomaly detection methods based on time series prediction thought

检测方法	数据集	针对攻击/异常类型	应用场景	优点	缺点
LSTM-SAS[55]	OpenSky	“幽灵飞机”注入	高流量机场周边空域	考虑并分析空域内多架飞机空间分布与相互关系, 内置异常原因可解释性	单机异常敏感度低, 计算复杂度较高
LSTM-PN[56]		轨迹伪造攻击	智慧交通系统	引入语义信息提高检测精度, 高效应对不同长度轨迹数据	严重依赖阈值设定, 对数据质量要求较高
GAN-LSTM[57]	CAAC	“幽灵飞机”注入、重放攻击、拒绝服务攻击	ATC环境下及具有商业航空背景	可视化异常情况, 预测精度增强	泛化能力受限, 计算资源需求较高

3.2.2　基于分类思想的异常检测方法

基于分类思想的异常检测过程为: 首先, 进行数据采集与标注, 完成清洗、对齐与分割; 然后, 依据任务定义构建类别体系, 并以监督学习训练判别器, 在开放场景下叠加开放集识别与持续学习机制; 最后, 在决策层输出离散类别及必要的定位或状态估计, 并辅以可解释性与运营级评估以支撑受监管的部署。其中, CNN 模型多用于该思想的方法。基于 CNN 的 ADS-B 异常检测框架如图 6 所示。

传统深度学习异常检测方法依赖轨迹特征, 并且缺乏端到端信号级伪造检测方案。为解决此问题, Joseph 等[25] 提出了一种基于生成对抗神经网络-卷积神经网络 (generative adversarial network-convolutional neural network, GAN-CNN) 的 ADS-B 异常检测方法, 通过将原始 ADS-B 报文输入到 GAN 模型中进行训练, 得到判别器, 利用一个二维 CNN 接收预处理后的 I/Q 数据矩阵, 并在时间维度上提取局部模式信息, 经过展平操作后输入至多个全连接层, 利用非线性映射实现高阶特征组合, 由 Softmax 输出各类航空器的识别概率, 但该方法依赖高质量原始数据, 同时识别航空器类型仅限于已

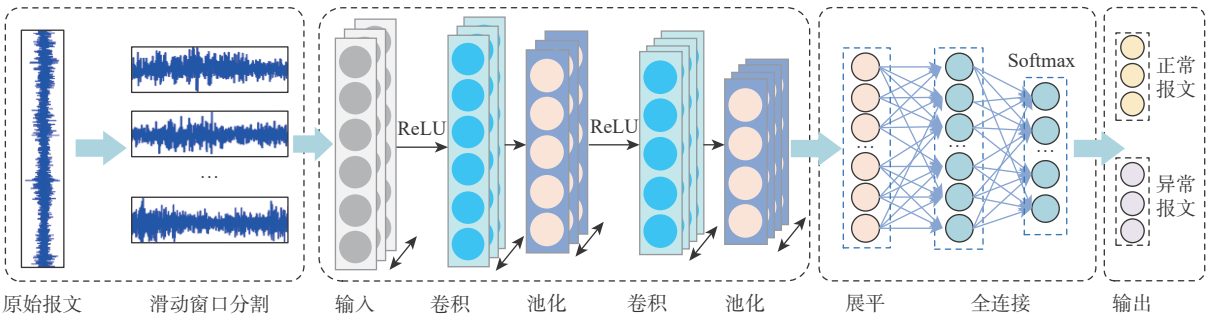


图 6 基于 CNN 的 ADS-B 异常检测框架

Fig. 6 ADS-B anomaly detection framework based on CNN

知类型，泛化能力有限。针对此问题，Cai 等[58]提出了一种基于注意力机制的卷积网络 (attention mechanism convolutional network, AMCN) 框架，通过构建逻辑回归分类器，对待检测范围内的 ADS-B 数据进行二分类，使用一维卷积网络提取单架航空器的时空特征，生成局部特征图并融合改进位置编码方法，将多个航空器的相对空间关系映射到注意力网络中，实现全局语义建模，将干扰源定位任务转化为干扰区相对位置的 16 类分类问题，并通过软标签的形式输出分类概率，最终确定干扰源所在网格区域。该方法通过先筛选再定位的分阶段策略有效减轻了模型负担，并使用相对位置分类策略提升了跨区域的鲁棒性和泛化能力，其结构灵活、可扩展性强，适用于高维 ADS-B 时序特征的分类或预测任务，特别是在数据具有明确标签和分布规律的情形下能够实现高精度识别，但对时间依赖性强的攻击模式敏感度较低，同时在异常样本稀缺或标签不完整的情况下性能可能下降。

为应对 ADS-B 系统故障或自然因素导致的未及时广播 ADS-B 报文情况下所带来的空域安全隐患，Heiselberg 等[59]提出了一种基于多光谱遥感图像与 CNN 的飞行器状态估计模型，利用 Sentinel-2 卫星图像中因通道成像延迟而产生的颜色错位特性，从中推断飞行器在成像时刻的空间位置与动态特征，利用 CNN 提取图像中飞机的空间形状与颜色错位特征，回归输出包含位置、尺寸、航向、速度、高度等 7 维状态向量，卷积层捕捉局部结构与位移信息，回归层联合输出物理状态，并采用 Smooth L1 与 focal loss 优化训练，该模型可在 ADS-B 缺失场景下对飞行器进行检测与状态估计，实现无源空域监控，但模型依赖训练集中已配准的 ADS-B 数据，难以应对无标签目标或训练样本分布外的新型飞行器。

同时，为解决 ADS-B 系统遭受注入攻击的问题，Vajrobol 等[31]提出了一种基于集成元学习 (ensemble meta-learning, EML) 与可解释 AI 的异常检测模型，采用 LSTM、随机森林及 XGBoost 这 3 种模型作为基础模型并输出各自的异常值，将 3 种模型的异常值作为元特征用于训练元模型并输出分类结果，可解释 AI 根据分类结果提供透明的决策解释。该方法相较于单一检测模型有较高的检测精度，同时具备更好的泛化能力。

为解决“闭时集训练、开时集部署”场景下由时间漂移与域偏移导致的识别率显著下降这一问题，Zheng 等[60]提出了一种以实收信号与基于统计建模的理想重建信号共同构造二维时频特征图 (time-frequency feature diagram, TFFD) 的方法，并在引入频偏建模层的 Swin Transformer 中完成判别，从系统层面打通“采集-解析-特征-识别”链路以提升跨时稳健性，该方案在闭时集与开时集均取得较优性能，优势在于充分利用物理先验与重建对齐以增强特征鲁棒性，但局限在于开时集精度仍有明显回落，对特征构造与较干净标注的依赖较强，跨更长期时漂与复杂电磁环境的泛化能力仍受限。

为缓解上述方法对充足标签依赖强，并难以在少样本条件下持续扩展等方面的局限，Li 等[61]提出了一种小样本开放集增量学习 (few-shot open-set incremental learning, FSOSIL)，联合原型正交化、开放集损失与自适应阈值机制实现识别已知、发现未知、低遗忘，该方法的优势在于仅依靠单样本训练且存在未知类别的情形下，仍能实现对已知目标的高精度识别，并对未知目标进行有效拒绝，但缺点在于训练流程复杂、对元任务采样与超参数敏感，且默认标签相对洁净，难以直接应对“严禁样本回放”的连续学习约束。

近年来，基于分类思想的异常检测研究总体呈现由封闭集判别向开放集-增量-噪声鲁棒的系统化演进。虽然此类方法实时性与可扩展性好，易与规则、物理先验及多源证据进行级联融合，但依赖标签，同时对时漂敏感，且流程复杂。综上，研究前沿亟须构建“开放集+类增量学习+少样本学习”统一原型框架并配合保形预测，并推进无回放的半监督持续学习与对抗合成数据扩增。基于分类思想的异常检测方法总结如表 8 所示。

表 8　基于分类思想的异常检测方法总结

Table 8　Summary of anomaly detection methods based on classification thought

检测方法	数据集	针对攻击/异常类型	应用场景	优点	缺点
FlightSense[25]	自采集数据集	ADS-B身份欺骗	未加密广播环境	无需手动特征提取, 自动学习信号特征	识别仅限已知飞机, 依赖高质量I/Q数据
AMCN[58]	中国民航数据主中心采集	GNSS干扰	地面无GNSS信号监测站的区域	支持大规模干扰源定位, 定位精度优于传统方法	依赖多个飞机数据协同分析, 对细粒度干扰事件灵敏度有限
EML[31]	Mendeley平台	“幽灵飞机”注入、速度欺骗攻击	对模型透明性有高要求的航空安全环境	高效的特征选择方法, 提升对特定攻击的敏感性, 内置决策解释机制	部署成本较大, 模型复杂度较高
Sentinel-CNN[59]	OpenSky	ADS-B设备故障	ADS-B缺失空域	实现无源目标检测, 有效提升空域态势感知能力	在姿态变化剧烈或强干扰条件下仍面临误差累积问题
TFFD[60]	自采集数据集	ADS-B身份欺骗	空管监视与航空通信安保的实时身份鉴别	成本可控, 便于维护	工程复杂度高
FSOSIL[61]	自采集数据集	伪造信息、身份欺骗	低样本、开集、增量场景下的设备身份鉴别与拒识	可持续拓展, 数据效率高	依赖元任务设计划分策略, 任务构造与调参成本较高

3.2.3　基于数据重构的异常检测方法

基于数据重构思想的 ADS-B 异常检测过程为: 首先, 在训练阶段仅观察正常轨迹, 学习正常数据在潜在空间的分布, 并尝试尽可能准确地重建输入信息; 然后, 在检测阶段, 待测报文经模型重构后与原始数据进行比较, 重构误差被用来衡量数据与正常模式的偏差; 当误差超过基于正常数据统计规律设定的阈值时, 即判断为异常。阈值可以通过支持向量数据描述或利用重构误差分布的高分位数自适应确定, 以保证对未知攻击的泛化能力。其中, AE 模型多用于该思想的方法。基于 AE 的 ADS-B 异常检测流程如图 7 所示。

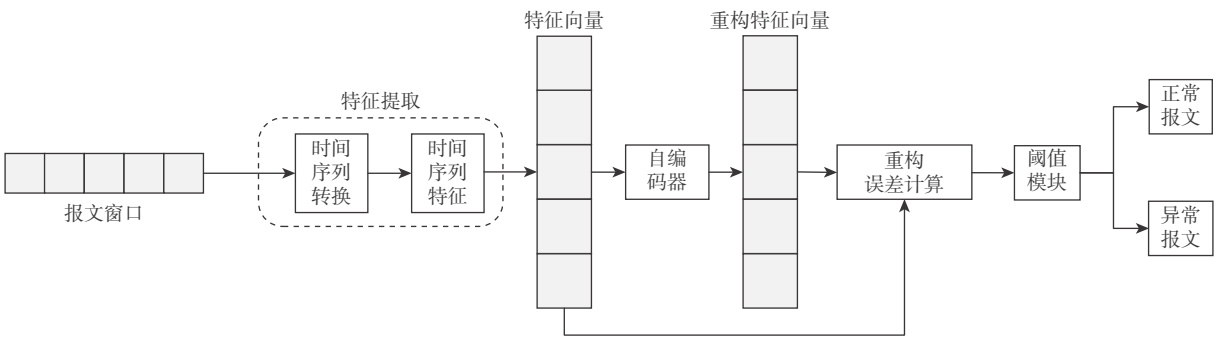


图 7　基于 AE 的 ADS-B 异常检测流程

Fig. 7　Flow chart of ADS-B anomaly detection based on AE

针对 ADS-B 协议本身缺乏安全机制导致的篡改、欺骗攻击等问题, Habler 等[62] 提出了一种基于 LSTM encoder-decoder 算法的 ADS-B 异常检测方法, 通过编码器将 ADS-B 广播报文序列编码为固定维度向量, 捕获时序依赖性, 利用解码器重新构造原始 ADS-B 报文序列, 对新的 ADS-B 序列采用余弦相似度, 计算重构误差, 并经由阈值模块判定是否存在异常。然而, 该模型需要一定的延迟积累窗口才能有效识别异常, 同时未能考虑空域中多个航空器之间的空间关联性。

ADS-B 协议因缺乏加密与认证机制, 极易遭受伪造、篡改、干扰等恶意攻击。然而, 现有方法还存在阈值设定机制缺乏自适应能力, 导致误判率高及模型存在过拟合或欠拟合风险的问题。为解决上述问题, Luo 等[63] 提出了一种变分自编码器-支持向量数据描述 (variational autoencoder-support vector data description, VAE-SVDD) 模型, 利用具备时序感知能力的编码器将序列映射至潜在空间, 捕捉其时间依赖性和分布特征, 通过解码器再从潜在变量中重构出原始序列, 由于每个数据点在多个滑动窗口中被重构多次, 为减少异常误判, 采用余弦相似度筛选其中位重构值作为最终输出, 计算重构值与真实值之间的差异, 并将误差序列输入 SVDD 模型中训练, 学习正常数据的边界分布, 通过测量新样本重构误差与 SVDD 球心的距离, 判断其是否越界, 从而实现异常识别。但该方法忽略了航空器飞行期间的上下文差异及重构值不稳定的问题。在此基础上, Chevrot 等[13] 提出了一种基于上下文自编码器 (contextual auto-encoder, CAE) 模型的 ADS-B 异常检测方法, 通过将 ADS-B 原始报文转换为标

准化后的多变量时间窗序列，并依据飞行阶段对数据进行标注分类，通过一个双向LSTM编码器进行特征编码，提取时间依赖性特征，并根据所处飞行阶段分别送入不同的上下文解码器重构数据，以重构误差为基础，分别为不同解码器计算对应的异常阈值，实现高精度的异常检测。该方法通过建模上下文差异，提高了对飞行阶段的异常检测精度，同时具有良好的可拓展性。

为了解决深度学习方法对新航线或历史数据缺失航班的检测精度和泛化性较差的问题，Fried等[28]提出了一种基于差分时序特征的自编码器(differencing time-series transformation autoencoder, DTTA)模型的ADS-B异常检测方法，通过将ADS-B报文中地理坐标转换为三维地心坐标系，并应用时间序列差分变换，以消除趋势性和季节性因素，提取反映飞行状态变化的动态特征，利用非递归结构的AE对正常航班数据进行训练，输入新数据后由模型进行重构，并计算其与原始输入之间的重构误差，将该误差与验证集上得到的误差分布进行比对，计算其在误差分布中的概率值，依据预设阈值进行异常判断。

为解决未知航班检测的泛化性不足及历史异常检测模型无法处理远距离依赖关系的问题，丁建立等[64]提出了一种基于Transformer-变分自编码器(Transformer-variational autoencoder, TVAE)的ADS-B异常检测模型，通过对原始ADS-B数据进行特征筛选与归一化处理，排除不随时间变化的冗余字段，针对时间点上的数据缺失，采用线性插值方法填补缺失值，以保持时序数据连续性，采用Transformer编码器进行长程依赖关系建模，通过自注意力机制，生成潜在的上下文特征表示，引入潜在随机变量来建模数据的随机性和整体性特征，估计该变量的后验分布，生成重构后的ADS-B数据，计算原始数据和重构数据之间的重构误差，并经过阈值模块来检测异常。该方法有效解决了现有方法无法处理长程时序数据的问题，提高了检测精度，但在实际应用中对训练数据的质量和分布覆盖范围高度敏感，若正常数据样本分布不完整或训练集存在异常混入，可能导致模型学习失效，重构能力泛化不足。在此基础上，Luo等[65]提出了一种基于时序卷积神经网络-Transformer-支持向量数据描述(temporal convolutional network-Transformer-support vector data description, TTSAD)的ADS-B异常检测模型，利用一维时序卷积网络(temporal convolutional network, TCN)模块对时间序列进行快速预测，将预测结果输入至Transformer重构模块，通过位置编码、自注意力和多头注意力机制对数据进行上下文建模与重建，以尽可能逼近原始序列，计算重构序列与真实序列之间的差值，并将该误差向量输入SVDD模块，其在高维空间中构造最小包围球，通过训练误差分布自动确定最优判定阈值，实现对异常数据的有效识别。该方法通过融合多模型，有效提升检测效率，同时实验结果表明在多种攻击场景下准确率可达94%，鲁棒性与泛化能力得到大幅提高。

近年来，基于数据重构思想的异常检测研究总体表现为不依赖异常标签，同时仅用正常数据即可建模，易与规则、多源证据级联，具备良好可迁移与实时部署潜力，但暴露出的问题在于对正常分布覆盖与数据洁净度敏感，且跨航线落地往往需要较多校准与流程治理。综上，研究前沿亟须以不确定性评估稳健化重构分数，同时利用无回放的半监督持续学习抵御污染与概念漂移，实现可解释、可运维、在线化的一体化框架。基于数据重构思想的异常检测方法总结如表9所示。

以上3种基于深度学习的异常检测方法优缺点如表10所示。深度学习方法通过训练可自动从

表9 基于数据重构思想的异常检测方法总结

Table 9 Summary of anomaly detection methods based on thought of data reconstruction

检测方法	数据集	针对攻击/异常类型	应用场景	优点	缺点
LSTM-编码器[62]	FlightRadar24	ADS-B身份欺骗、ADS-B报文篡改	单机或航空器内部	系统部署要求少，无需额外数据支持	高度依赖已知航线数据，实时性表现较差
VAE-SVDD[63]	OpenSky	拒绝服务攻击、数据篡改攻击	实时检测或历史数据回溯分析的高风险空域	较低的误报率和漏报率	对训练数据依赖较大，时序依赖捕捉能力有限
CAE[13]	OpenSky	错误警报注入	突发飞行事件识别	在不同飞行阶段的异常检测中表现优异	针对阶段过渡时的异常检测表现差
DTTA[28]	OpenSky	数据篡改攻击	不依赖历史数据检测航迹异常空域	对历史数据不足的航路或新航线泛化性较好	无法处理飞行中的动态变化
TVAE[64]	FlightRadar24	“幽灵飞机”注入、拒绝服务攻击	泛航线、无先验场景	有效捕捉时序数据的全局信息，处理大规模数据	训练过程资源消耗大，数据量小或包含噪声数据时，性能可能受到影响
TTSAD[65]	OpenSky	数据篡改攻击、重放攻击	轨迹安全监控	训练时间短，可拓展性好	结构相对复杂

表 10　基于深度学习的 ADS-B 异常检测方法总结

Table 10　Summary of ADS-B anomaly detection methods based on deep learning

检测方法	主要针对的攻击类型	方法描述	优点	缺点
基于时序预测思想	轨迹伪造、速度欺骗、重放攻击、“幽灵飞机”注入	通过建模时序数据, 能够捕捉序列中的长期依赖与动态行为变化	能有效建模序列数据中的长期依赖关系, 适用于飞行状态等具有时序性的行为模式识别	网络结构较为复杂, 训练过程计算资源消耗大, 且在长序列建模中存在梯度传播效率问题
基于分类思想	GNSS干扰、ADS-B身份欺骗	采用多层神经结构, 适合处理时序特征, 进行高维特征分类与学习	结构形式灵活, 适用于提取高维时序特征, 能够高效完成复杂模式的时序分类任务	对时间相关性建模能力有限, 难以捕捉数据随时间演化的动态特征
基于数据重构思想	数据篡改攻击、拒绝服务攻击	通过编码解码结构重构输入数据, 以重构误差判断样本是否异常	可在缺乏异常标签的情况下实现异常检测	模型对正常数据分布高度依赖, 若训练集覆盖不全, 容易对异常识别能力产生干扰

数据中学习关键特征, 挖掘潜在异常模式, 无需人工定义具体规则, 适应性更强, 且可根据不同应用需求灵活选择模型结构, 如监督、无监督或半监督模型, 也可融合多源信息, 适应多场景下的异常检测任务。

4　ADS-B 异常检测应用

在 ADS-B 的运行保障中, 现行空中管理体系仍然依赖飞行员与空管人员的人工报告、系统内置的运行告警、基于冗余导航手段等事后缓解措施, 并非实时对 ADS-B 报文进行可信性评估或 GNSS 干扰监测。文献 [66] 指出, 当前投入应用的射频干扰 (radio frequency interference, RFI) 报告并不能反映现场的真实情况, 报告数量只能提供小部分指示, 同时取决于人们是否愿意报告。因此, 需要将基于 ADS-B 异常检测技术的监测与评估模块嵌入既有监视体系, 以实现对报文可信性的在线评估与告警。

目前公布的 ADS-B 异常检测产品中, 主要采用几何一致性检验、多源数据一致性检验及时序预测方法, 在不改变现有监视链路的情况下, 面向航迹级与空域级 2 类目标提供自动检测、可信度评估与告警联动能力。相关应用场景如下:

1) 航迹溯源与可信度评分。对目标航迹进行几何重定位与运动学一致性比对, 给出报文来源可信度/验证得分, 溯源潜在的“幽灵飞机”航迹或冒名播发, 从源头降低伪造报文进入战术显示与自动化决策链的风险。

2) GNSS 干扰与欺骗态势监测。结合星基或地基 ADS-B 与多源监视, 在空域尺度统计导航完整性类别 (navigation integrity category, NIC) 或位置完整性类别 (position integrity category, PIC) 退化、定位漂移、丢报等指标, 形成近实时干扰热区与强度评估, 支持管制流量调配、航司运控改航及预案触发。

3) 已知异常模式识别与版本比对。利用时序模型 (如 EKF、IMM、深度学习预测残差) 对不同异常类型 (如位置偏移、速度/航向异常、轨迹伪造) 进行特征匹配与相似性检验, 判定是否命中既有异常样式库或出现新型异常类型。

随着复杂空域运行与数据规模的增长, 异常检测作为提升监视可靠性与安全韧性的核心手段, 已经成为学术界与工业界的研究热点。ADS-B 异常检测技术是新一代航空监视安全保障的重要基础。通过对航迹-报文-环境进行组成式分析, 提取多维度特征, 计算航迹可信度与空域健康度指标, 可在应用开发与运行维护全周期中检测异常航迹与不可靠数据源, 深度挖掘 GNSS 干扰、报文异常与数据质量风险, 实现从感知到决策的闭环管控。全面覆盖空域态势监测、运行审计取证、数据门控与第三方源管控及系统运维保障等应用场景。表 11 总结了当前已成功部署的 ADS-B 异常检测产品。

表 11　基于 ADS-B 异常检测技术的空域监测产品

Table 11　Airspace monitoring products based on ADS-B anomaly detection technology

产品名称	企业	检测对象与粒度	应用场景	优势	局限性
Aireon Safety Dashboard	Aireon	空域级指标化监测与趋势分析	面向航空导航服务机构与监管的空域风险监测	星基覆盖广、指标体系完善、支持区域与全球视角、运营成熟	商业化闭源、对接与采购成本较高、细节透明度有限
uAvionix truSky	uAvionix	航迹级报文真实性验证与可信度评分	面向无人机超视距任务	低时延服务、提供验证得分、生态集成成熟、易于接入现有管控链路	覆盖度受地面接收网络布局影响、空域级态势需与其他平台联动
Spire Global Aviation GNSS Interference	Spire Global	空域级干扰监测与区域告警	面向航空运营者和监管部门, 通过API提供ADS-B异常趋势与区域可靠性评估	全球覆盖, 支持实时API和自定义区域监测	算法细节和检测标准公开有限, 服务费用和对接成本较高
SkAI Data Services GPSwise	SkAI Data Services	空域级近实时干扰与疑似欺骗态势图与事件分析	航空公司运控评估、机队层级研判、研究与汇报	近实时可视化、开放生态灵活、易于快速验证与分析	数据完备性与一致性受众包网络密度影响、可靠性低于星基体系

5 面临的挑战与展望

近年来,尽管面向ADS-B的异常检测方法取得了显著进展,但在发展过程中仍面临诸多亟待解决的技术挑战,这些挑战不仅制约了现有检测模型在复杂环境下的检测性能和泛化能力,也影响了面向ADS-B系统异常检测技术在实际航空运行场景中的部署效果。随着攻击技术的不断演化,攻击者开始倾向采用更加隐蔽、复杂且具有对抗性的规避手段,使得传统检测机制难以有效识别与响应异常行为,暴露出当前检测模型在鲁棒性与可解释性方面的不足。本节将深入探讨当前研究中所面临的主要挑战,并展望未来可行的研究方向。

5.1 面临的挑战

1)对抗性攻击问题。随着技术的不断发展,异常检测方法进步的同时,也给恶意攻击者提供了新的技术手段。这些攻击是针对特定模型和数据集量身定制的,使其难以检测和防御,并导致异常检测中出现误报或漏报[67]。文献[68]明确指出,主流的深度学习异常检测模型在应对时间序列毒化攻击时极易被破坏。同时,文献[69]系统演示了针对基于深度学习的ADS-B欺骗检测器的物理层对抗攻击。因此,未来的研究应致力于系统引入对抗性稳健训练框架,将对抗样本融入模型训练流程,以增强模型对输入扰动的稳定性。同时,针对时间序列数据的特有结构,开发融合物理约束与时间连续性的攻击检测机制。

2)数据稀缺与不平衡。异常事件在真实航空运行中极为罕见,导致可用于模型训练的已标记异常数据十分稀少且样本分布不均。数据样本的不足和类别不平衡使得传统有监督模型难以有效学习异常模式,研究者往往不得不依赖无监督或半监督学习方法来检测异常,并通过模拟攻击数据来构建评估基准[70-71]。因此,未来的研究应关注合成攻击数据生成、多样化样本设计与多任务学习的融合机制。

3)可解释性缺乏。当前的深度学习检测模型大多属于“黑盒”,无法直观地向用户解释判定异常的依据[72-73],而传统统计模型基于高维特征空间超平面的判别同样难以被领域专家所理解。在航空安全这一关键领域,这种缺乏可解释性的现状不仅降低了用户对异常报警的信任度,也给后续人工分析带来困难。因此,后续研究应侧重于提高模型的可解释性,为深入理解数据与模型提供基础。

4)泛化能力不足。当前主流模型对新环境和未知模式的泛化能力欠缺仍是ADS-B异常检测的一大挑战。许多深度学习模型对训练数据的依赖性较强,当深度学习模型应用于训练分布以外的数据时(如新的航线、机型或全新手法的攻击),常出现检测性能显著下降的问题。部分方法甚至需要针对每条航线单独训练专门的模型,缺乏跨航线或跨区域的一般化能力[74]。同时,正常与异常的界限会随着时间推移和运行环境改变而发生漂移[75-76]。因此,未来的研究方向应在有限样本甚至零样本的条件下,让模型具备检测新型异常的能力。

5.2 未来研究展望

针对本文所指出的目前研究仍需面临的挑战,未来研究应集中于抵御对抗性攻击、增加可解释性及提高模型泛化性等方面,以进一步提高ADS-B异常检测方法的检测性能与实用性。未来可以重点研究的方向包括以下方面:

1)对抗性防御。为应对对抗性攻击威胁的加剧,未来研究应着重于设计更具鲁棒性的ADS-B异常检测模型,以抵御恶意攻击者的对抗性攻击、中毒注入攻击等其他攻击方式。可考虑通过“基础对抗训练+输入净化”的两段式策略构建安全退化通路。在训练阶段,针对物理可达扰动与小幅梯度扰动进行联合对抗训练以提升参数稳健性,推理阶段可叠加时序去噪与可行域投影以抑制异常微扰扩散,避免在未知分布下出现错误判决。

2)增强模型泛化能力。当前的ADS-B异常检测方法的研究大多依赖于版本落后或自采集数据集,但这些数据集存在时效性不足、可信度较差及严重的数据不平衡问题,难以满足当前异常检测模型提高泛化性的需求。因此,可考虑采用迁移学习等方法,实现预训练主干在目标空域少量标注上微调,并使用对抗式或统计匹配的域对齐削弱分布差异,同时跨站点以联邦方式聚合参数而非原始数据以满足合规与隐私约束,同时配合类别重加权与自适应阈值重标定维持稳定检出率与低误警率。

3)先验约束的重构学习。为增强ADS-B报文中的物理约束,可考虑以AE为核心,在解码端注入3类先验。物理先验通过对位移-速度-加速度的平滑约束,以及对协调转弯与升降率边界的惩罚,使运动过程连续且落在可行范围;当输出越界时,再用投影把点拉回可行域,对难以求导的硬规则生成可学习的惩罚。程序先验把进离场程序、扇区高度窗、禁飞区等编码为时空掩膜,对“违反规程”的片段在重构损失中加权放大,并用阶段感知门控在起飞、巡航、进近等阶段动态调节约束强度。运行先验把气象与调度作为条件输入,并用后验正则化协调多源先验的相对权重;同时将雷达或MLAT与

气象对齐做一致性重构, 用一致性偏差作为辅助告警信号。评测时除 F_1 分数外, 增加物理违约率、程序违规率与跨域稳健性等作为评估指标。

4) 大模型部署。在 ADS-B 异常检测中, 可将通用大模型当作“时空语义引擎”, 通过指令化微调与检索增强, 让模型同时理解轨迹与气象等上下文, 在推理阶段输出“异常分数+不确定度”。为兼顾实时性与算力, 采用“云端教师-边缘学生”的蒸馏方案, 并配合低秩适配与整模量化, 在不牺牲识别能力的前提下降低延迟与资源占用; 对高风险或高不确定样本, 采用“边缘筛查-云端复核”的两级架构, 并结合密码学验签与独立定位偏差形成多证据决策。上线运维遵循影子运行与分批发布, 持续监测时延、吞吐、能耗与检出率漂移, 确保系统稳定演进。整体上, 这一方案在“可解释、可复核、可落地”的同时, 保持对复杂场景的鲁棒性与可维护性。

6　结 束 语

由于 ADS-B 系统的报文明文传输方式及物联网、5G 等新技术的迅猛发展, 导致 ADS-B 数据获取难度大幅下降。同时对 ADS-B 的攻击手段也由早期的显性注入与篡改行为逐渐演变为隐蔽性更强、结构更复杂的攻击。因此, 如何在复杂时空背景下实现对异常行为的准确识别, 成为保障空中交通安全的关键任务之一。本文对 ADS-B 异常数据的基本概念和检测流程进行了系统梳理, 详细分析了基于一致性检验的 ADS-B 异常检测方法和基于深度学习的 ADS-B 异常检测方法的研究现状, 探讨了不同异常检测方法在异常检测精度、泛化能力和实时性方面的优势与不足。对已投入应用的 ADS-B 异常检测产品进行归纳总结。针对当前 ADS-B 异常检测领域所面临的主要挑战, 提出未来研究方向, 为后续研究提供参考。

参考文献 (References)

[1] CCOM, DCOM. Nextgen-SESAR state of harmonisation[R/OL]. Luxembourg: Publications Office of the European Union, 2018. https://www.faa.gov/nextgen/nextgen-sesar-state-harmonisation.

[2] Çevik N, Akleylek S. SoK of machine learning and deep learning based anomaly detection methods for automatic dependent surveillance-broadcast[J]. IEEE Access, 2024, 12: 35643-35662.

[3] Strohmeier M, Lenders V, Martinovic I. On the security of the automatic dependent surveillance-broadcast protocol[J]. IEEE Communications Surveys & Tutorials, 2015, 17(2): 1066-1087.

[4] Wu Z J, Shang T, Guo A X. Security issues in automatic dependent surveillance-broadcast (ADS-B): a survey[J]. IEEE Access, 2020, 8: 122147-122167.

[5] Hicok D S, Lee D. Application of ADS-B for airport surface surveillance[C]//Proceedings of the 17th Digital Avionics Systems Conference. Piscataway: IEEE Press, 1998, 2: 3401-3408.

[6] Corrado S J, Puranik T G, Fischer O P, et al. A clustering-based quantitative analysis of the interdependent relationship between spatial and energy anomalies in ADS-B trajectory data[J]. Transportation Research Part C: Emerging Technologies, 2021, 131: 103331.

[7] Zhang J, Liu W, Zhu Y B. Study of ADS-B data evaluation[J]. Chinese Journal of Aeronautics, 2011, 24(4): 461-466.

[8] McCallie D, Butts J, Mills R. Security analysis of the ADS-B implementation in the next generation air transportation system[J]. International Journal of Critical Infrastructure Protection, 2011, 4(2): 78-87.

[9] Da Silva M, Puys M, Thevenon P H, et al. Automated ICS template for STRIDE microsoft threat modeling tool[C]//Proceedings of the 18th International Conference on Availability, Reliability and Security. New York: ACM, 2023: 1-7.

[10] Khan H A, Khan H, Ghafoor S, et al. A survey on security of automatic dependent surveillance-broadcast (ADS-B) protocol: challenges, potential solutions, and future directions[J]. IEEE Communications Surveys & Tutorials, 2025, 27(5): 3199-3226.

[11] Chiocchio S, Persia A, Santucci F, et al. Modeling and evaluation of enhanced reception techniques for ADS-B signals in high interference environments[J]. Physical Communication, 2020, 42: 101171.

[12] Zhang X L, Li J S. SR-GNN: spectral residuals with graph neural networks for anomaly detection in ADS-B data[C]//Proceedings of the International Conference on Frontiers in Cyber Security. Berlin: Springer, 2024: 503-516.

[13] Chevrot A, Vernotte A, Legeard B. CAE: contextual auto-encoder for multivariate time-series anomaly detection in air transportation[J]. Computers & Security, 2022, 116: 102652.

[14] Leonardi M, Sirbu G. ADS-B crowd-sensor network and two-step Kalman filter for GNSS and ADS-B cyber-attack detection[J]. Sensors, 2021, 21(15): 4992.

[15] Dong C, Zhang Y F, Jia Z Y, et al. Three-dimension collision-free trajectory planning of UAVs based on ADS-B information in low-altitude urban airspace[J]. Chinese Journal of Aeronautics, 2025, 38(2): 103170.

[16] Cretin A, Vernotte A, Chevrot A, et al. Test data generation for false data injection attack testing in air traffic surveillance[C]//Proceedings of the IEEE International Conference on Software Testing, Verification and Validation Workshops. Piscataway: IEEE Press, 2020: 143-152.

[17] Jheng S L, Jan S S, Chen Y H, et al. 1 090 MHz ADS-B-based wide area multilateration system for alternative positioning navigation and timing[J]. IEEE Sensors Journal, 2020, 20(16): 9490-9501.

[18] Wang J, Zou Y K, Ding J L. ADS-B spoofing attack detection method based on LSTM[J]. EURASIP Journal on Wireless Communications and Networking, 2020, 2020: 160.

[19] Leonardi M. ADS-B anomalies and intrusions detection by sensor clocks tracking[J]. IEEE Transactions on Aerospace and Electronic Systems, 2019, 55(5): 2370-2381.

[20] Jansen K, Niu L, Xue N, et al. Trust the crowd: wireless witnessing to detect attacks on ADS-B-based air-traffic surveillance[C]//Proceedings of the Network and Distributed System Security Symposium. [S.l.]: NDSS, 2021.

[21] 刘海涛, 刘家祥, 李冬霞, 等. 基于到达时间间隔差的 ADS-B 位

置消息验证方法[J]. 北京航空航天大学学报, 2024(9): 2696-2703.
Liu H T, Liu J X, Li D X, et al. Verification scheme of position message for automatic dependent surveillance-broadcast system based on interval difference of arrival[J]. Journal of Beijing University of Aeronautics and Astronautics, 2024(9): 2696-2703(in Chinese).

[22] Panda D K, Guo W S. Action robust reinforcement learning for air mobility deconfliction against conflict induced spoofing[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(12): 21343-21355.

[23] Wang E S, Song Y S, Xu S, et al. ADS-B anomaly data detection model based on deep learning and difference of Gaussian approach[J]. Transactions of Nanjing University of Aeronautics and Astronautics, 2020, 37(4): 550-561.

[24] Çevik N, Akleylek S. Anomaly detection system for ADS-B data: attack vectors and machine learning models[J]. Internet of Things, 2025, 29: 101416.

[25] Joseph N S, Banerjee C, Pasiliao E, et al. FlightSense: a spoofer detection and aircraft identification system using raw ADS-B data[C]// Proceedings of the IEEE International Conference on Big Data. Piscataway: IEEE Press, 2020: 3885-3894.

[26] Ying X H, Mazer J, Bernieri G, et al. Detecting ADS-B spoofing attacks using deep neural networks[C]//Proceedings of the IEEE Conference on Communications and Network Security. Piscataway: IEEE Press, 2019: 187-195.

[27] Strohmeier M, Schäfer M, Lenders V, et al. Realities and challenges of nextgen air traffic management: the case of ADS-B[J]. IEEE Communications Magazine, 2014, 52(5): 111-118.

[28] Fried A, Last M. Facing airborne attacks on ADS-B data with autoencoders[J]. Computers & Security, 2021, 109: 102405.

[29] Li T Y, Wang B H. Sequential collaborative detection strategy on ADS-B data attack[J]. International Journal of Critical Infrastructure Protection, 2019, 24: 78-99.

[30] Melvyn P, Couturier R, Ambert F, et al. Detecting ghost aircraft flooding in the surveillance of low-flying civil and military aircraft[C]//Proceedings of the 4th International Conference on Computer, Control and Robotics. Piscataway: IEEE Press, 2024: 328-332.

[31] Vajrobol V, Saxena G J, Singh S, et al. Enhancing aviation control security through ADS-B injection detection using ensemble meta-learning models with Explainable AI[J]. Alexandria Engineering Journal, 2025, 112: 63-73.

[32] Li T Y, Wang B H, Shang F T, et al. Dynamic temporal ADS-B data attack detection based on sHDP-HMM[J]. Computers & Security, 2020, 93: 101789.

[33] Jasra S K, Valentino G, Muscat A, et al. Hybrid machine learning-statistical method for anomaly detection in flight data[J]. Applied Sciences, 2022, 12(20): 10261.

[34] Li T Y, Wang B H, Shang F T, et al. Online sequential attack detection for ADS-B data based on hierarchical temporal memory[J]. Computers & Security, 2019, 87: 101599.

[35] Li T Y, Wang B H, Shang F T, et al. ADS-B data attack detection based on generative adversarial networks[C]//Proceedings of the 11th International Symposium on Cyberspace Safety and Security. Berlin: Springer, 2019: 323-336.

[36] Karam R, Salomon M, Couturier R. A comparative study of deep learning architectures for detection of anomalous ADS-B messages [C]//Proceedings of the 7th International Conference on Control, Decision and Information Technologies. Piscataway: IEEE Press, 2020: 241-246.

[37] Cao Y P, Cao J W, Zhou Z G, et al. Aircraft track anomaly detection based on MOD-Bi-LSTM[J]. Electronics, 2021, 10(9): 1007.

[38] Zha H R, Tian Q, Lin Y. Real-world ADS-B signal recognition based on radio frequency fingerprinting[C]//Proceedings of the IEEE 28th International Conference on Network Protocols. Piscataway: IEEE Press, 2020: 1-6.

[39] Zhang Z C, Li G Y, Shi J T, et al. Real-world aircraft recognition based on RF fingerprinting with few labeled ADS-B signals[J]. IEEE Transactions on Vehicular Technology, 2024, 73(2): 2866-2871.

[40] Zhong L F, Yang H, Zhang L, et al. Spoofing attack detection in ADS-B data through frequency enhanced patch attention mechanism[C]//Proceedings of the 6th International Conference on Electronic Engineering and Informatics. Piscataway: IEEE Press, 2024: 999-1003.

[41] Nicolussi A, Tanner S, Wattenhofer R. Aircraft fingerprinting using deep learning[C]//Proceedings of the 28th European Signal Processing Conference. Piscataway: IEEE Press, 2021: 740-744.

[42] Kacem T, Wijesekera D, Costa P. ADS-Bsec: a holistic framework to secure ADS-B[J]. IEEE Transactions on Intelligent Vehicles, 2018, 3(4): 511-521.

[43] Naganawa J, Tajima H, Miyazaki H, et al. ADS-B anti-spoofing performance of monopulse technique with sector antennas[C]//Proceedings of the IEEE Conference on Antenna Measurements & Applications. Piscataway: IEEE Press, 2017: 87-90.

[44] Shang F T, Wang B H, Yan F H, et al. Multidevice false data injection attack models of ADS-B multilateration systems[J/OL]. Security and Communication Networks, 2019. https://doi.org/10.1155/2019/8936784.

[45] Darabseh A, AlKhzaimi H, Pöpper C. MAVPro: ADS-B message verification for aviation security with minimal numbers of on-ground sensors[C]//Proceedings of the 13th ACM Conference on Security and Privacy in Wireless and Mobile Networks. New York: ACM, 2020: 53-64.

[46] Zhao D X, Sun J L, Gui G. En-route multilateration system based on ADS-B and TDOA/AOA for flight surveillance systems[C]// Proceedings of the IEEE 91st Vehicular Technology Conference. Piscataway: IEEE Press, 2020: 1-6.

[47] Chai Y E, Liu M Q, Zheng W X, et al. False signal identification of ADS-B assisted by UAV cooperative localization[J]. Chinese Journal of Aeronautics, 2025, 38(10): 103439.

[48] 王布宏, 罗鹏, 李腾耀, 等. 基于粒子群优化多核支持向量数据描述的广播式自动相关监视异常数据检测模型[J]. 电子与信息学报, 2020, 42(11): 2727-2734.
Wang B H, Luo P, Li T Y, et al. ADS-B anomalous data detection model based on PSO-MKSVDD[J]. Journal of Electronics & Information Technology, 2020, 42(11): 2727-2734(in Chinese).

[49] Lukeš P, Matejovie M. Detecting outlier positions in publicly available ADS-B data sets[C]//Proceedings of the New Trends in Civil Aviation. Piscataway: IEEE Press, 2024: 19-25.

[50] Li J H, Zhou Y Z. Automatic dependent surveillance-broadcast deceptive jamming detection method based on track data[J]. Journal of

Circuits, Systems and Computers, 2024, 33(12): 2450203.

[51] Khan H, Khan H, Ghafoor S. Securing ADS-B communications through a novel authentication framework[PP/OL]. TechRxiv (2023-08-29)[2025-08-01]. https://doi.org/10.36227/techrxiv.24043494.v1.

[52] Dabit A, Al-Fayoumi M, Mahmoud K. A secure regional authentication layer for global ADS-B communications[C]//Proceedings of the International Jordanian Cybersecurity Conference. Piscataway: IEEE Press, 2024: 99-104.

[53] Chen X, He D B, Peng C, et al. A secure and effective hierarchical identity-based signature scheme for ADS-B systems[J]. IEEE Transactions on Aerospace and Electronic Systems, 2024, 60(4): 5157-5168.

[54] Yao C, Zhang X J, Liu Y Z, et al. Blockchain-based secure and efficient ADS-B authentication via certificateless signature with packet loss tolerance[J]. IEEE Internet of Things Journal, 2025, 12(8): 10574-10588.

[55] Habler E, Shabtai A. Analyzing sequences of airspace states to detect anomalous traffic conditions[J]. IEEE Transactions on Aerospace and Electronic Systems, 2022, 58(3): 1843-1857.

[56] Ji Y F, Wang L W, Wu W L, et al. A method for LSTM-based trajectory modeling and abnormal trajectory detection[J]. IEEE Access, 2020, 8: 104063-104073.

[57] Yue M, Zheng H, Cui H R, et al. GAN-LSTM-based ADS-B attack detection in the context of air traffic control[J]. IEEE Internet of Things Journal, 2023, 10(14): 12651-12665.

[58] Cai K Q, Di Z, Zhu Y B, et al. An attention-based convolutional network framework for detection and localization of GNSS interference sources[J]. IEEE Transactions on Aerospace and Electronic Systems, 2024, 60(3): 2995-3011.

[59] Heiselberg P, Sørensen K A, Heiselberg H. Aircraft detection and state estimation[C]//Proceedings of the IEEE International Geoscience and Remote Sensing Symposium. Piscataway: IEEE Press, 2024: 7693-7696.

[60] Zheng Y F, Zhang X J, Tan Y H, et al. Transformer-based identification for ADS-B transmitters in open-time sets[J]. Chinese Journal of Aeronautics, 2025, 38(8): 103418.

[61] Li T T, Wen Z Y, Jin C D, et al. Meta-RFF: meta-task adaptive-based few-shot open-set incremental learning for RF fingerprint recognition[J]. IEEE Transactions on Cognitive Communications and Networking, 2026, 12: 2115-2130.

[62] Habler E, Shabtai A. Using LSTM encoder-decoder algorithm for detecting anomalous ADS-B messages[J]. Computers & Security, 2018, 78: 155-173.

[63] Luo P, Wang B H, Li T Y, et al. ADS-B anomaly data detection model based on VAE-SVDD[J]. Computers & Security, 2021, 104: 102213.

[64] 丁建立, 张琪琪, 王静, 等. 基于 Transformer-VAE 的 ADS-B 异常检测方法[J]. 系统工程与电子技术, 2023, 45(11): 3680-3689.
Ding J L, Zhang Q Q, Wang J, et al. ADS-B anomaly detection method based on Transformer-VAE[J]. Systems Engineering and Electronics, 2023, 45(11): 3680-3689(in Chinese).

[65] Luo P, Wang B H, Tian J W. TTSAD: TCN-Transformer-SVDD model for anomaly detection in air traffic ADS-B data[J]. Computers & Security, 2024, 141: 103840.

[66] Nasser H. Use of ADS-B for GNSS RFI monitoring[R]. [S.l.]: IDM, 2022.

[67] Liu J, Liu Y, Lin J Y, et al. Networking systems for video anomaly detection: a tutorial and survey[J]. ACM Computing Surveys, 2025, 57(10): 1-37.

[68] Luo P, Wang B H, Tian J W, et al. ADS-Bpois: poisoning attacks against deep-learning-based air traffic ADS-B unsupervised anomaly detection models[J]. IEEE Internet of Things Journal, 2024, 11(23): 38301-38311.

[69] Shang F T, Wang B H, Li T Y, et al. Adversarial examples on deep-learning-based ADS-B spoofing detection[J]. IEEE Wireless Communications Letters, 2020, 9(10): 1734-1737.

[70] Wang C, Wang Z D, Dong H L, et al. Fusionformer: a novel adversarial Transformer utilizing fusion attention for multivariate anomaly detection[J]. IEEE Transactions on Neural Networks and Learning Systems, 2025, 36(8): 14479-14492.

[71] Entezami A, Sarmadi H, Behkamal B, et al. Early warning of structural damage via manifold learning-aided data clustering and non-parametric probabilistic anomaly detection[J]. Mechanical Systems and Signal Processing, 2025, 224: 111984.

[72] Zhang H, Wang Z, Zeng D, et al. DiffusionAD: norm-guided one-step denoising diffusion for anomaly detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2025, 47(8): 7140-7152.

[73] Lin Y X, Chang Y, Tong X, et al. A survey on RGB, 3D, and multimodal approaches for unsupervised industrial image anomaly detection[J]. Information Fusion, 2025, 121: 103139.

[74] 王布宏, 罗鹏, 阳勇, 等. 空中交通管理系统网络安全研究综述与展望[J]. 电子与信息学报, 2025, 47(5): 1230-1265.
Wang B H, Luo P, Yang Y, et al. A review and prospect of cybersecurity research on air traffic management systems[J]. Journal of Electronics & Information Technology, 2025, 47(5): 1230-1265(in Chinese).

[75] He H Y, Zhang J N, Chen H X, et al. A diffusion-based framework for multi-class anomaly detection[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2024, 38(8): 8472-8480.

[76] Liu Q H, Paparrizos J. The elephant in the room: towards a reliable time-series anomaly detection benchmark[C]//Proceedings of the 38th International Conference on Neural Information Processing Systems. New York: ACM, 2024: 108231-108261.

Review of ADS-B anomaly detection research

YANG Hongyu[1, 2, *], ZHAO Ziwen[1], ZHU Youwen[3], HU Huiling[4], HU Juncheng[5]

(1. School of Safety Science and Engineering, Civil Aviation University of China, Tianjin 300300, China;
2. School of Computer Science and Artificial Intelligence, Civil Aviation University of China, Tianjin 300300, China;
3. College of Computer Science and Technology, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China;
4. Air Traffic Management Department, Central South Air Traffic Management Bureau CAAC, Guangzhou 510440, China;
5. College of Computer Science and Technology, Jilin University, Changchun 130012, China)

Abstract: The automatic dependent surveillance broadcast (ADS-B) system, as an important component of aviation surveillance technology, has been widely deployed and applied. The application of the ADS-B system significantly improves the coverage and positioning accuracy of air traffic surveillance. Nonetheless, owing to its open broadcast communication framework, this system is susceptible to numerous security risks including data manipulation, harmful message insertion, and interference assaults, which significantly compromise air traffic safety and control determinations. Anomaly detection for the ADS-B system has gradually become a research hotspot. This paper systematically summarizes and analyzes the current research status of anomaly detection in ADS-B systems at home and abroad. Firstly, it analyzes the causes of abnormal data in ADS-B systems and summarizes the types of attacks that this system is vulnerable to and their impacts. The present state of research on ADS-B anomaly detection is thoroughly examined from two perspectives: the consistency check-based approach and the deep learning-based approach. The merits and demerits of several techniques regarding detection precision, generalisation, and practical implementation are examined, with an analysis and summary of existing ADS-B anomaly detection products in relation to their respective application contexts. Ultimately, a comprehensive synthesis of the current research findings reveals the primary obstacles encountered by contemporary anomaly detection techniques for ADS-B, alongside potential future research avenues and developmental trajectories.

Keywords: automatic dependent surveillance broadcast; anomaly detection; air traffic surveillance; consistency check; deep learning

Received: 2025-08-26; **Accepted**: 2025-11-07; **Published Online**: 2025-11-20 12:16

URL: link.cnki.net/urlid/11.2625.V.20251119.1820.004

Foundation item: Key Project of the Civil Aviation Joint Research Fund of the National Natural Science Foundation of China (U2433205)

* **Corresponding author**. E-mail: yhyxlx@hotmail.com

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0426

改进轻量高效 EHH-YOLOv8s 的带钢表面缺陷检测算法

梁礼明*，龙鹏威，卢宝贺，欧燕燕，曾璐

(江西理工大学 电气工程与自动化学院，赣州 341000)

摘 要：针对当前钢材表面缺陷检测存在效率低和精度差等问题，以及现有缺陷检测模型参数量庞大、检测精度和实时性较差的挑战，提出一种基于 YOLOv8s 的轻量级钢材表面缺陷检测算法 EHH-YOLOv8s。采用轻量级的 EfficientViT 网络作为骨干网络，以降低模型复杂度并更好地处理跨尺度特征信息，从而提升检测性能；重构特征交互模块 H-C2f，有效保留空间和通道特征，抑制冗余信息，以提高检测精度和速度；采用 Haar 小波下采样 (HWD) 模块，以扩大感受野、降低模型复杂度、提升训练和检测速度。在 NEU-DET 和 Severstal 钢材缺陷数据集上进行实验验证，结果表明，相较于 YOLOv8s 算法，EHH-YOLOv8 算法的平均精度均值 (mAP) 分别提升 6.9% 和 5.4%，参数量和浮点运算量分别降低 4.1×10^6 和 13.2×10^9 次，检测速度分别达到 136 帧/s 和 118 帧/s，表明所提算法在检测精度、速度和轻量化方面取得了更好的平衡，为边缘终端设备提供高精度和实时性的可靠参考。在 PCB 板缺陷数据集上进行验证，结果显示，所提算法具备良好的泛化性能。

关 键 词：缺陷检测；轻量化 YOLOv8s；EfficientViT 网络；交换模块 H-C2f；Haar 小波下采样
中图分类号：TP391.4
文献标志码：A **文章编号**：1001-5965(2026)11-3699-13

钢材作为建筑行业中常见的材料之一，确保高质量的钢材生产对居民生命和财产安全至关重要。钢材表面缺陷检测算法可分为传统算法和基于深度学习的算法。传统算法存在耗时、费力等问题，导致误检率和漏检率较高，难以满足高效和高质量的生产需求。随着深度学习[1]技术的快速发展，基于图像的物体检测[2]算法在工业领域得到广泛应用[3]。然而，深度学习模型的训练和测试需要占用大量的计算资源，而终端设备的计算能力有限，这给钢材表面缺陷检测的实际应用带来一定困难和挑战[4]。因此，研究和应用轻量级、高效和准确的钢材表面缺陷检测技术具有重要的现实需求。

目前，基于深度学习的表面缺陷检测主流算法分为两阶段和单阶段的检测算法。两阶段目标检测算法具有较高的检测精度，但检测速度较低且模型参数量较大，不利于边缘终端设备部署，典型算法包括 R-CNN[5]、Fast R-CNN[6]、Faster R-CNN[7] 和 Mask R-CNN[8] 等。单阶段目标检测算法虽具备较快的检测速度，但检测精度不如两阶段目标检测算法，典型算法有 SSD[9] 和 YOLO[10-11] 系列等。然而，在钢材表面缺陷检测领域，因终端设备计算能力有限，过量的参数不利于模型在边缘终端设备上部署。因此，在实际应用场景中，缺陷检测的实时性也成为评估网络性能的重要指标。

为应对深度学习算法在终端设备上部署和实时性等挑战，一些研究者提出一系列轻量级带钢表面缺陷检测模型。例如，文献 [12] 基于 YOLOv5 构建了一种轻量级带钢表面缺陷检测模型 YOLOv5s-GCE，

收稿日期：2024-06-12；**录用日期**：2024-07-30；**网络出版时间**：2024-08-08 08:50
网络出版地址：link.cnki.net/urlid/11.2625.V.20240807.1403.003
基金项目：国家自然科学基金 (51365017,61463018)；江西省自然科学基金面上项目 (20192BAB205084)；江西省教育厅科学技术研究重点项目 (GJJ170491,GJJ2200848)；江西省研究生创新专项资金 (YC2022-S676)
* **通信作者**. E-mail：9119890012@jxust.edu.cn

引用格式：*梁礼明，龙鹏威，卢宝贺，等. 改进轻量高效 EHH-YOLOv8s 的带钢表面缺陷检测算法 [J]. 北京航空航天大学学报，2026，52（11）：3699-3711. Liang L M，Long P W，Lu B H，et al. Improved lightweight and efficient EHH-YOLOv8s algorithm for strip steel surface defect detection [J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：3699-3711 （in Chinese）.*

该模型引入 GhostConv 卷积和坐标注意力机制，以减少参数量，实现轻量化目的，但在小目标检测方面表现较为不足。文献 [13] 采用 EfficientNet 网络作为骨干特征提取网络，设计 EDDNet 模型，有效减少计算开销。文献 [14] 使用 MobilenetV2 模块和卷积块注意力模块 (convolutional block attention module, CBAM) 构建 CBAM-MobilenetV2-YOLOv5 模型，实现 YOLOv5 模型轻量化。文献 [15] 基于 YOLOv5 算法构造 SPP_Res 特征金字塔结构，同时加入多头注意力机制，有效提升检测精度，但该算法对部分小尺度目标 (如裂缝类) 检测效果较差。文献 [16] 通过使用轻量化 ShuffleNetv2 作为 YOLOv5 模型的骨干网络，有效压缩模型体积并提升检测速度。文献 [17] 将 MobileNet 引入 Mask R-CNN 目标检测框架，作为骨干特征提取网络，成功降低模型参数量和计算量。文献 [18] 在 YOLOv7 算法基础上，通过 SPPCSPC_Group 对空间金字塔池化模块进行分组，设计出轻量级 YOLOv7 模型。上述研究对参数量庞大的目标检测算法具有启发意义。但轻量化操作虽有利于减少模型体积，却会降低网络的非线性建模能力，导致模型精度损失。因此，尽管上述文献在缺陷检测领域取得一定进展，但依然无法较好地平衡检测精度、速度和轻量级问题。

鉴于上述研究存在的局限性，本文在 YOLOv8s 算法的基础上，提出一种轻量级高效的钢材表面缺陷检测算法 EHH-YOLOv8s (EfficientViT+H-C2f+HWD，简称 EHH)，并实现对缺陷目标较高精度和速度的检测。主要研究工作如下：

1）采用轻量级的 EfficientViT 作为骨干特征提取网络，融入高效的多尺度注意力 (multi-scale attention, MSA) 机制，高效处理跨尺度信息，且显著压缩模型体积，加快模型检测速度。

2）设计轻量级特征交互模块 H-C2f，旨在优化模型参数量，充分融合空间和通道的语义信息，提高检测精度和速度。

3）使用 Haar 小波下采样 (Haar wavelet down-sampling, HWD) 模块作为整体网络的下采样操作，扩大模型感受野，同时压缩模型体积，提升模型性能。

4）在 NEU-DET 数据集上进行实验，验证本文算法的优越性。相较于主流算法，本文算法具备更低的计算资源、更快的检测速度和更高的检测精度。在 Severstal 数据集上的实验结果显示，EHH-YOLOv8 算法具有良好的鲁棒性。此外，在 PCB 数据集上的验证进一步展示了本文算法的泛化性能。

1 YOLOv8s 模型

YOLOv8 是 Ultralyticsgongs 团队开源的网络，集成检测、分割和实时追踪等任务。相较于现有 YOLO 系列算法，其最大的改进在于采用中心检测算法的无锚框检测方式，通过解耦头结构将分类与回归分离，减少了因锚框数量和选择尺寸而导致的干扰，并使用解耦头作为最终检测头，有效提升网络性能。此外，将 C3 模块换成梯度流丰富且轻量的 C2f 模块，该模块综合了 C3 模块和 YOLOv7 中 ELAN 的优点。YOLOv8 提供了 5 种不同尺寸的模型，为平衡检测精度和速度，本文选用 YOLOv8s 作为钢材表面缺陷检测的基线模型。该网络结构包括输入端、骨干网络、特征融合网络和预测网络 4 部分，分别用于特征输入、特征提取、特征融合和预测输出。YOLOv8s 网络结构如图 1 所示。

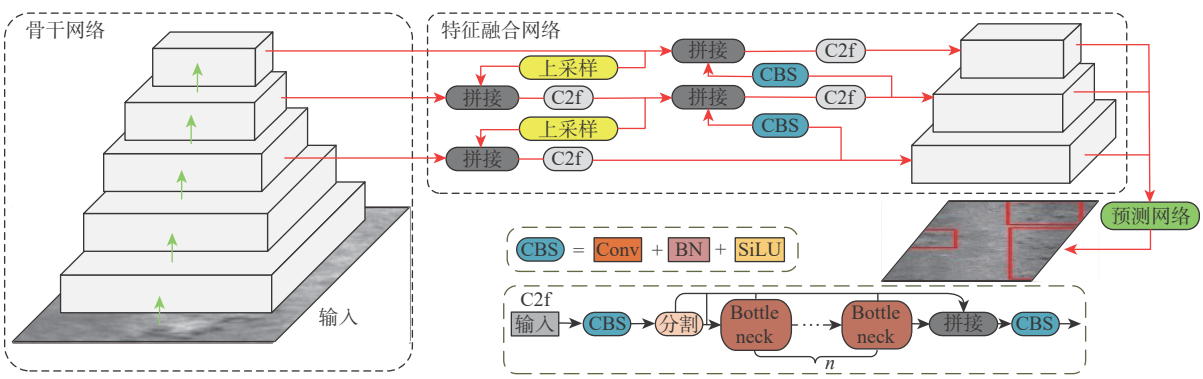


图 1 YOLOv8s 网络结构

Fig. 1 YOLOv8s network structure

2 本文模型

2.1 EHH-YOLOv8s 模型

针对现有钢材表面缺陷检测精度和效率低、通用算法参数量大等问题，本文提出一种轻量级的 EHH-YOLOv8s 检测模型，用于快速准确地检测钢材表面形态多样、结构复杂的缺陷。首先，将轻量级的 EfficientViT 网络替代原 YOLOv8s 的骨干网

络, 在维持较高精度的同时有效压缩模型体积。其次, 重新设计特征交互模块 H-C2f 取代原特征融合网络中的 C2f 模块, 抑制空间和通道维度上的冗余信息, 提升网络检测精度。最后, 将原网络颈部的下采样操作替换为 HWD 模块, 扩大感受野, 充分保留特征图细粒度信息, 提升模型的检测性能。EHH-YOLOv8s 网络结构如图 2 所示, 改进部分用红框标注。图中: SPPF 表示快速空间金字塔池化。

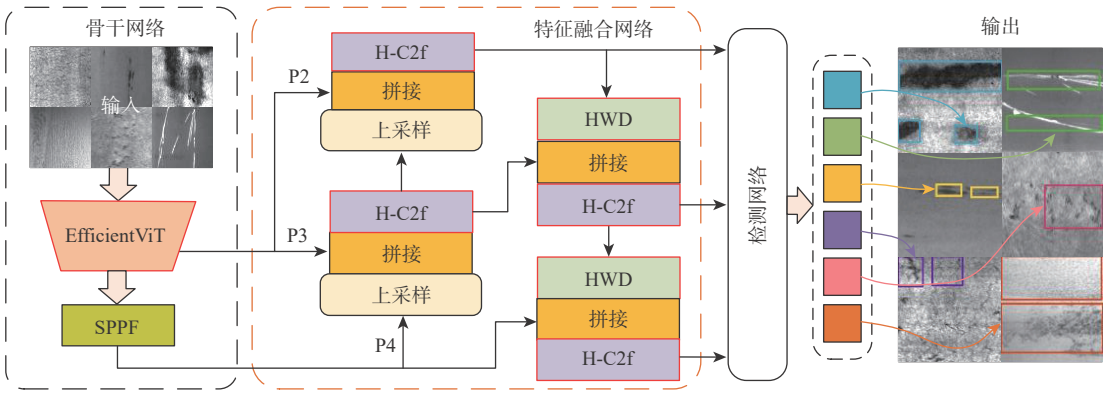


图 2　EHH-YOLOv8s 网络结构

Fig. 2　EHH-YOLOv8s network structure

2.2　EfficientViT 骨干网络

YOLOv8 的骨干网络由一系列卷积层和残差模块堆叠而成, 导致模型体积过大, 限制训练和推理速度, 不适合边缘设备部署; 且传统的骨干网络结构在处理跨尺度信息方面存在局限性, 难以准确捕捉钢材表面缺陷的全局特征。为解决上述问题, Cai 等[19]提出一种 EfficientViT 网络, 其结构如图 3 所示。图中: MBConv 表示倒置瓶颈卷积模块, GConv 表示分组卷积, DSConv 表示完整深度可分离卷积, FPN 表示特征金字塔网络。该网络采用轻量化设计, 减少网络的参数量和计算量, 使模型更易于部署在移动设备或资源受限的环境中。此外, EfficientViT 网络结合轻量级 MSA 机制, 有助于处理钢材表面缺陷的跨尺度信息, 提升模型的检测准确性。

MSA 摒弃复杂的 Softmax 注意力, 首先, 采用 ReLU 线性注意力对全局感受野进行操作。假设给定输入特征 $\boldsymbol{x}\in\mathbf{R}$, Softmax 注意力的广义形式在数学可表示为

$$\boldsymbol{Q}_i=\sum_{j=1}^{N}\frac{\mathrm{Sim}(\boldsymbol{Q}_i,\boldsymbol{K}_i)}{\sum_{j=1}^{N}\mathrm{Sim}(\boldsymbol{Q}_i,\boldsymbol{K}_i)}\boldsymbol{V}_j \tag{1}$$

式中: $\mathrm{Sim}(\boldsymbol{Q},\boldsymbol{K})=\mathrm{ReLU}(\boldsymbol{Q})\cdot\mathrm{ReLU}(\boldsymbol{K})^{\mathrm{T}}$ 为 ReLU 线性注意力的相似性函数; $\boldsymbol{Q}=\boldsymbol{x}\boldsymbol{W}_{\boldsymbol{Q}},\boldsymbol{K}=\boldsymbol{x}\boldsymbol{W}_{\boldsymbol{K}},\boldsymbol{V}=\boldsymbol{x}\boldsymbol{W}_{\boldsymbol{V}}$, 且 $\boldsymbol{W}_{\boldsymbol{Q}},\boldsymbol{W}_{\boldsymbol{K}},\boldsymbol{W}_{\boldsymbol{V}}\in\mathbf{R}$ 为线性投影矩阵; $\boldsymbol{Q}_i$ 表示矩阵 $\boldsymbol{Q}$ 的第 i 行。

然后, 利用矩阵乘法的结合性, 成功将计算复杂度和内存占用从二次降到线性, 同时保持其性能

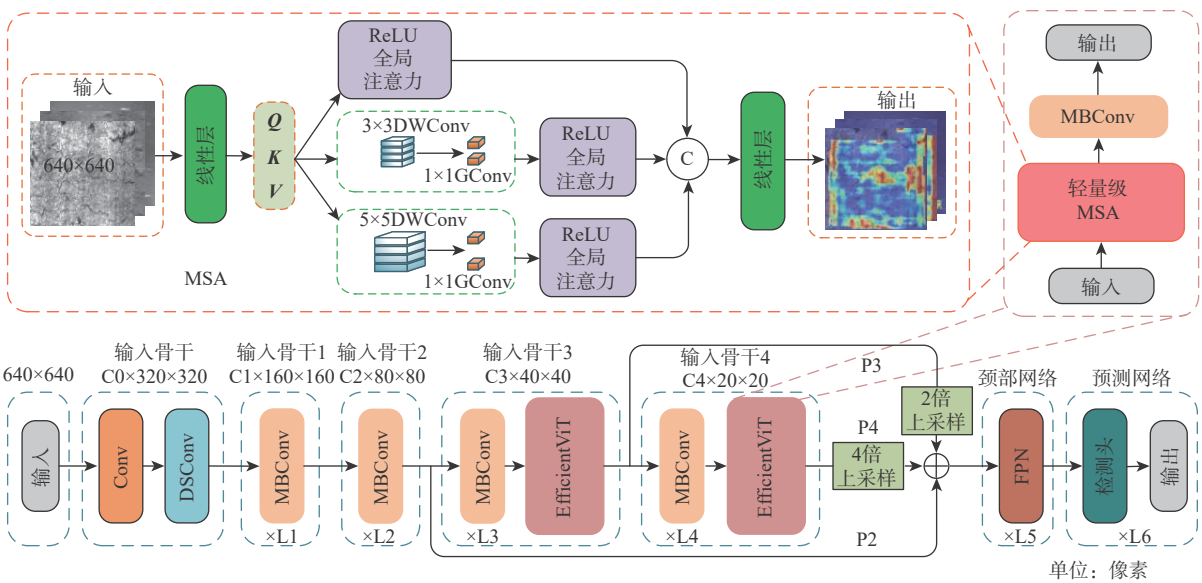


图 3　EfficientViT 宏观网络结构

Fig. 3　EfficientViT macro network structure

不受影响。最后，ReLU线性注意力的计算表达式在数学上可表示为

$$\boldsymbol{O}_i=\frac{\mathrm{ReLU}(\boldsymbol{Q}_i)\left[\sum_{j=1}^{N}\mathrm{ReLU}(\boldsymbol{K}_j)^{\mathrm{T}}\boldsymbol{V}_j\right]}{\mathrm{ReLU}(\boldsymbol{Q}_i)\sum_{j=1}^{N}\mathrm{ReLU}(\boldsymbol{K}_j)^{\mathrm{T}}} \tag{2}$$

可知，ReLU只需计算一次$\sum_{j=1}^{N}\mathrm{ReLU}(\boldsymbol{K}_j)^{\mathrm{T}}$和$\sum_{j=1}^{N}\left[\mathrm{ReLU}(\boldsymbol{K}_j)^{\mathrm{T}}\boldsymbol{V}_j\right]$，在每个查询中可对其重复使用，该过程只需消耗$\boldsymbol{O}(N)$的计算成本和内存，无需涉及Softmax，避免了硬件效率低和延时等问题。

为了在GPU上高效执行上述操作，MSA先将所有的深度可分离卷积(DWConv)融合为单个DWConv，并采用组卷积范式，再通过全局注意力操作提取多尺度的全局特征，最终将来自不同尺度的特征沿头部维度连接，输入线性投影层进行融合。

EfficientViT宏观网络主要由输入骨干和4个阶段组成，采用MSA和MBConv模块进行设计。信息传递过程中，特征图逐渐减小，通道数逐渐增加。其中，MSA模块用于捕获上下文信息，MBConv模块的步长为2，用于捕获本地信息和下采样操作。此外，该网络共设计了6种大小不同版本的模型(V0～V5)，以满足各种效率约束。

2.3 H-C2f模块

C2f是一种通道压缩和特征融合模块。语义信息经C2f模块后，因通道压缩易导致信息丢失，降低模型在复杂场景下的检测性能。此外，C2f模块采用深层网络结构，导致计算复杂度较高，影响模型的运行效率和速度。Li等[20]提出混合注意力模块(hybrid attention module, HAM)，将通道注意力模块(channel attention module, CAM)和空间注意力模块(spatial attention module, SAM)进行融合，有效提升模型对关键特征的提取能力，且该模块采用快速一维卷积实现跨通道的信息交互，保证信息传递过程不受通道降维影响，同时降低模型的复杂度。本文受此启发，将C2f模块与HAM模块进行融合，设计了H-C2f模块。HAM和H-C2f模块网络结构如图4所示。

假设输入特征为$\boldsymbol{F}\in\mathbf{R}^{H\times W\times C}$，HAM模块首先导出一维通道注意张量$\boldsymbol{A}_{\mathrm{C}}$，并与原始输入张量相乘得到通道细化特征$\boldsymbol{F}'$。其次，SAM模块沿通道轴线将$\boldsymbol{F}'$分为$\boldsymbol{F}'_1$和$\boldsymbol{F}'_2$ 2组，并分别产生二维空间注意力张量$\boldsymbol{A}_{\mathrm{S1}}$和$\boldsymbol{A}_{\mathrm{S2}}$。然后，与$\boldsymbol{F}'_1$和$\boldsymbol{F}'_2$相乘得到一对空间细化特征$\boldsymbol{F}''_1$和$\boldsymbol{F}''_2$。最后，将两者相加得到最终的细化特征$\boldsymbol{F}''$。上述过程在数学上可分别表示为

$$\begin{cases}\boldsymbol{F}'=\boldsymbol{A}_{\mathrm{C}}(\boldsymbol{F})\otimes\boldsymbol{F}\\ \boldsymbol{F}'=\boldsymbol{F}'_1\oplus\boldsymbol{F}'_2\\ \boldsymbol{F}''_1=\boldsymbol{A}_{\mathrm{S1}}(\boldsymbol{F}'_1)\otimes\boldsymbol{F}'_1\\ \boldsymbol{F}''_2=\boldsymbol{A}_{\mathrm{S2}}(\boldsymbol{F}'_2)\otimes\boldsymbol{F}'_2\\ \boldsymbol{F}''=\boldsymbol{F}''_1\oplus\boldsymbol{F}''_2\end{cases} \tag{3}$$

式中：⊗和⊕分别表示元素的乘法和加法。

CAM网络结构如图5所示。首先，通过平均池化和最大池化操作对空间维度信息进行聚合，生成平均池化特征$\boldsymbol{F}_{\mathrm{C}}^{\mathrm{avg}}$和最大池化特征$\boldsymbol{F}_{\mathrm{C}}^{\max}$。然后，通过自适应机制模块，将$\boldsymbol{F}_{\mathrm{C}}^{\mathrm{avg}}$和$\boldsymbol{F}_{\mathrm{C}}^{\max}$分别与可训练参数$\alpha$和$\beta$相乘，得到信息提取特征$\boldsymbol{F}_{\mathrm{C}}^{\mathrm{add}}$。该特征不仅保留了原始信息，且通过自适应调整特征倾向，使特征更加丰富。CAM模块采用快速一维卷积对跨通道的交互信息进行处理，降低模型复杂度，并避免通道降维对性能的影响。假设一维卷积的核大小为k，大小由通道数C决定，其计算式可表示为

$$k=\phi(C)=\left|\frac{\log_2 C}{\gamma}+\frac{b}{\gamma}\right|_{\mathrm{odd}} \tag{4}$$

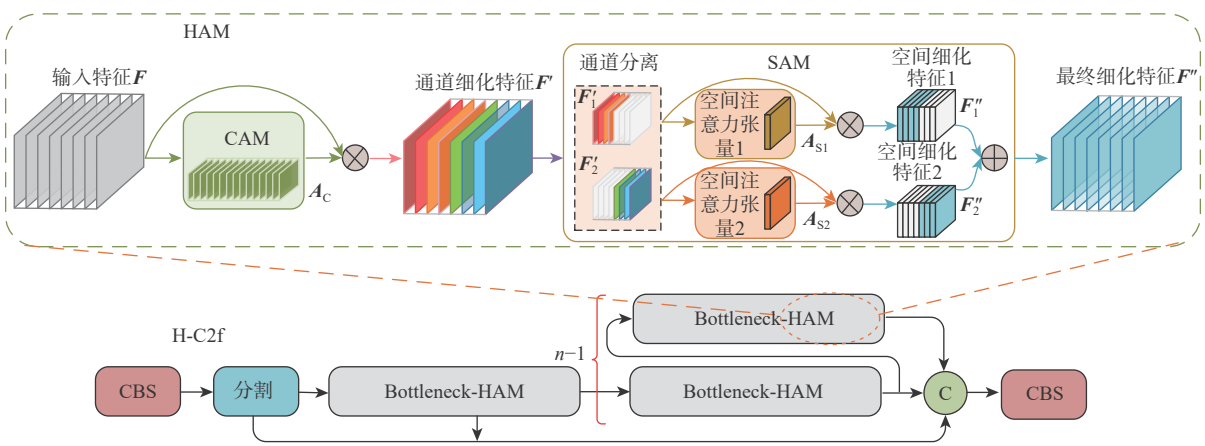


图4 HAM和H-C2f网络结构

Fig. 4 HAM and H-C2f network structure

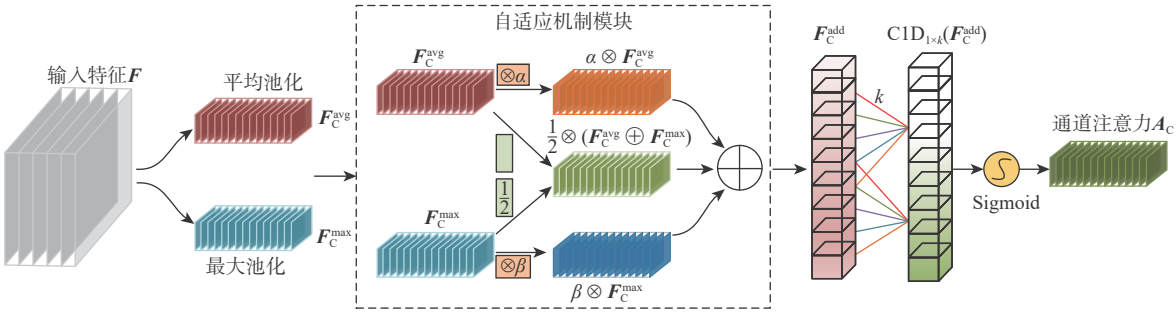


图 5　CAM 网络结构

Fig. 5　CAM network structure

式中: $|t|_{\text{odd}}$表示t最接近的奇数; γ和b为超参数。

最后, 特征信息$\boldsymbol{F}_{\text{C}}^{\text{add}}$经过一维卷积后, 采用 Sigmoid 函数激活输出特征张量$\boldsymbol{A}_{\text{C}}$, 得到通道细化特征$\boldsymbol{F}'$, 并将其作为 SAM 模块的输入。

上述过程在数学上可分别表示为

$$\begin{cases} \boldsymbol{F}_{\text{am}} = \boldsymbol{F}_{\text{C}}^{\text{avg}} \oplus \boldsymbol{F}_{\text{C}}^{\text{max}} \\ \boldsymbol{F}_{\alpha\beta} = \alpha \otimes \boldsymbol{F}_{\text{C}}^{\text{avg}} \oplus \beta \otimes \boldsymbol{F}_{\text{C}}^{\text{max}} \\ \boldsymbol{F}_{\text{C}}^{\text{add}} = \dfrac{1}{2} \otimes \boldsymbol{F}_{\text{am}} \oplus \boldsymbol{F}_{\alpha\beta} \end{cases} \tag{5}$$

$$\boldsymbol{A}_{\text{C}} = \sigma(\text{C1D}_{1\times k}(\boldsymbol{F}_{\text{C}}^{\text{add}})) \tag{6}$$

式中: α和β为大于 0 且小于 1 的浮动实数; σ表示 Sigmoid 函数; $\text{C1D}_{1\times k}$表示核大小为k的一维卷积。

SAM 网络结构如图 6 所示。首先, 对通道细化特征$\boldsymbol{F}'$进行通道分离, 得到$\boldsymbol{F}_1'$和$\boldsymbol{F}_2'$。其次, 采用平均池化和最大池化操作对其进行聚合, 得到 2 对二维特征$\boldsymbol{F}_{\text{S1}}^{\text{max}}$和$\boldsymbol{F}_{\text{S1}}^{\text{avg}}$及$\boldsymbol{F}_{\text{S2}}^{\text{max}}$和$\boldsymbol{F}_{\text{S2}}^{\text{avg}}$, 并将 2 对特征输出进行连接, 生成一对特征描述符。然后, 经过 7×7 的共享卷积层, 得到一对二维注意力图。最后, 通过归一化和激活函数操作, 生成空间注意力特征$\boldsymbol{A}_{\text{S1}}$和$\boldsymbol{A}_{\text{S2}}$。

上述过程在数学上可分别表示为

$$\begin{aligned} \boldsymbol{A}_{\text{S1}}(\boldsymbol{F}') &= \Phi(\text{C2D}_{7\times7}([\text{AvgPool}(\boldsymbol{F}_1');\text{MaxPool}(\boldsymbol{F}_1')])) = \\ &\Phi(\text{C2D}_{7\times7}([\boldsymbol{F}_{\text{S1}}^{\text{avg}};\boldsymbol{F}_{\text{S1}}^{\text{max}}])) \end{aligned} \tag{7}$$

$$\begin{aligned} \boldsymbol{A}_{\text{S2}}(\boldsymbol{F}') &= \Phi(\text{C2D}_{7\times7}([\text{AvgPool}(\boldsymbol{F}_2');\text{MaxPool}(\boldsymbol{F}_2')])) = \\ &\Phi(\text{C2D}_{7\times7}([\boldsymbol{F}_{\text{S2}}^{\text{avg}};\boldsymbol{F}_{\text{S2}}^{\text{max}}])) \end{aligned} \tag{8}$$

式中: Φ表示一系列非线性操作, 依次为批归一化、ReLU 函数和 Sigmoid 函数; $\text{C2D}_{7\times7}$表示 7×7 的共享卷积。

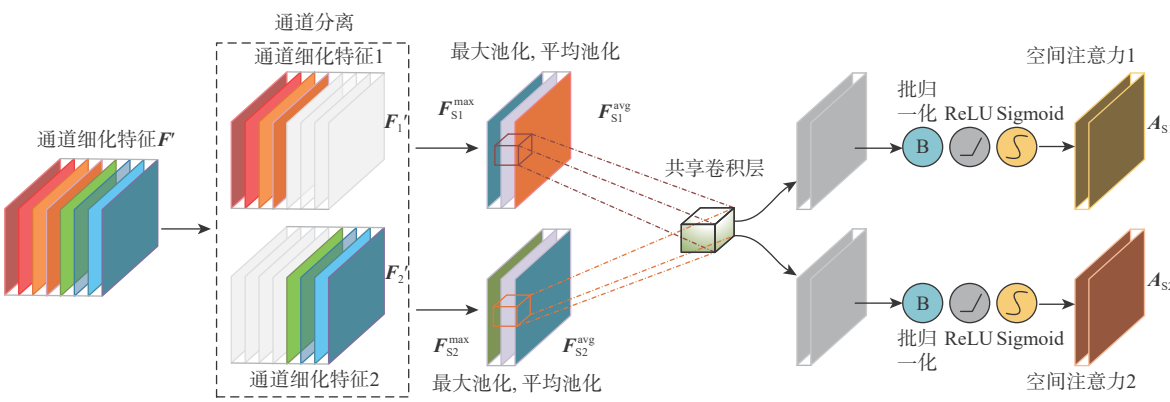


图 6　SAM 网络结构

Fig. 6　SAM network structure

2.4　HWD 模块

YOLOv8s 的下采样采用步长为 2 的卷积操作, 但该过程会使特征图尺寸迅速减小, 丢失细节信息, 导致感受野不足, 从而降低模型对细小缺陷或局部特征的识别准确性。Xu 等[21]提出 HWD 模型, 其网络结构如图 7 所示。HWD 利用 Haar 小波变换进行下采样操作, 充分保留图像细节的同时增加特征图的感受野, 使模型能更好地理解和捕捉图像整体特征, 提高检测准确性。此外, 相比于跨步卷积, HWD 设计简单高效, 能有效减少计算开销, 提升训练速度, 并提高检测精度。本文受此启发, 将 YOLOv8s 中步长为 2 的卷积替换为 HWD 模块, 以充分改善模型的检测性能。

HWD 模块主要包括无损特征编码块和特征学习块。其中, 无损特征编码块利用 Haar 小波变换对特征图进行转换和降低空间分辨率。首先, 将分

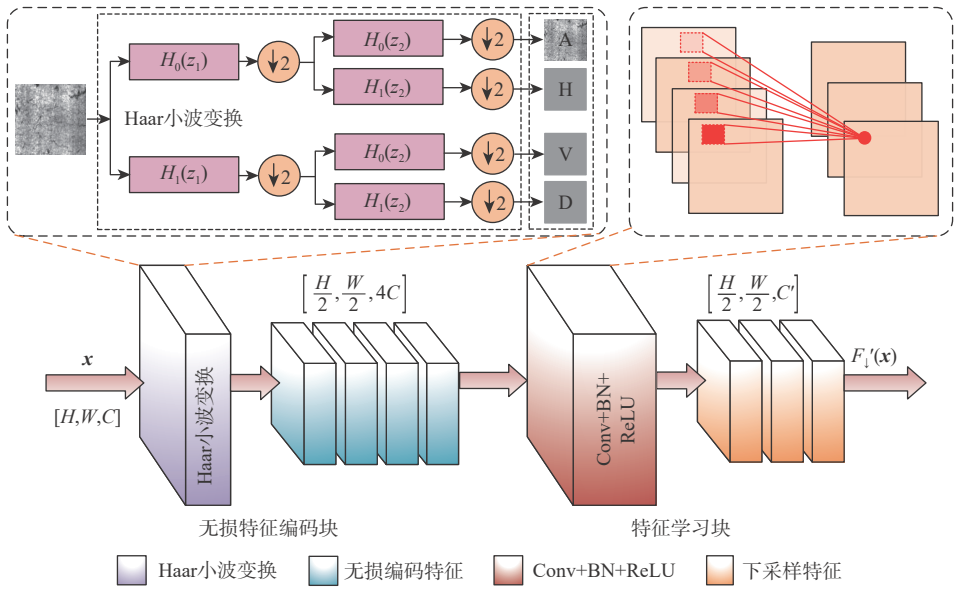


图 7 HWD 网络结构

Fig. 7 HWD network structure

辨率为 $H\times W$ 的图像进行分解，并利用高通(H_0)和低通(H_1)分解滤波器进行近似信息和高频信息的提取。然后，通过近似和细节分量的下采样操作(↓2)生成水平(H)、垂直(V)和对角线(D)方向上的近似低频(A)和细节高频分量，从而有效保留细节特征信息。Haar 小波变换的基函数和尺度函数在数学上可表示为

$$\begin{cases}\phi_1(x')=\dfrac{1}{\sqrt{2}}\phi_{1,0}(x')+\dfrac{1}{\sqrt{2}}\phi_{1,1}(x')\\ \psi_1(x')=\dfrac{1}{\sqrt{2}}\phi_{1,0}(x')+\dfrac{1}{\sqrt{2}}\phi_{1,1}(x')\end{cases} \tag{9}$$

$$\phi_{1,k}(x')=\sqrt{2^j}\phi(2^jx'-k)\qquad k=0,1,\cdots,2^j-1 \tag{10}$$

式中：j和k为基函数的阶。

特征学习块由卷积层、批归一化层和 ReLU 激活层组成，用于调整特征映射的通道数，并尽可能过滤掉冗余信息，使后续层更高效地学习代表性特征。

假设特征图和下采样特征图的输入大小分别为$H\times W\times C$和$H/2\times W/2\times C$，则 HWD 模块与传统跨步卷积的参数量和计算复杂度在数学上可分别表示为

$$\begin{cases}P_{\mathrm{H}}=4C^2\\ F_{\mathrm{H}}=2HWC^2+3.75HWC\end{cases} \tag{11}$$

$$\begin{cases}P_{\mathrm{C}}=9C^2\\ F_{\mathrm{C}}=4.5HWC^2-0.25HWC\end{cases} \tag{12}$$

式中：P_{H}、P_{C}和F_{H}、F_{C}分别为参数量和计算复杂度。

由式(11)和式(12)可知，跨步卷积的参数量接近 HWD 模块的2倍，而当$C>1$时，其计算开销也高于 HWD 模块。综上，HWD 模块不仅输出更丰富的细节特征映射信息，而且在参数量和计算量之间取得了较好的平衡。

3 实验结果及分析

3.1 数据集

本文实验数据集来源于东北大学 NEU-DET[16] 钢材缺陷数据集和 Kaggle 钢铁缺陷比赛数据集，后者由 Severstal 公司提供。2 个数据集分别包含 1 800 张和 1 120 张图像，涵盖市面上常见的裂缝、夹杂物、斑块、点蚀表面、氧化皮和划痕等 6 种缺陷类型。为增强模型的泛化性能和鲁棒性，减少过拟合的影响，对 Severstal 数据集进行数据增强，包括水平翻转、垂直翻转和水平垂直翻转，扩充比例为 1∶3。图 8 展示了原图和增强后的图像示例，对于训练集、验证集和测试集，2 个数据集均采用 6∶2∶2 的比例进行随机划分。

3.2 实验环境与参数设置

实验操作系统为 Windows11，采用 Pytorch1.11.0 作为深度学习框架，CPU 为 Intel Core i7-12700H，GPU 为 RTX4060，显卡为 8 GB。在训练阶段，采用 Adam 作为优化器，初始学习率为 0.01，动量为 0.973，衰减系数为 0.000 5。输入图像尺寸为 640 像素×640 像素，batch size 大小为 16，epoch 为 300 轮。

3.3 评价指标

实验采用平均精度均值(mean average precision, mAP)、参数量、浮点运算量和检测速度 4 个指标对网络性能进行评估。mAP 表示所有类别的检测准确率的均值，由精确度 P、召回率 R 和平均精度(average precision, AP)计算所得。上述指标的定义式分别为

$$A_{\mathrm{P}}=\int_0^1 P\mathrm{d}R \tag{13}$$

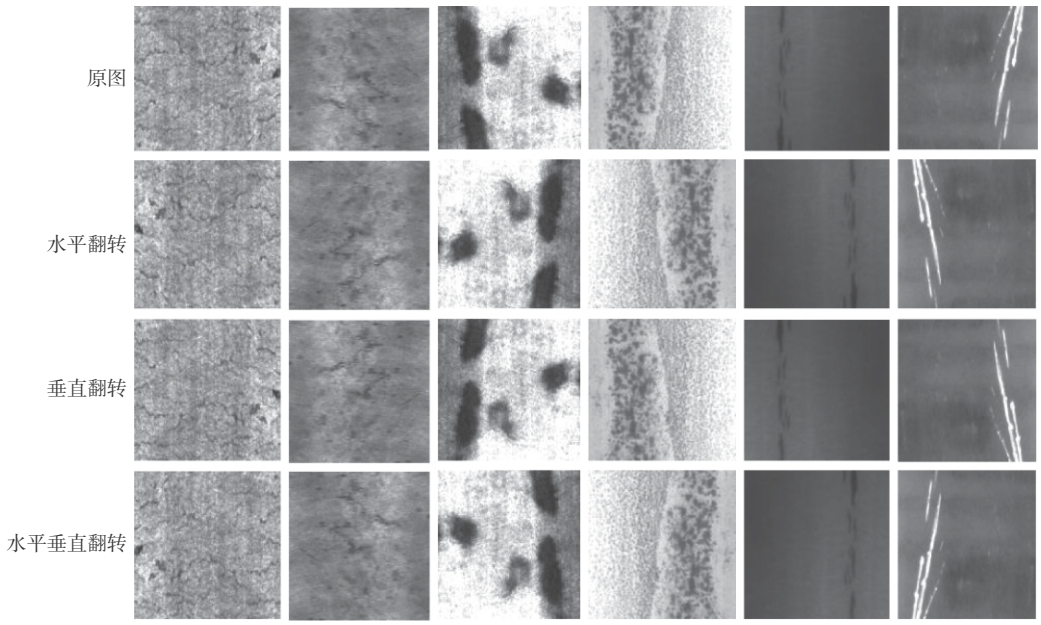


图 8　数据增强前后各图像示例

Fig. 8　Examples of each image before and after data enhancement

$$A_{\mathrm{mP}}=\frac{\sum_{i=1}^{N}A_{\mathrm{P}i}}{N} \tag{14}$$

$$P=\frac{N_{\mathrm{TP}}}{N_{\mathrm{TP}}+N_{\mathrm{FP}}} \tag{15}$$

$$R=\frac{N_{\mathrm{TP}}}{N_{\mathrm{TP}}+N_{\mathrm{FN}}} \tag{16}$$

$$F_{\mathrm{PS}}=\frac{N_{\mathrm{frame}}}{T_{\mathrm{elapsed}}} \tag{17}$$

式中: A_{P} 表示 *P-R* 曲线与坐标轴围成的面积; N 为待检测目标的类别数; N_{TP}、N_{FP} 和 N_{FN} 分别为正确检测的真阳性、误报阳性和漏报阳性的数量; N_{frame} 为检测图像总数; T_{elapsed} 为检测所需总时间。

3.4　改进模块实验

3.4.1　EfficientViT 网络实验

在 NEU-DET 数据集上, 对 EfficientViT 网络的 6 个版本 (V0～V5) 进行实验, 验证对指标提升效果最佳的版本, 实验结果如表 1 所示。

从表 1 结果可知, 随着 EfficientViT 网络版本从 V0 到 V5 逐步增加, 参数量和计算复杂度逐渐增加, 对 GPU 的性能要求也更高。选择 V0 版本时, 整体网络的参数量和计算开销相较于基线模型分别降低 2.8×10^6 和 4.9×10^9 次, 同时, mAP 和检测速度达到最优, 分别为 76.5% 和 126 帧/s, 优于其他版本。其中, EfficientViT-V0 是最基础的版本, 模型参数量和计算量较小, 适合在资源受限的环境提高模型的效率和速度。相较于其他版本, EfficientViT-V0 更适合捕捉和定位钢材缺陷的小尺度场景, 故而提升效果更为显著。

表 1　EfficientViT 网络不同版本实验结果

Table 1　Experimental results of different versions of EfficientViT network

模型	mAP%	参数量	浮点运算量/10^9次	检测速度/(帧·s^{-1})
基线模型	72.8	11.1×10^6	28.8	109
V0	76.5	8.3×10^6	23.9	126
V1	75.0	9.0×10^6	25.2	113
V2	75.2	10.2×10^6	26.9	101
V3	76.2	13.0×10^6	32.8	80
V4	75.3	14.9×10^6	37.7	75
V5	72.4	18.6×10^6	42.5	67

3.4.2　H-C2f 模块实验

为验证 HAM 与 C2f 模块融合的有效性, 在 NEU-DET 数据集上, 将其与 SE、CBAM、Shuffle-Attention、CA、SimAM 注意力机制与 C2f 模块融合后的效果进行对比, 实验结果如表 2 所示。

从表 2 结果可知, 将上述注意力与 C2f 模块融合后, mAP 值相比基线模型均得到一定程度的提升。选择 HAM 模块与 C2f 模块融合后, 对网络的整体贡献能力最佳, 检测精度和速度均达到最优水平。相较于基线模型, 参数量和计算复杂分别减少 0.9×10^6 和 2.2×10^9 次, 优于其余注意力机制。HAM 模块采用一维快速卷积实现跨通道信息交互, 有效提升模型对关键特征的提取能力, 同时大幅降低模型的复杂度。综上所述, 本文设计的 H-C2f 模块具备较高的优越性。

3.5　消融实验

以 YOLOv8s 为基线模型, 对其围绕 3 个方面

表2 H-C2f模块实验结果

Table 2 Experimental results of H-C2f module

模型	mAP%	参数量	浮点运算量/10^9次	检测速度/(帧·s^{-1})
基线模型	72.8	11.1×10^6	28.8	109
H-C2f	75.7	10.2×10^6	26.6	116
C2f+SE	75.3	19.8×10^6	46.2	90
C2f+CBAM	75.2	11.2×10^6	28.5	105
C2f+Shuffle-Attention	75.6	11.1×10^6	28.4	108
C2f+CA	74.3	11.1×10^6	28.5	113
C2f+SimAM	73.6	11.1×10^6	28.4	109

进行改进，设计了轻量高效的EHH-YOLOv8s模型，为验证每项改进的有效性，本文在NEU-DET和Severstal数据集上进行5组消融实验。其中，M1表示将原骨干网络替换为EfficientViT-V0网络，M2表示将颈部的C2f模块替换为H-C2f模块，M3表示将颈部下采样操作替换为HWD模块。实验结果如表3所示。

从表3结果可知，在NEU-DET和Severstal数据集上，首先，将骨干网络替换为轻量级的EfficientViT网络，mAP值分别提升3.7%和3.3%，参数量和计算复杂度相应减少2.8×10^6和4.9×10^9次，检测速度分别提升17帧/s和5帧/s。表明轻量级的EfficientViT-V0网络能够减少冗余信息，优化模型参数量和计算复杂度，并提升检测速度。EfficientViT网络采用MSA机制，更好地处理钢材表面缺陷的跨尺度信息，提高检测能力。其次，将颈部的C2f模块替换为更轻量的H-C2f模块，参数量和计算量分别降低0.9×10^6和2.2×10^9次，检测精度和速度也有所提升。HAM模块通过空间和通道注意力机制，提升对细节特征信息的提取能力。同时采用快速一维卷积来实现跨通道信息交互，降低模型复杂度。然后，将颈部的下采样操作替换为HWD模块，mAP值分别提升2.0%和2.9%，模型体积和检测速度进一步得到优化。HWD模块采用Haar小波变换保留图像细节信息，扩大特征图感受野，其简单高效的设计节省了计算开销，提升训练速度。最后，同时添加3个模块，即本文所提EHH-YOLOv8s算法，mAP值分别提升6.9%和5.4%，检测速度分别提升27帧/s和15帧/s，参数量和计算量仅为基线模型的63.1%和54.2%，精确度分别达到77.1%和73.8%。消融实验结果表明，本文算法具有合理性，较好地平衡了检测精度、速度和轻量化。

同时，为验证Severstal数据集中各项性能指标是因数据增强还是本文算法的效果所致，在相同实验条件下，将本文算法和YOLOv8s算法在扩充前后数据集上进行实验对比，其中，SeverstalA、SeverstalB分别表示扩充前、后的数据集。实验结果如表4所示。从表4实验结果可知，Severstal数据集扩充前mAP值达到74.3%，而扩充后mAP值反而降低4.4%。由于数据增强前的样本过于简单，导致模型在训练过程中出现过拟合。相反，本文算法的mAP值在数据增强前后均得到提升，表明Severstal数据集检测精度的提升源于本文算法的效果，同时其他指标也得到一定优化。实验结果表明，数据增强在一定程度上能避免过拟合，本文算法具有良好的鲁棒性。

3.6 对比实验

为验证本文算法的优越性，在相同实验条件下，在NEU-DET和Severstal数据集上，将改进后的算法与其他算法进行对比，包括Faster R-CNN、SSD、RetinaNet、YOLOv3-tiny、YOLOv4-tiny、YOLOv5s、YOLOv5m、YOLOX-s、YOLOv7-tiny、YOLOv8s及文献[15-16,22-24]中的算法。由于Severstal数据集扩充后样本数量庞大，本文实验设备的计算能力和内存容量有限，而Faster R-CNN算法参数量过大，因此无法对其进行实验。此外，文献[15-16,22-24]算法主要针对NEU-DET数据集，因此，无法在Sever-

表3 消融实验结果

Table 3 Ablation test results

数据集	模型方法	mAP%	参数量	浮点运算量/10^9次	检测速度/(帧·s^{-1})	*P*%	*R*%
NEU-DET	YOLOv8s	72.8	11.1×10^6	28.8	109	72.8	70.9
	YOLOv8s+M1	76.5	8.3×10^6	23.9	126	68.8	76.1
	YOLOv8s+M2	75.7	10.2×10^6	26.6	116	70.0	73.5
	YOLOv8s+M3	74.8	10.7×10^6	27.9	113	73.5	70.6
	YOLOv8s+M1+M2+M3	79.7	7.0×10^6	15.6	136	77.1	74.6
Severstal	YOLOv8s	69.9	11.1×10^6	28.8	103	71.1	68.4
	YOLOv8s+M1	73.2	8.3×10^6	23.9	108	71.8	64.7
	YOLOv8s+M2	72.3	10.2×10^6	26.6	105	70.8	68.5
	YOLOv8s+M3	72.8	10.7×10^6	27.9	104	67.5	68.2
	YOLOv8s+M1+M2+M3	75.3	7.0×10^6	15.6	118	73.8	68.6

表 4　Severstal 数据集扩充前后实验对比

Table 4　Comparison of experiments before and after enrichment of Severstal dataset

数据集	模型方法	mAP%	参数量	浮点运算量/10^9次	检测速度/(帧·s^{-1})
SeverstalA	YOLOv8s	74.3	11.1×10^6	28.8	120
	EHH-YOLOv8s	78.6	7.0×10^6	15.6	125
SeverstalB	YOLOv8s	69.9	11.1×10^6	28.8	103
	EHH-YOLOv8s	75.3	7.0×10^6	15.6	118

stal 数据集上进行对比分析。表 5 展示了实验结果。

从表 5 实验结果可知, EHH-YOLOv8s 算法在 NEU-DET 和 Severstal 数据集上表现出显著优势。相较于上述所提经典模型算法, EHH-YOLOv8s 算法具有较高的检测精度, 其 mAP 值分别达到 79.7% 和 75.3%。此外, EHH-YOLOv8s 算法的检测速度分别为 136 帧/s 和 118 帧/s, 优于其他对比算法。相比之下, 文献 [16] 在 NEU-DET 数据集上具有较高的检测精度, 模型参数量和计算量也具备优势, 但检测精度与实验设备、数据集划分及实验参数设置也具有相关性, 其 49 帧/s 的检测速度较低, 实时性较差。文献 [15,22-23] 的检测速度相比于文献 [16] 有所提升, 但参数量随之增加, 检测精度也有所降低。而文献 [24] 算法占用过多的计算资源, 同时检测精度和速度较低。上述文献均无法较好地平衡检测精度、速度和轻量级。相反, 本文算法参数量和计算量仅为 7.0×10^6 和 15.6×10^9 次, 检测速度达到最优, 极大地满足了实时性需求。因此, EHH-YOLOv8s 算法可更好地平衡检测精度、速度和轻量级, 具有较高的通用性和实用价值。

3.7　可视化对比实验

为直观比较本文算法和基线模型在钢材表面缺陷检测性能上的差异, 使用 EHH-YOLOv8s 算法与 YOLOv8s 模型对 NEU-DET 和 Severstal 数据集

表 5　对比实验结果

Table 5　Compare experimental results

数据集	模型方法	mAP0.5/%	参数量	浮点运算量/10^9次	检测速度/(帧·s^{-1})
NEU-DET	Faster R-CNN	65.7	72.00×10^6	167.3	17
	SSD	61.0	41.10×10^6	145.3	41
	RetinaNet	69.5	18.30×10^6	45.1	15
	YOLOv3-tiny	46.5	8.60×10^6	12.9	142
	YOLOv4-tiny	54.6	5.90×10^6	16.1	128
	YOLOv5s	70.1	7.07×10^6	16.4	102
	YOLOX-s	71.8	8.00×10^6	21.6	46
	YOLOv7-tiny	68.7	6.02×10^6	13.1	108
	YOLOv8s	72.8	11.10×10^6	28.8	120
	文献[15]	74.1	23.90×10^6		75
	文献[16]	78.5	5.80×10^6	10.9	49
	文献[22]	77.2	7.03×10^6		115
	文献[23]	75.5	8.12×10^6		96
	文献[24]	75.2	90.80×10^6		30
	EHH-YOLOv8s(本文)	79.7	7.00×10^6	15.6	136
Severstal	SSD	65.3	41.10×10^6	145.3	12
	RetinaNet	71.2	18.30×10^6	45.1	11
	YOLOv3-tiny	56.4	8.60×10^6	12.9	117
	YOLOv4-tiny	59.6	5.90×10^6	16.1	103
	YOLOv7-tiny	68.7	6.02×10^6	13.1	108
	YOLOv5s	72.4	7.07×10^6	16.4	59
	YOLOv5m	73.2	21.00×10^6	50.3	52.6
	YOLOX-s	73.8	8.00×10^6	21.6	42
	YOLOv8s	69.8	11.10×10^6	28.8	103
	EHH-YOLOv8s(本文)	75.3	7.00×10^6	15.6	118

的6类缺陷类别进行定性分析，并通过可视化展示检测效果，如图9所示。可以看出，YOLOv8s算法存在多处漏检现象，难以满足工厂生产高质量钢材的需求。相较于基线模型，本文算法能够更准确地检测出有效的缺陷区域，极大地避免了漏检和误检情况，尤其是对于难以检测的裂缝、氧化皮和划痕类别。还可以看出，在NEU-DET数据集上，本文算法在裂缝、夹杂物、点蚀表面和氧化皮等类别上表现出较好的提升效果；而在Severstal数据集上，对裂缝、氧化皮和划痕3类缺陷的提升效果较为显著。此外，本文算法检测到的缺陷相较于基线模型具有较高的缺陷置信度。尽管存在部分漏检情况(如裂缝、点蚀表面和划痕缺陷)，但总体检测效果较为突出。可视化结果表明，EHH-YOLOv8s算法具备更强的浅层特征提取能力，对小目标的检测能力较强，能更好地避免漏检和误检情况，同时具备显著的检测性能优势。

同时，采用伽马变换对可视化中的6类缺陷图像亮度进行增强和减弱操作，模拟本文算法和基线模型在不同光照条件下的表现，图10展示了本文算法和基线模型在NEU-DET数据集上对不同亮度缺陷类别的检测效果。可见，基线模型在不同亮度的缺陷类别中存在多处漏检现象，尤其对裂缝、夹杂物和氧化皮的漏检较为明显。相比之下，EHH-YOLOv8s算法对各类缺陷在不同亮度条件下均能准确检测出有效区域，且漏检和误检情况较少。实验结果表明，本文算法在面对环境因素时具有较强的抗干扰和鲁棒性能力。

此外，对NEU-DET和Severstal数据集的6类缺陷，采用本文算法和基线模型生成相应的可视化热力图。为更直观地展示其效果，在实验中将热力图区域指定为缺陷区域，最终效果如图11所示。可以看出，热力图的可视化结果与图9的检测效果大致相符。对于部分较难检测的缺陷类别(如图中用红框标注的裂缝、夹杂物、点蚀表面和细小划痕等)，EHH-YOLOv8s算法相较于YOLOv8s算法，在缺陷区域的热力效果更佳，对于大部分缺陷区域热力效果更为显著，漏检率和误检率较低。表明本文算法在小目标检测方面表现出较强的性能，具备较高的鲁棒性。

3.8 泛化性验证

采用开放PCB数据集[25]对本文算法(EHH-YOLOv8s)进行泛化性能验证。该数据集共包含693张图像，涵盖焊点漏焊、缺口、开路、短路、毛刺和余铜等6种缺陷类型，每张图像均包含3处以上缺陷，如图12所示，其中，部分缺陷已用红圈标出。数据集划分、实验参数设置和评价指标与3.2节和3.3节保持一致。

将基线模型和本文算法在PCB板上进行实验对比，其实验结果如表6所示。从表6实验结果可知，EHH-YOLOv8s算法在PCB数据集上mAP值达到94.2%，相较于基线模型提升2.4%，检测速度提升24帧/s，表现出较强的实时性。表明本文算法具备更强的小目标检测能力，同时参数量和计算量

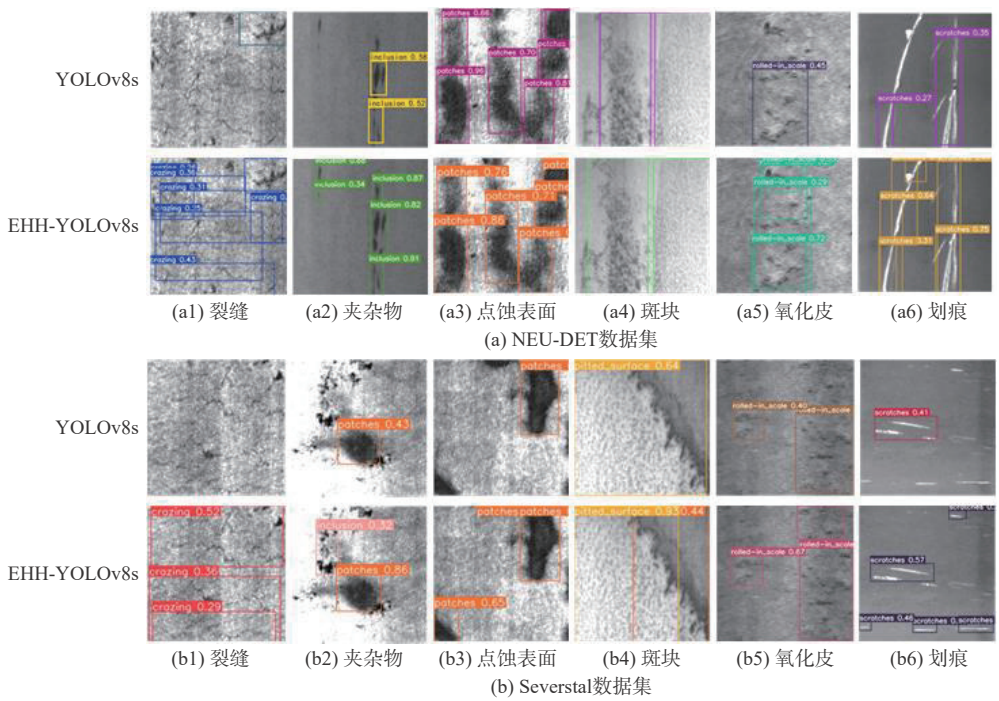


图9 本文算法与原模型可视化结果对比

Fig. 9 Visualization results comparison between the proposed algorithm and the original model

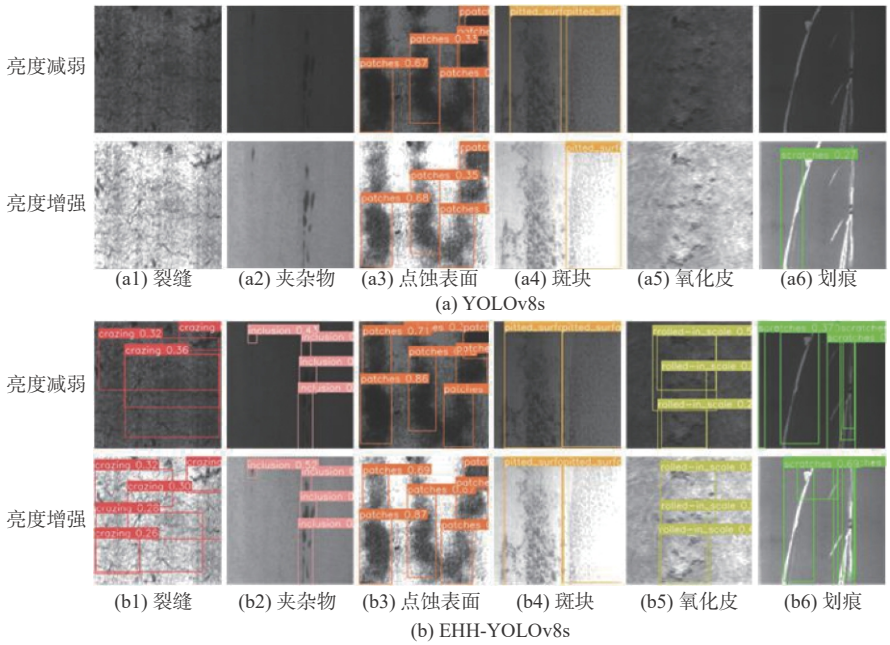


图 10　不同亮度检测效果对比

Fig. 10　Comparison of detection effect of different brightness

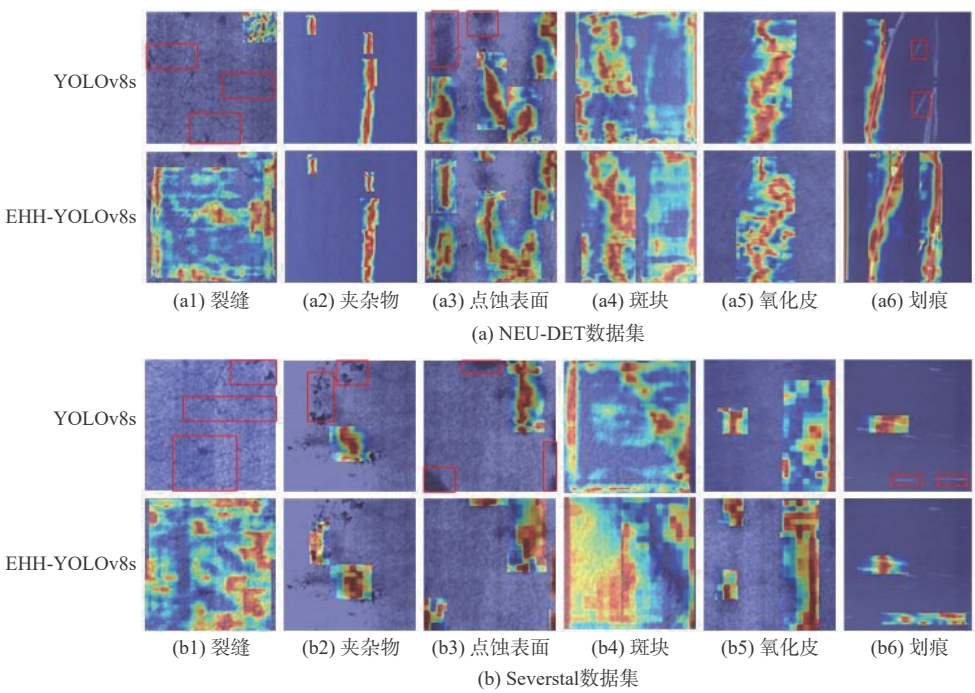


图 11　本文算法与原模型热力图检测效果对比

Fig. 11　Comparison of heat map detection effect between the proposed algorithm and original model

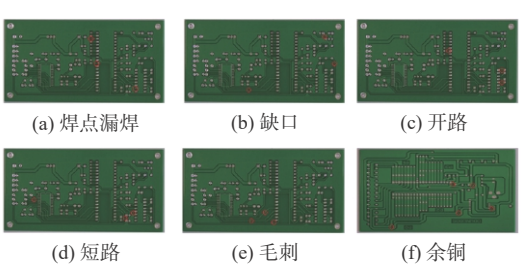


图 12　PCB 板表面各类缺陷图像

Fig. 12　Image of various defects on PCB surface

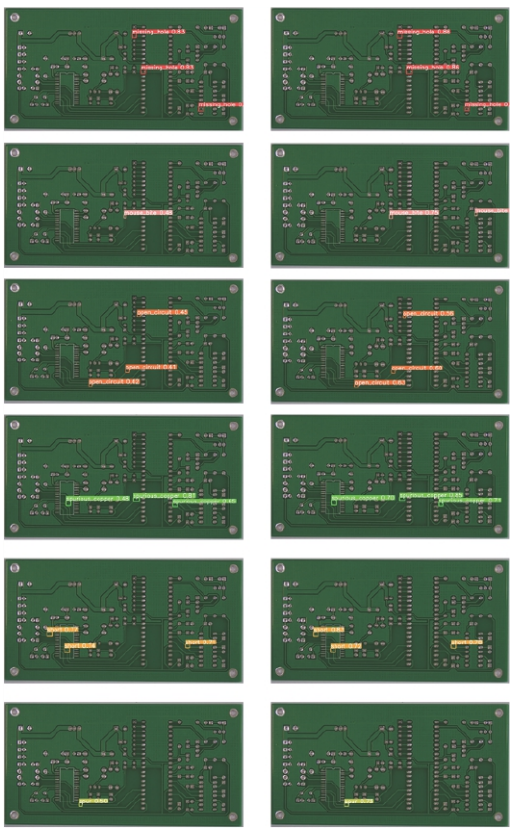
也具有显著优势。实验结果表明, 本文算法具备较强的泛化性能。

本文算法与基线模型在 PCB 板数据集上的可视化结果如图 13 所示。可以看出, 相比于基线模型, 本文算法能够更准确地检测出更多的缺陷目标。同时, 尽管 2 种算法都存在漏检情况, 但 EHH-YOLOv8 算法相对于 YOLOv8s 算法而言漏检情况较少, 且置信度更高, 进一步凸显了本文算法的优越性。

表 6 PCB板数据集检测结果对比

Table 6 Comparison of detection results of PCB board dataset

模型方法	mAP%	参数量	浮点运算量/10^9次	检测速度/(帧·s^{-1})
YOLOv8s	91.8	11.1×10^6	28.8	101
EHH-YOLOv8s	94.2	7.0×10^6	15.6	125



(a) YOLOv8s (b) EHH-YOLOv8s

图 13 本文算法和基线模型可视化结果对比

Fig. 13 Comparison of visualization results between the proposed algorithm and baseline model

4 结 论

针对现有缺陷检测模型参数量大、检测精度和实时性较差等问题，以及钢材表面缺陷检测效率低和精度差的挑战，本文提出EHH-YOLOv8s算法。

1）对Severstal数据集图像进行数据增强处理，以避免模型训练过拟合。

2）采用轻量级骨干网络，压缩模型体积，实现轻量化操作。

3）设计特征交互模块，引入HWD模块，保证减低模型体积的同时有效平衡检测精度和速度。

4）EHH-YOLOv8s算法在NEU-DET、Severstal和PCB板数据集上，在保持较高检测精度的同时，所需的计算资源更少，检测速度更快，较好地平衡了检测精度、速度和轻量级，且具备优越的泛化性能。

目前，EHH-YOLOv8s模型的部署尚在实验阶段，未来研究将考虑模型在实际部署时的寿命、维护和能源消耗等因素，并将其应用于工业钢材缺陷检测领域。

参考文献（References）

[1] 梁礼明, 阳渊, 朱晨锟, 等. 融合 Mobile Vit 和倒置门控编解码的视网膜血管分割算法[J]. 北京航空航天大学学报, 2025, 51(3): 712-723.
Liang L M, Yang Y, Zhu C K, et al. Fusion of Mobile Vit and inverted gated codec retinal vessel segmentation algorithm[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(3): 712-723(in Chinese).

[2] 李彬, 汪诚, 丁相玉, 等. 改进 YOLOv4 的表面缺陷检测算法[J]. 北京航空航天大学学报, 2023, 49(3): 710-717.
Li B, Wang C, Ding X Y, et al. Surface defect detection algorithm based on improved YOLOv4[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(3): 710-717(in Chinese).

[3] Singh S A, Desai K A. Automated surface defect detection framework using machine vision and convolutional neural networks[J]. Journal of Intelligent Manufacturing, 2023, 34(4): 1995-2011.

[4] Wang C M, Liu H. YOLOv8-VSC: lightweight algorithm for strip surface defect detection[J]. Journal of Frontiers of Computer Science and Technology, 2024, 18(1): 151-160.

[5] Liang F T, Zhou Y, Chen X, et al. Review of target detection technology based on deep learning[C]//Proceedings of the 5th International Conference on Control Engineering and Artificial Intelligence. New York: ACM, 2021: 132-135.

[6] Girshick R. Fast R-CNN[C]//Proceedings of the IEEE International Conference on Computer Vision. New York: ACM, 2015: 1440-1448.

[7] Hu B, Wang J. Detection of PCB surface defects with improved Faster-RCNN and feature pyramid network[J]. IEEE Access, 2020, 8: 108335-108345.

[8] He K M, Gkioxari G, Dollár P, et al. Mask R-CNN[C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2017: 2980-2988.

[9] Qian H M, Wang H L, Feng S, et al. FESSD: SSD target detection based on feature fusion and feature enhancement[J]. Journal of Real-Time Image Processing, 2023, 20(1): 2.

[10] Jiang P Y, Ergu D, Liu F Y, et al. A review of YOLO algorithm developments[J]. Procedia Computer Science, 2022, 199: 1066-1073.

[11] Hussain M. YOLO-v1 to YOLO-v8, the rise of YOLO and its complementary nature toward digital manufacturing and industrial defect detection[J]. Machines, 2023, 11(7): 677.

[12] Zhou S Y, Zeng Y L, Li S C, et al. Surface defect detection of rolled steel based on lightweight model[J]. Applied Sciences, 2022, 12(17): 8905.

[13] Qin R B, Chen N J, Huang Y H. EDDNet: an efficient and accurate defect detection network for the industrial edge environment [C]//Proceedings of the IEEE 22nd International Conference on Software Quality, Reliability and Security. Piscataway: IEEE Press, 2022: 854-863.

[14] Yang L Y, Huang X B, Ren Y C, et al. Steel plate surface defect detection based on dataset enhancement and lightweight convolution

neural network[J]. Machines, 2022, 10(7): 523.

[15] 曹义亲, 伍铭林, 徐露. 基于改进 YOLOv5 算法的钢材表面缺陷检测[J]. 图学学报, 2023, 44(2): 335-345.
Cao Y Q, Wu M L, Xu L. Steel surface defect detection based on improved YOLOv5 algorithm[J]. Journal of Graphics, 2023, 44(2): 335-345(in Chinese).

[16] 张政超. 改进 YOLOv5 的轻量级带钢表面缺陷检测[J]. 计算机系统应用, 2023, 32(6): 278-285.
Zhang Z C. Lightweight strip steel defect detection based on improved YOLOv5[J]. Computer Systems and Applications, 2023, 32(6): 278-285(in Chinese).

[17] 蔡剑锋, 柏俊杰, 张雪, 等. 基于改进 Mask R-CNN 的金属板材表面缺陷检测[J]. 重庆科技学院学报 (自然科学版), 2023(2): 110-116.
Cai J F, Bai J J, Zhang X, et al. Research on surface defect recognition of metal sheet based on improved mask R-CNN[J]. Journal of Chongqing University of Science and Technology (Natural Sciences Edition), 2023(2): 110-116(in Chinese).

[18] Huang P L, Wang S H, Chen J Y, et al. Lightweight model for pavement defect detection based on improved YOLOv7[J]. Sensors, 2023, 23(16): 7112.

[19] Cai H, Li J Y, Hu M Y, et al. EfficientViT: multi-scale linear attention for high-resolution dense prediction[PP/OL]. arXiv (2024-02-06) [2024-06-01]. https://doi.org/10.48550/arXiv.2205.14756.

[20] Li G Q, Fang Q, Zha L L, et al. HAM: hybrid attention module in deep convolutional neural networks for image classification[J]. Pattern Recognition, 2022, 129: 108785.

[21] Xu G P, Liao W T, Zhang X, et al. Haar wavelet downsampling: a simple but effective downsampling module for semantic segmentation[J]. Pattern Recognition, 2023, 143: 109819.

[22] 周彦, 孟江南, 王冬丽, 等. 基于多尺度轻量化注意力的钢材缺陷检测[J]. 控制与决策, 2024, 39(3): 901-909.
Zhou Y, Meng J N, Wang D L, et al. Steel defect detection based on multi-scale lightweight attention[J]. Control and Decision, 2024, 39(3): 901-909(in Chinese).

[23] 赵林熔, 甄国涌, 储成群, 等. 基于 CBE-YOLOv5 的钢材表面缺陷检测方法[J]. 电子测量技术, 2023, 46(15): 73-80.
Zhao L R, Zhen G Y, Chu C Q, et al. Detection method of steel surface defects based on CBE-YOLOv5[J]. Electronic Measurement Technology, 2023, 46(15): 73-80(in Chinese).

[24] Guo Z X, Wang C S, Yang G, et al. MSFT-YOLO: improved YOLOv5 based on transformer for detecting defects of steel surface[J]. Sensors, 2022, 22(9): 3467.

[25] 周贤勇, 祝俊辉, 王圆, 等. 基于改进 YOLOv7 算法的 PCB 裸板缺陷检测[J]. 无线电工程, 2023, 53(12): 2791-2797.
Zhou X Y, Zhu J H, Wang Y, et al. PCB bare board defect detection based on improved YOLOv7 algorithm[J]. Radio Engineering, 2023, 53(12): 2791-2797(in Chinese).

Improved lightweight and efficient EHH-YOLOv8s algorithm for strip steel surface defect detection

LIANG Liming*, LONG Pengwei, LU Baohe, OU Yanyan, ZENG Lu

(School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou 341000, China)

Abstract: To address the issues of low efficiency, and poor accuracy in current steel surface defect detection, and the challenges of large model parameters, low detection accuracy, and poor real-time performance of existing defect detection models, a lightweight steel defect detection algorithm based on YOLOv8s (EHH-YOLOv8s) is proposed. The reconstruction feature interaction module H-C2f, which successfully preserves spatial and channel features, suppresses redundant information, and improves detection accuracy and speed; the Haar wavelet downsampling (HWD) module, which expands the receptive field, reduces model complexity, and speeds up training and inference; and the lightweight EfficientViT network, which serves as the backbone network to reduce model complexity and better handle cross-scale feature information. Experimental validation on the NEU-DET and Severstal steel defect datasets shows that compared to the YOLOv8s algorithm, the EHH-YOLOv8 algorithm achieves an improvement in mean average precision (mAP) of 6.9% and 5.4%, respectively, with reductions in parameters and computations of 4.1×10^6 and 13.2×10^9, and achieves detection speed of 136 frames/s and 118 frames/s. These findings show that the algorithm strikes a superior balance between speed, lightweight design, and detection accuracy, offering a dependable reference for high precision and real-time performance on edge devices. Finally, validation on the PCB board defect dataset shows that the algorithm possesses good generalization performance.

Keywords: defect detection; lightweight YOLOv8s; EfficientViT; H-C2f; Haar wavelet downsampling

Received: 2024-06-12; **Accepted**: 2024-07-30; **Published Online**: 2024-08-08 08:50

URL: link.cnki.net/urlid/11.2625.V.20240807.1403.003

Foundation items: National Natural Science Foundation of China (51365017,61463018); General Project of Jiangxi Provincial Natural Science Foundation (20192BAB205084); Jiangxi Provincial Department of Education Science and Technology Research Key Project (GJJ170491,GJJ2200848); Jiangxi Province Graduate Innovation Special Fund (YC2022-S676)

* **Corresponding author**. E-mail: 9119890012@jxust.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0660

民机大尺寸全机缩比模型机体噪声风洞试验研究

周国成[1,2,*]，孙一峰[3]，包安宇[1,2]，丁存伟[1,2]

(1. 中国航空工业空气动力研究院，哈尔滨 150001；2. 空气动力噪声及其控制黑龙江省重点实验室，哈尔滨 150001；
3. 中国商用飞机有限责任公司上海飞机设计研究院，上海 200135)

摘 要：采用大尺寸模型开展风洞试验是准确掌握民机机体噪声特性、验证降噪设计效果的重要手段。基于8 m×6 m大型声学风洞及其配套的试验支撑设备和测试设备，采用民机大尺寸全机缩比模型进行了机体噪声风洞试验，并利用地面线阵、1/4圆弧阵、地面麦克风相位阵列等对其过顶噪声、边线噪声及噪声源分布进行测试；介绍了试验所采用的试验设备及试验方法，并分析了机体噪声随风速、迎角、增升装置偏度、有无起落架等参数的变化规律。研究结果表明：民机机体噪声整体呈现为宽频噪声，在不同频段符合不同的马赫数幂次律关系；增升装置对民机机体总噪声的贡献与起落架接近，并随着迎角、襟缝翼偏度增大而增大；机体噪声在飞跃和横侧方向均表现出一定的指向性，在横侧方向的指向性更强；不同构型下机体噪声源分布特性具有较大差异，大襟翼偏度下襟翼边缘噪声将成为高频段的主要声源之一。

关 键 词：民用飞机；机体噪声；风洞试验；远场噪声；声源定位
中图分类号：V211; O424
文献标志码：A **文章编号**：1001-5965(2026)11-3712-12

随着世界航空运输业的快速发展，民机噪声成为影响机场附近居民生活质量的主要环境问题之一[1-3]。针对民机的外部噪声问题，国际民航组织(International Civil Aviation Organization，ICAO)、美国联邦适航局和中国民用航空局均颁布了相应的噪声适航标准，要求民机必须满足噪声限值的要求。2018年起，国际民航组织开始采用第五阶段的适航噪声标准，进一步提高了民机外部噪声要求。

民机气动噪声主要包括发动机噪声、机体噪声及安装效应噪声等。随着大涵道比发动机、消声短舱和声衬等先进技术的广泛应用，发动机噪声已经大幅度降低，机体噪声的重要性在飞机外部噪声中逐渐凸显出来[4-5]，成为当前民机噪声控制的主要问题。机体噪声通常分为增升装置噪声和起落架噪声2个主要部分。机体噪声的产生与分离流动、尾流与机体结构干扰等复杂流动现象密切相关，具有产生机理复杂、控制困难的特点。准确掌握民机机体噪声特性是评判其噪声水平和进行降噪优化的基础。

针对民机机体噪声的评估及降噪设计的验证，目前的主要手段仍是风洞试验。国内外开展了大量的机体噪声风洞试验研究，这些试验按照模型尺寸或简化程度，通常可分为小尺寸部件模型噪声试验[6-8]、大尺寸/全尺寸部件模型试验[9-12]及大尺寸全机模型噪声试验[13-15]。由于模型缩比对气动噪声试验结果有着重要影响，气动噪声风洞试验通常希望在大型声学风洞中采用大尺寸模型进行试验。

欧美国家的大型航空声学风洞建设较早，气动噪声试验技术成熟，以DNW LLF、NASA Ames中心的12.2 m×24.4 m风洞为代表的多座声学风洞开展了多期大尺寸全机缩比模型机体噪声试验研究。Dobrzynski等[13]采用缩比为1∶7.5的A320飞机模型在DNW LLF风洞中开展了全机缩比模型噪声试验，对增升装置的脉动压力、噪声源分布及远场噪

收稿日期：2024-09-05；**录用日期**：2024-11-14；**网络出版时间**：2024-12-04 08:50
网络出版地址：link.cnki.net/urlid/11.2625.V.20241203.0858.001
*通信作者. E-mail：zhougc@avic.com

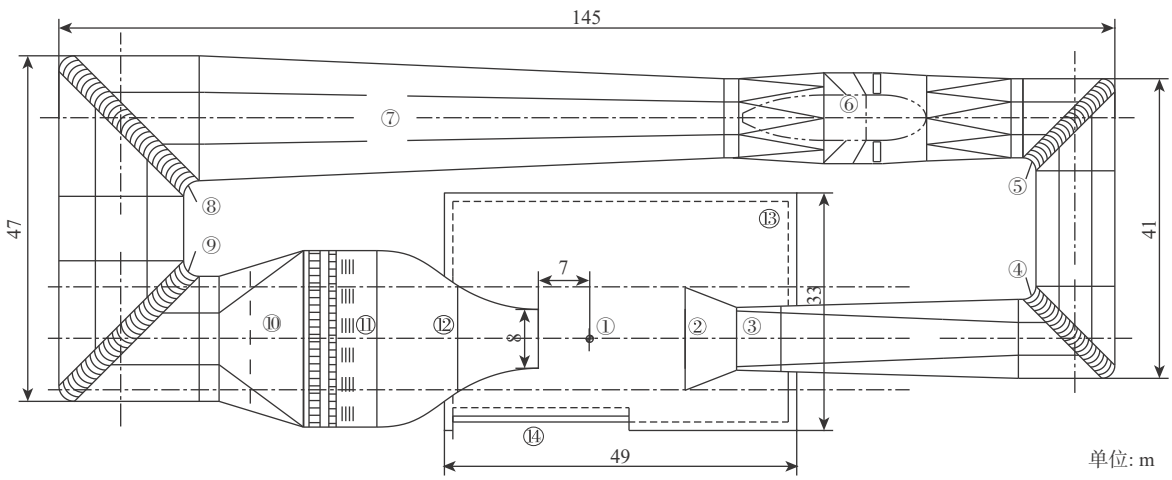
引用格式：*周国成，孙一峰，包安宇，等. 民机大尺寸全机缩比模型机体噪声风洞试验研究[J]. 北京航空航天大学学报，2026，52(11)：3712-3723. Zhou G C，Sun Y F，Bao A Y，et al. Experimental research on airframe noise of large-scale full-scaled civil aircraft model in wind tunnel[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3712-3723 (in Chinese).*

声进行了测量, 通过试验准确识别了民机机体主要噪声源分布与特性, 为民机机体噪声快速预估方法研究提供了基准数据。Oerlemans 等[14] 采用 1∶10.6 的 A340 飞机模型在 DNW LLF 风洞的开口试验段和闭口试验段分别进行噪声源定位试验, 并将功率积分方法应用于不同降噪方案的区域量化评估, 研究表明, 采用互谱矩阵对角元素移除与功率谱积分相结合, 能够更好地评估降噪设计在局部与总体的降噪效果。Horne 等[15] 采用 26% 缩比的波音 777 飞机半模模型在 NASA Ames 中心的 12.2 m×24.4 m 风洞中开展试验, 并采用固定阵列与移动阵列相结合的方法对不同噪声源进行对位和对比, 重点评估了端板、整流罩、翼尖延伸、缝翼凹腔填充、涡流发生器等降噪措施的降噪效果。Khorrami 等[16] 采用 18% 缩比的湾流公务机半模模型在 NASA Langley 中心的 4.4 m×6.6 m 风洞中进行气动力和气动噪声测试, 验证了多孔结构、声衬结构、襟翼翅片、连式襟翼等多种襟翼降噪措施, 取得了 2～4 dB 的降噪效果, 并发现这些降噪措施对增升装置气动性能的影响几乎可以忽略。中国的大型航空声学风洞建设较晚, 相应的气动噪声试验技术研究起步也晚, 因此, 在大尺寸全机模型气动噪声风洞试验方面的研究较少。宋玉宝等[17] 采用展长为 3.695 m 的民机标模全机模型, 在 5.5 m×4 m 的声学风洞中用翼展 3.69 m 的全机缩比模型开展增升装置噪声试验研究, 用 1/4 圆弧阵对远场噪声进行测量, 并用 3 m 量级麦克风相位阵列对噪声源进行定位, 分析增升装置噪声随迎角、风速等参数的变化规律, 并发现随迎角增加, 增升装置噪声在中高频段总体上呈增加趋势, 随着风速增加, 模型辐射噪声相应明显增大, 并呈现出良好的马赫数相似性。

2019 年, 中国航空工业空气动力研究院的 8 m×6 m 大型低速风洞(FL-10 风洞)完成了消声室的建设和校测[18], 具备了气动噪声风洞试验条件, 并先后开展了全机缩比、起落架、半模等气动噪声试验研究[19]。本文基于 FL-10 风洞开展了翼展 4.5 m 的民机大尺寸全机缩比模型机体噪声风洞试验研究, 采用地面麦克风相位阵列、1/4 圆弧阵及地面线阵对模型气动噪声进行测量, 并分析了风速、迎角、襟翼偏度、有无起落架等对模型气动噪声的影响, 以及不同增升装置构型下的噪声源分布特性。相关研究工作可为民机机体噪声特性研究与降噪设计等提供参考。

1　FL-10 风洞概况

试验在中国航空工业空气动力研究院 FL-10 风洞中进行。FL-10 风洞是一座常压低速回流式航空声学风洞, 总体轮廓如图 1 所示。FL-10 风洞建有闭口与开口 2 个试验段, 配备净空间为 47 m(长)×31 m(宽)×22 m(高)、截止频率为 80 Hz 的全消声室。开口试验段尺寸为 8 m(宽)×6 m(高)×20 m(长), 最大风速为 85 m/s, 80 m/s 风速下的背景噪声为 76.6 dB(A)(A 表示声级, 测量距离 12.8 m), 为本文试验所使用试验段。



①开口试验段; ②收集器; ③第一扩散段; ④第一拐角; ⑤第二拐角; ⑥动力段; ⑦第二扩散段; ⑧第三拐角; ⑨第四拐角; ⑩大角扩散段; ⑪稳定段; ⑫收缩段; ⑬消声室; ⑭隔声门。

图 1　FL-10 大型低速风洞平面图

Fig. 1　Sketch of FL-10 large low speed wind tunnel

2　试验模型与支撑系统

采用的风洞试验模型为某型民机全机缩比模型, 模型缩比为 1∶7.636, 缩比后模型展长为 4.5 m(不包括翼梢小翼)。模型采用 7075 铝和 30CrMnSi 合金结构钢等材料制作, 由机身、机翼(含增升装置

和翼梢小翼)、通气短舱、起落架、角度块等部件组成,试验时未安装尾翼。

采用FL-10风洞的液压尾撑系统来支撑试验模型(见图2),模型与尾撑系统通过翼型支杆连接,并采用背部支撑的方式将模型支撑到风洞试验段中心,以降低翼型支杆对气动噪声测试的影响。为降低尾撑系统的噪声干扰,FL-10风洞液压尾撑系统配有专用的声学整流罩,将液压尾撑装置复杂结构外形与风洞高速气流隔离开。声学整流罩外表面包裹有柔性声学材料,进一步降低高速气流与整流罩相互作用产生的噪声。安装整流罩后,尾撑系统的迎角变化范围为−2°～12°。

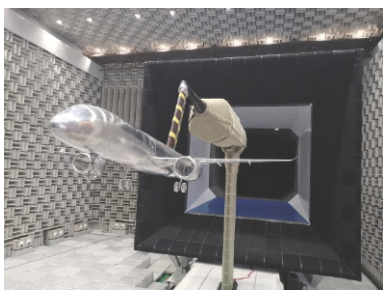


图2 全机缩比模型在风洞中的安装

Fig. 2 Installation of a scaled model in a wind tunnel

由于模型的缩比,使得相同风速下风洞试验的雷诺数要远低于飞行状态,进而导致机翼表面层流与湍流区域分布和真实飞行状态有所差异。为了更加准确地模拟飞机机翼表面流态,试验时对模型进行转捩控制[20],分别在机翼、机头、短舱等前缘位置采用锯齿形转捩带进行处理(见图3)。其中,机翼转捩位置为缝翼30%弦长位置,机头和短舱转捩位置距前缘33 mm。



图3 全机缩比模型机翼及短舱强制转捩处理

Fig. 3 Forced transition treatment on wing and nacelle of scaled model

3 噪声测试系统

分别采用地面线阵、1/4圆弧阵来测量模型的远场噪声,采用地面麦克风相位阵列测量模型的噪声源分布。此外,采用内式天平对模型的气动力进行测量,以供有效迎角修正使用。

3.1 地面线阵

地面线阵用来测量模型的过顶噪声,布置在模型的正下方,位于风洞试验段左右对称面上,距离地面高度为2.5 m,距离试验模型高度差为7.5 m。地面线阵上的麦克风布置如图4所示。地面线阵共有19个测试通道,测量角度范围为40°～130°,按5°等角度间隔布置,试验时,每个麦克风均指向试验段中心,以消除麦克风测量角度的影响。其中,第11通道位于机体模型的正下方,指向角为90°。地面线阵上每个麦克风均配备防风球,以降低风洞开口试验段回流对噪声测试结果的影响。

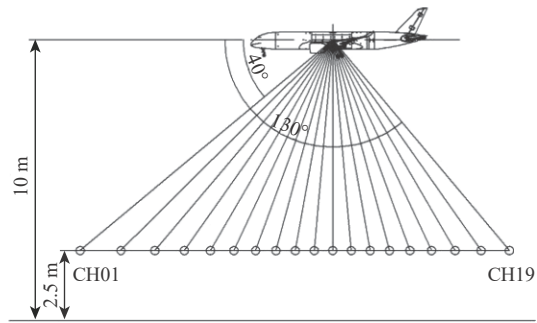


图4 地面线阵布置(侧视)

Fig. 4 Ground line array layout (side view)

3.2 1/4圆弧阵

1/4圆弧阵用来测量模型的边线噪声,如图5所示。1/4圆弧阵的测量半径为7 m,测量角度范围为90°,共布置有19个麦克风,按5°等角度间隔布置。1/4圆弧阵可沿底部导轨平行于风洞轴线移动,以得到整个扫描面上的噪声数据。底部移测架的长度为14 m,可用的轴向移测范围为12 m。

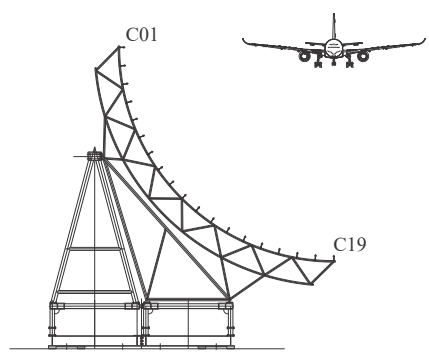


图5 1/4圆弧阵布置(正视)

Fig. 5 1/4 Arc array layout (front view)

3.3 地面麦克风相位阵列

地面麦克风相位阵列用来对机体噪声源分布进行定位,阵列总通道数为143通道,采用多臂螺旋形式,共分为13条旋臂,每条旋臂上布置11个麦克风。考虑机体模型的对称性,试验时,麦克风相位阵列位于左侧机翼下方,一方面避免与地面线阵干涉,另一方面改善对增升装置噪声源定位的效

果。地面麦克风相位阵列与机翼模型的位置关系如图 6 所示, 阵列中心到风洞轴线的距离为 2.5 m, 到机体模型的高度差为 7.5 m。

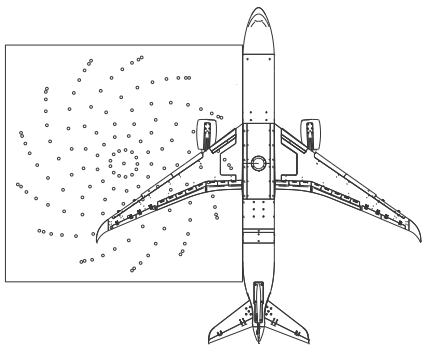


图 6　地面麦克风相位阵列阵元分布与布置(俯视)

Fig. 6　Distribution and arrangement of ground microphone phase array element (top view)

3.4　麦克风与数据采集系统

本文共采用 181 支麦克风进行噪声测试, 所采用的麦克风均为 B&K 4954A 型麦克风, 该型麦克风具有高频率、高声压级、宽频带的特点。数据采集系统为 NI 公司 PXIe 高速并行采集系统, 采样率设置为 81 920 Hz, 采样时长为 10 s, 采样块数为 100 块, 单块点数为 8 192 点。

3.5　试验总体布置

试验模型及上述 3 种测试阵列在 FL-10 风洞消声室中的布置如图 7 所示。地面麦克风相位阵列位于模型左侧机翼正下方, 地面线阵位于机体模型的正下方, 1/4 圆弧阵列位于模型机翼的右下方。

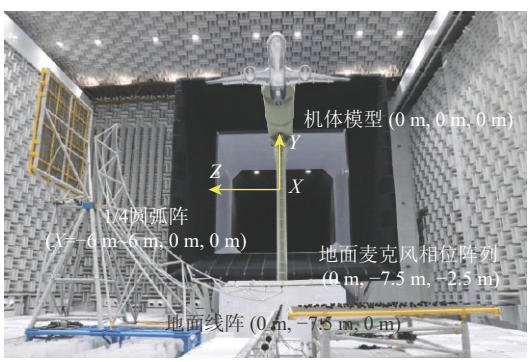


图 7　全机缩比模型气动噪声风洞试验总体布置

Fig. 7　Layout of aerodynamic noise wind tunnel test of full-scaled model

4　数据处理与修正方法

本文主要对模型的噪声源分布及远场噪声特性等进行分析, 采用了频谱分析、声源定位、射流剪切层影响修正、远场噪声数据修正、迎角修正、高通滤波等相关数据处理与修正方法。

4.1　声源定位算法

试验采用经典波束形成算法对模型的噪声源进行定位[21]。为对阵列及定位算法进行检验, 正式试验前, 在试验模型机翼表面粘贴 3 个小型扬声器, 扬声器在模型上的粘贴位置和效果如图 8 和图 9 所示。在无来流条件下, 采用功放驱动扬声器发出不同频率的纯音噪声, 利用地面麦克风相位阵列对每个声源进行定位, 并与真实声源位置进行对比, 作为后续声源定位结果判断的参考。试验测得的校准声源定位结果如图 10 所示, 可以看出, 声源定位结果与校准扬声器的真实安装位置吻合良好, 证明本文所采用的噪声源定位算法能够准确识别声源位置。

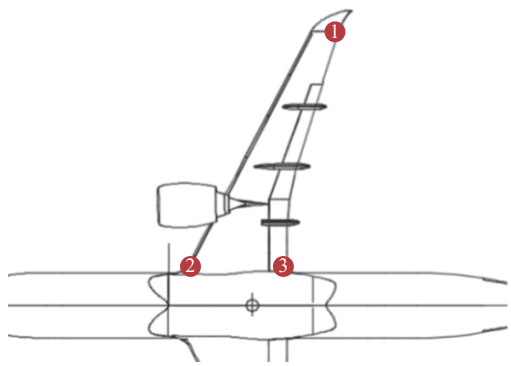


图 8　校准扬声器在模型表面的布置位置

Fig. 8　Position of calibrated speakers on model surface



图 9　校准扬声器在模型表面的安装效果

Fig. 9　Installation of calibrated speaker on model surface

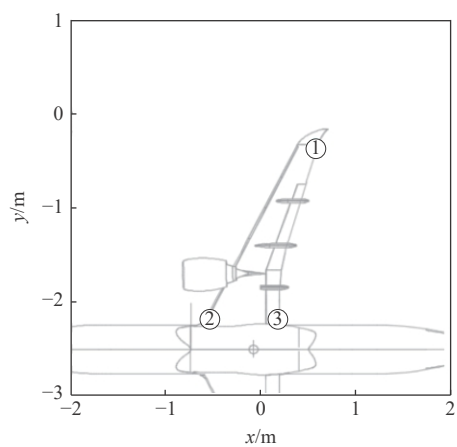


图 10　校准扬声器声源定位结果

Fig. 10　Sound source localization results of calibration speaker

4.2 射流剪切层影响修正方法

当声波穿过开口试验段射流剪切层时，将发生折射与散射等声学现象，进而影响声源定位与指向性测量结果。针对射流剪切层的影响，本文采用基于 Amiet 的射流剪切层影响修正方法[22]。该方法假设开口试验段射流剪切层是无穷薄的涡流层，且两侧介质均匀，基于 Snell 定律构建声折射方程可得

$$\frac{c_{\mathrm{i}}}{\cos\theta_{\mathrm{r}}}+U=\frac{c_{\mathrm{a}}}{\cos\theta} \tag{1}$$

式中：c_{i}和c_{a}分别为气流内部和外部声速；θ为折射角；θ_{r}为修正角；U为开口试验段试验风速。

如图 11 所示（图中，WFa 表示空气中的波前，WFi 表示气流中的波前，U_{T}为风洞中流速），结合传播路径之间的几何关系，可以得出

$$\tan\theta_{\mathrm{c}}=\frac{\zeta}{X_{\mathrm{m}}+(1+X_{\mathrm{m}})^2\cos\theta} \tag{2}$$

式中：θ_{c}为入射角；X_{m}为沿流场方向传声器距声源距离；$\zeta=\sqrt{(1-X_{\mathrm{m}}\cos\theta)^2-\cos^2\theta}$。

通过迭代求解，可以得到入射角θ_{c}和折射角θ，进而得出修正角θ_{r}。在计算得到入射角和折射角后，能够对声波的传播距离及因散射引起的幅值变化进行修正。

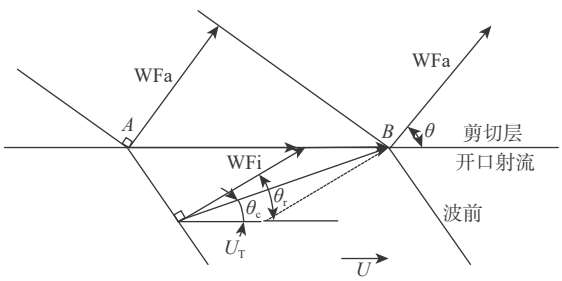


图 11 射流剪切层构建 Snell 定律示意图

Fig. 11 Scheme of Snell law in jet shear-layer

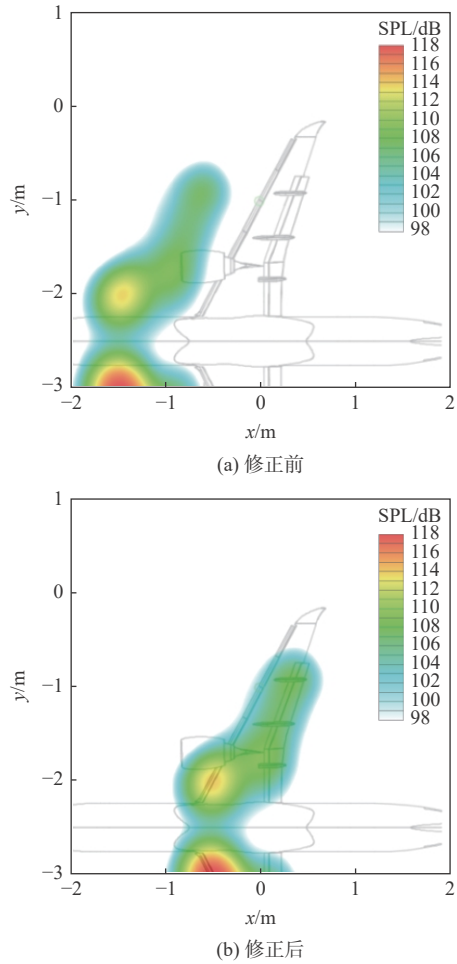
该方法被分别应用于声源定位结果的修正及远场噪声指向性的修正。图 12 给出了射流剪切层影响修正前后的增升装置噪声源定位结果对比。图中：SPL 表示声压级。可以看出，未进行射流剪切层影响修正时，声源定位结果整体向上游偏移明显，修正后的声源定位结果能够与模型部件位置相重合，证明了射流剪切层影响修正方法的可靠。

4.3 远场噪声数据修正

气动噪声风洞试验时，射流剪切层、麦克风频响、大气衰减等多种因素均会对试验结果产生影响。针对远场噪声数据，分别进行下述修正，以去除测试设备、试验环境等带来的影响。

1）麦克风频响修正。基于 B&K 公司提供的麦克风频响曲线进行修正。

2）防风球影响修正。基于同一声源、有无防风球下的麦克风测量结果进行修正。



(a) 修正前

(b) 修正后

图 12 射流剪切层影响修正前后声源分布对比

Fig. 12 Comparison of sound source distribution before and after correction for influence of jet shear layer

3）射流剪切层影响修正。采用基于 Amiet 的射流剪切层影响修正方法进行修正，得到修正后的传播距离及指向角。

4）大气衰减修正。采用 GB/T 17247.1—2000[23]中给定的方法进行修正，修正时传播路径为考虑射流剪切层影响的实际传播路径。

5）传播距离修正。按照点声源自由场衰减规律，将不同测量点的声压级修正到 7.5 m 距离，修正时，传播距离为考虑射流剪切层影响的实际传播距离。

4.4 有效迎角修正

在开口试验段试验时，由于模型的下洗作用，会导致其真实的气流迎角小于机构迎角，因此，需要对模型的有效迎角进行修正。本文通过测量开口试验段下试验模型的升力系数，并以闭口试验段中试验模型的迎角和升力系数为基准，反推出升力系数相等下开口试验段中对应的机构迎角，建立机构迎角和有效迎角的关系。表 1 给出了着陆构型有效迎角和机构迎角之间的对应关系，可以看出，受气流下洗的影响，要达到相同的升力系数，需要

表 1　着陆构型有效迎角和机构迎角之间的对应关系

Table 1　Correspondence between effective attack angle and mechanism attack angle of landing configuration

有效迎角/(°)	机构迎角/(°)
0	0
3	3.3
6	6.6
9	10.0

采用更大的机构迎角。

4.5　高通滤波

考虑低频段下所测得的噪声，以风洞背景噪声为主，在进行远场噪声数据分析时，采用 500 Hz 高通滤波对试验数据进行滤波处理，滤波器的频谱曲线如图 13 所示，该滤波器在 1 000 Hz 处的幅值衰减量为−1.07 dB。

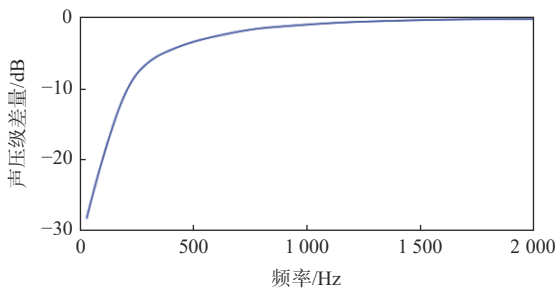


图 13　500 Hz 高通滤波器频谱曲线

Fig. 13　Frequency spectral curve of 500 Hz high pass filter

5　试验数据分析

本文测试了某民机全机缩比模型巡航构型、起飞构型及着陆构型在有效迎角为 0°、3°、6°、9°下的噪声。其中，着陆构型与起飞构型缝翼偏度相同，但襟翼偏度增大了 15°。试验共有 50 m/s、60 m/s、70 m/s 这 3 个不同风速。下文针对风速、迎角、构型等参数对远场噪声和声源分布特性的影响进行分析。

5.1　试验数据重复性精度与信噪比分析

采用 60 m/s 风速、起飞构型下 7 次试验的频谱曲线及总声压级结果来对测试重复性精度和信噪比进行分析，图 14 给出了地面线阵过顶测点(CH11)7 次测试结果的频谱曲线对比结果。可以看出，7 次测试结果的频谱曲线很好地重叠在一起，具有很好的重复性。通过对 7 次测试的总声压级(频率范围为 500～40 906 Hz)进行均方根误差分析，得到本次试验过顶噪声的重复性精度优于 0.32 dB。此外，试验数据在 1 000 Hz 以上频段、起飞构型的信噪比超过 10 dB。着陆构型增升装置偏度增大，机体噪声增大，因此，信噪比相对起飞构型也更大。重复性精度与信噪比数据说明本次试验数据具有很高的质量。

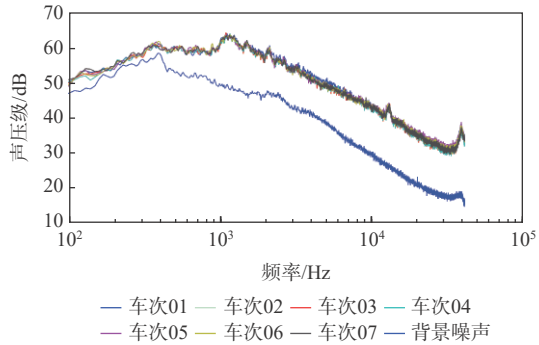


图 14　起飞构型过顶噪声频谱重复性(风速 60 m/s, 迎角 6°)

Fig. 14　Spectral repeatability of overhead noise in takeoff configuration (wind speed is 60 m/s, angle of attack is 6°)

5.2　增升装置噪声随马赫数变化规律

选取着陆构型无起落架状态在 50 m/s、60 m/s、70 m/s 这 3 个试验风速下、3°迎角的噪声数据，来分析噪声随马赫数的变化规律。该状态下增升装置是主要机体噪声源。

图 15 给出了不同风速下噪声频谱数据。可以看出，在这 3 个试验风速下，增升装置噪声整体表现为宽频噪声，频谱上未出现明显的纯音峰值，噪声幅值随着风速的增大而增大。其中，风速 70 m/s 时，在 400 Hz 附近出现了一个峰值，该峰值在后续 70 m/s 风速、不同构型下的远场噪声中均存在，经分析，该频率对应风洞风扇的叶频噪声，主要由风洞动力段风扇引起，属于风洞的背景噪声成分。

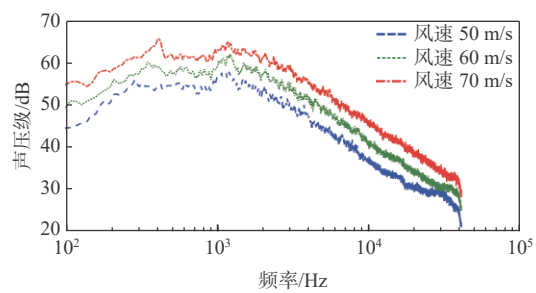


图 15　着陆构型无起落架状态不同风速下噪声频谱曲线(迎角 3°)

Fig. 15　Noise spectrum curves of landing configuration without landing gear at different wind speeds (angle of attack is 3°)

进一步对试验数据进行无量纲处理，先将频率转化为斯特劳哈尔数：

$$St = fD/U \tag{3}$$

式中：f 为频率；D 为特征长度，取为机翼的气动弦长；U 为试验风速。

然后，对声压级进行无量纲化处理，方法如下：

$$L_{p,s} = L_{p,e} - 10m\lg(Ma) \tag{4}$$

式中：$L_{p,e}$ 为风洞试验所测得的声压级；$L_{p,s}$ 为无量纲处理后的声压级；Ma 为试验的来流马赫数；m 为

声压级与 *Ma* 数之间的幂次律系数，调整 *m* 的数值，可以改变各频段下频谱曲线的重合程度，进而确定相应频段的幂次律关系。

图 16 给出了不同幂次律系数下噪声无量纲频谱曲线的对比情况。可以看出，当 *m*=6.5 时，无量纲频谱曲线在 *St*=1～4 范围内重合较好；当 *m*=5 时，无量纲频谱曲线在 *St*=4～20 范围内重合较好；当 *m*=4 时，无量纲频谱曲线在 *St*=20～200 范围内重合较好。因此，增升装置噪声在不同频段遵循不同的无量纲幂次律，在研究机体噪声特性时有必要分频段构建相应的幂次律关系。

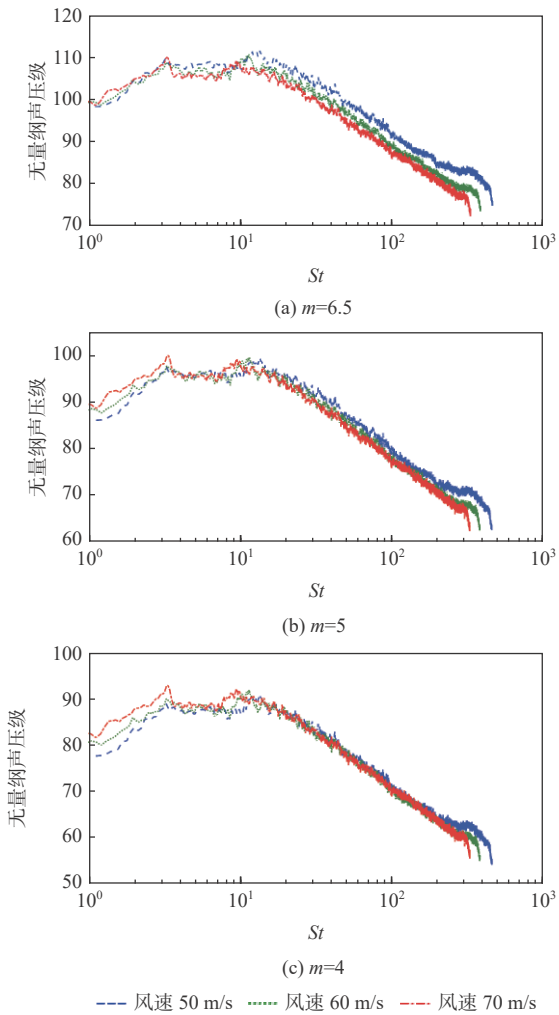


图 16 着陆构型无起落架状态噪声马赫数幂次律分析(迎角 3°)

Fig. 16 Mach power law analysis of noise in landing configuration without landing gear (angle of attack is 3°)

5.3 机体噪声随迎角变化规律

对比试验风速 *U*=70 m/s 下不同有效迎角的机体噪声频谱，如图 17 所示。可以看出，着陆构型下，迎角对机体噪声幅值的影响并不明显，随着迎角的增大，中高频段的噪声幅值略有增大。表 2 给出了不同构型和迎角下 500～40 000 Hz 范围内总声压级相对于 0°迎角的增量数据。可以看出，着陆构型总噪声随迎角的变化量在 0.3 dB 左右。对于起飞构型起落架收起状态，噪声随迎角的变化量更大，总噪声的幅值变化超过 1 dB，这种增量主要由高频段贡献，由频谱可以看出高频段幅值增量超过了 2 dB。分析认为，起飞构型下襟翼偏度更小，迎角变化对襟翼区域流动影响更大，噪声增幅也较大；而着陆构型下襟翼偏度增大，流动处于深度分离状态，迎角变化对襟翼区域流动影响减小，对噪声的影响也变小。

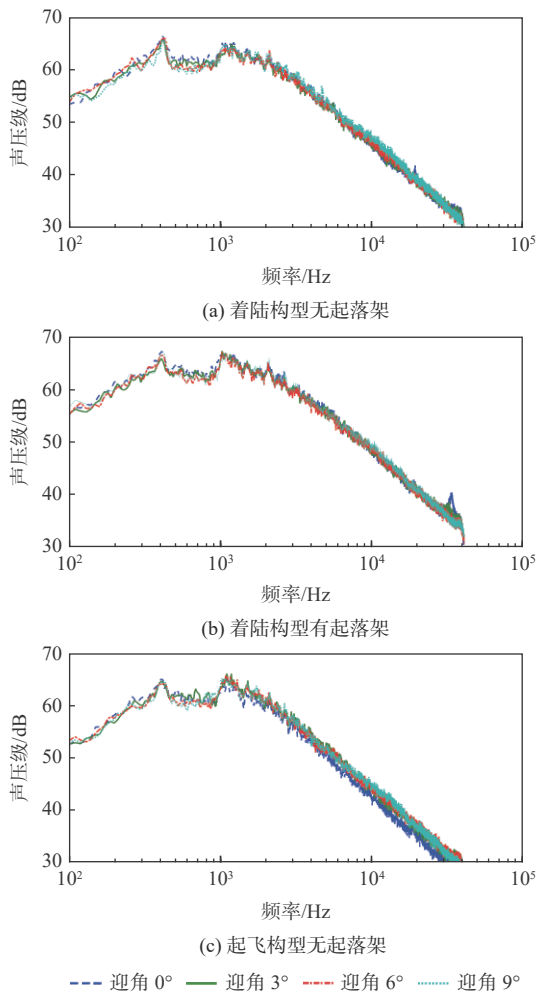


图 17 机体噪声随迎角变化规律分析(风速 70 m/s)

Fig. 17 Variation of aircraft noise with angle of attack (wind speed is 70 m/s)

表 2 不同构型和迎角下总声压级增量

Table 2 Increment of overall sound pressure level under different configurations and angles of attack

迎角/(°)	相对于0°迎角下的总声压级增量/dB		
	着陆构型 起落架放下	着陆构型 起落架收起	起飞构型 起落架收起
3	−0.28	0.08	1.14
6	−0.31	−0.16	0.87
9	0.19	0.22	1.06

5.4　起落架噪声影响

起落架噪声也是主要的机体噪声源之一。为获取起落架本身的噪声数据，将增升装置收起为巡航构型，并在模型上安装起落架模型进行风洞试验，测得噪声主要为起落架噪声。图 18 给出了巡航构型下有无起落架时噪声频谱的对比结果，以评估起落架噪声特性。可以看出，有起落架时，机体噪声幅值显著增大，起落架引起的噪声增量达 10～15 dB。

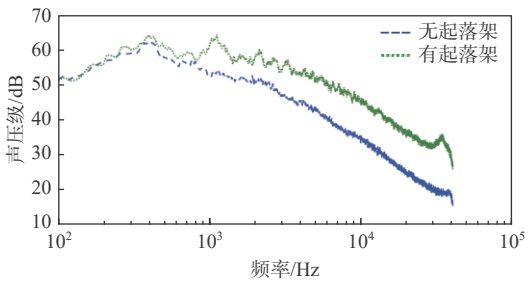


图 18　巡航构型有无起落架噪声频谱对比
（风速 70 m/s，迎角 3°）

Fig. 18　Comparison of noise spectrum of cruise configuration with and without landing gear (wind speed is 70 m/s, angle of attack is 3°)

图 19 给出了着陆构型下有无起落架时噪声频谱的对比结果，并加入了巡航构型有起落架时的噪声频谱。可以看出，起落架噪声与增升装置噪声量级相当，在 4 000 Hz 以下要比增升装置噪声稍低。着陆构型下，有起落架相对于无起落架，其噪声幅值增加 3 dB 左右。

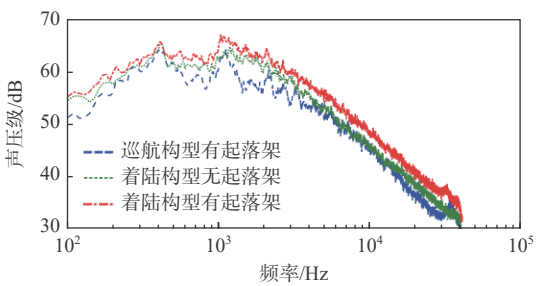


图 19　着陆构型有无起落架噪声频谱对比
（风速 70 m/s，迎角 3°）

Fig. 19　Comparison of noise spectrum of landing configuration with and without landing gear (wind speed is 70 m/s, angle of attack is 3°)

5.5　襟翼偏度影响

进一步对比起飞构型与着陆构型下增升装置噪声并分析襟翼偏度对噪声的影响，如图 20 所示。相对于起飞构型，模型缝翼偏度没有变化，但襟翼偏度增大了 15°。襟翼偏度的增大导致机体噪声明显增大，并主要集中于高频段（4～40 kHz）。

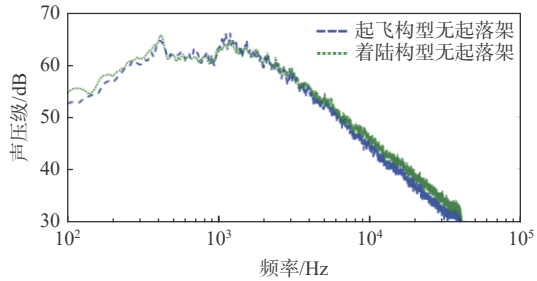


图 20　起飞与着陆构型增升装置噪声频谱对比
（风速 70 m/s，迎角 3°）

Fig. 20　Comparison of noise spectrum of high lift device between takeoff and landing configuration (wind speed is 70 m/s, angle of attack is 3°)

结合下文的噪声源定位结果可以看出，这部分噪声增量主要由襟翼边缘噪声增大引起。

5.6　机体噪声指向性分析

绘制巡航构型有起落架在迎角 3°、风速 70 m/s 下地面线阵指向性和 1/4 圆弧阵指向性，如图 21、图 22 所示。图中，各测量点的测试距离均换算到 7.5 m。可以看出，过顶噪声的总声压级最大值在 105°，而最小值在 65°，幅值差为 2.5 dB。边线噪声的指向性要比过顶噪声更为明显，在 10°～15°方向总声压级最强，在 90°方向总声压级最小，幅值差为 3.4 dB。

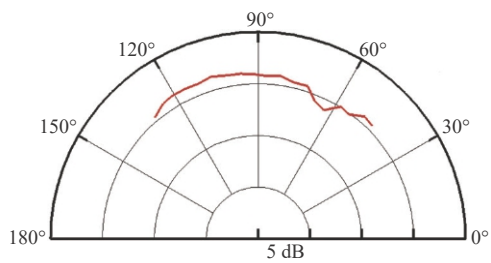


图 21　地面线阵指向性曲线

Fig. 21　Directionality curve of ground linear array

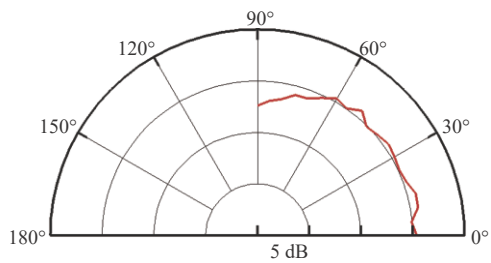


图 22　1/4 圆弧阵指向性曲线

Fig. 22　Directionality curve of 1/4 arc array

5.7　噪声源定位结果

采用经典波束形成算法对地面麦克风相位阵列的数据进行分析处理，得到了起飞构型（无起落架）和着陆构型（有起落架）在不同频段下的噪声源分布，如图 23 和图 24 所示。图中，声压级均为各

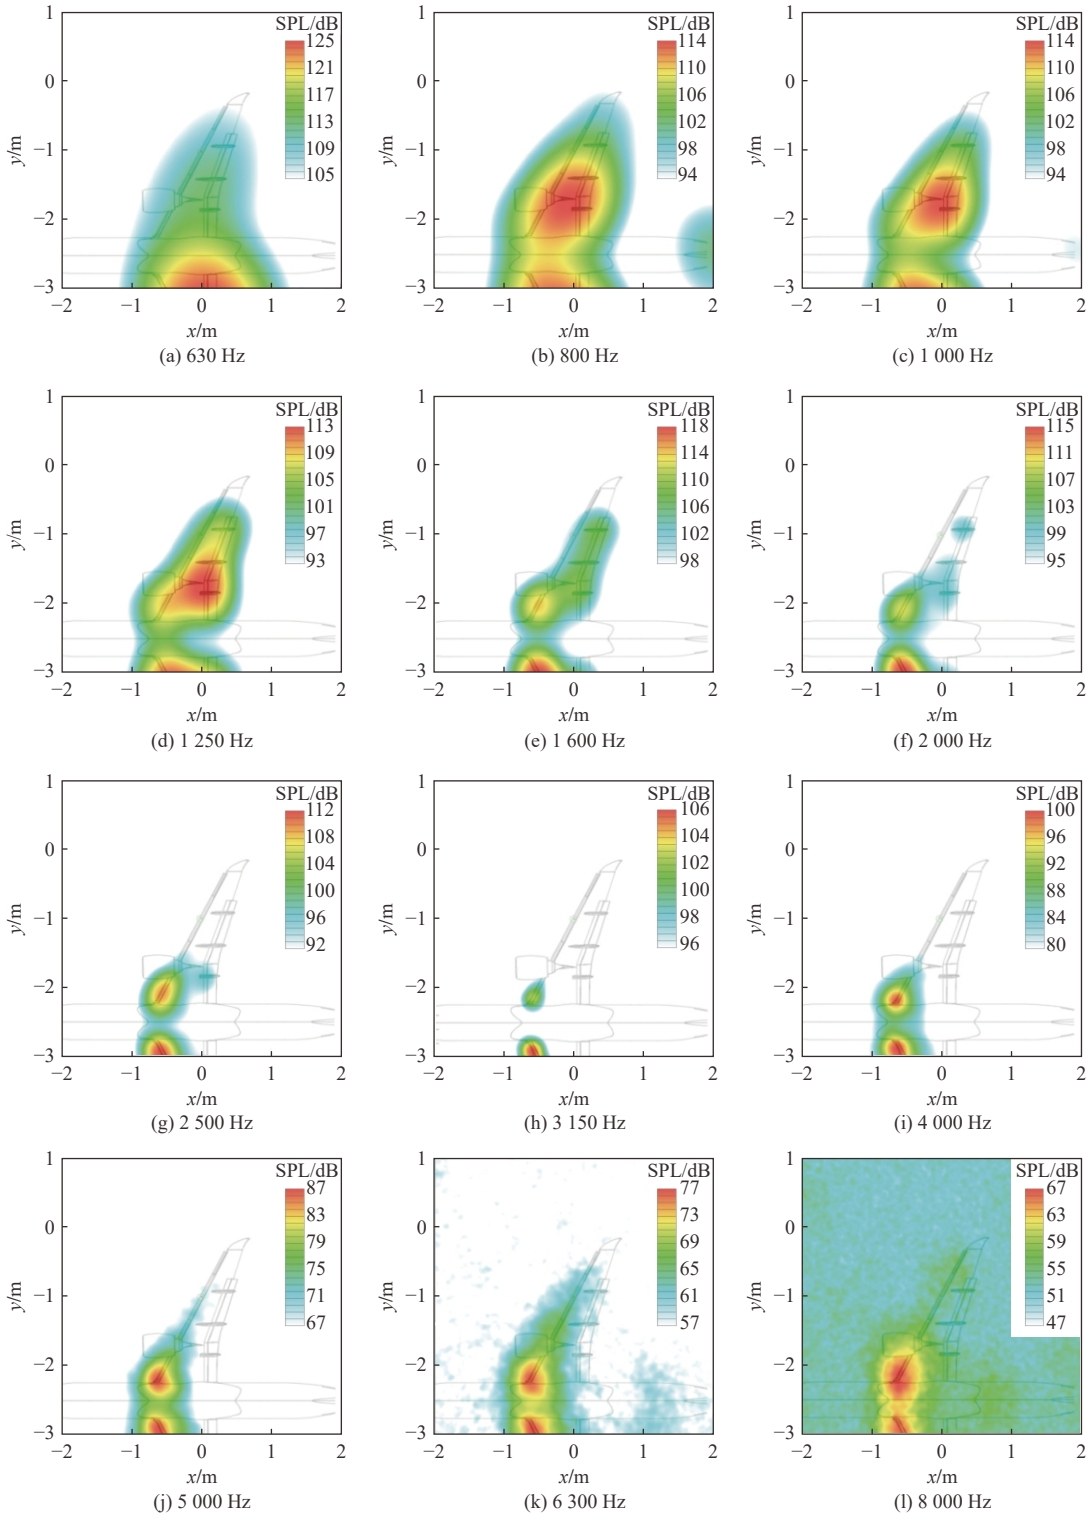


图 23 起飞构型噪声源定位结果(无起落架,风速 70 m/s,迎角 3°)

Fig. 23 Noise source localization results of takeoff configuration (without landing gear, wind speed is 70 m/s, angle of attack is 3°)

个中心频率对应频段的总声压,渲染范围均设置为20 dB。在 8 000 Hz 及以上频段,由于阵列动态范围的减小,导致在相同渲染范围内旁瓣增多,声源分布图像受到影响。

在起飞构型(无起落架)下,630～1 250 Hz 的噪声源主要分布在短舱及内侧襟翼区域,其中,短舱区域的噪声主要由增升装置和短舱的干扰引起。在 1 600 Hz 及以上频段,噪声源主要集中在内侧缝翼区域。同时,随着频率增加,外侧缝翼噪声源也逐渐显现出来。

在着陆构型(有起落架)下,630～1 250 Hz 的噪声源分布区域进一步扩展到主起落架和前起落架区域。由于襟翼偏度的增大,一方面内侧襟翼的噪声贡献增大,在 2 000～4 000 Hz 频段成为与缝翼噪

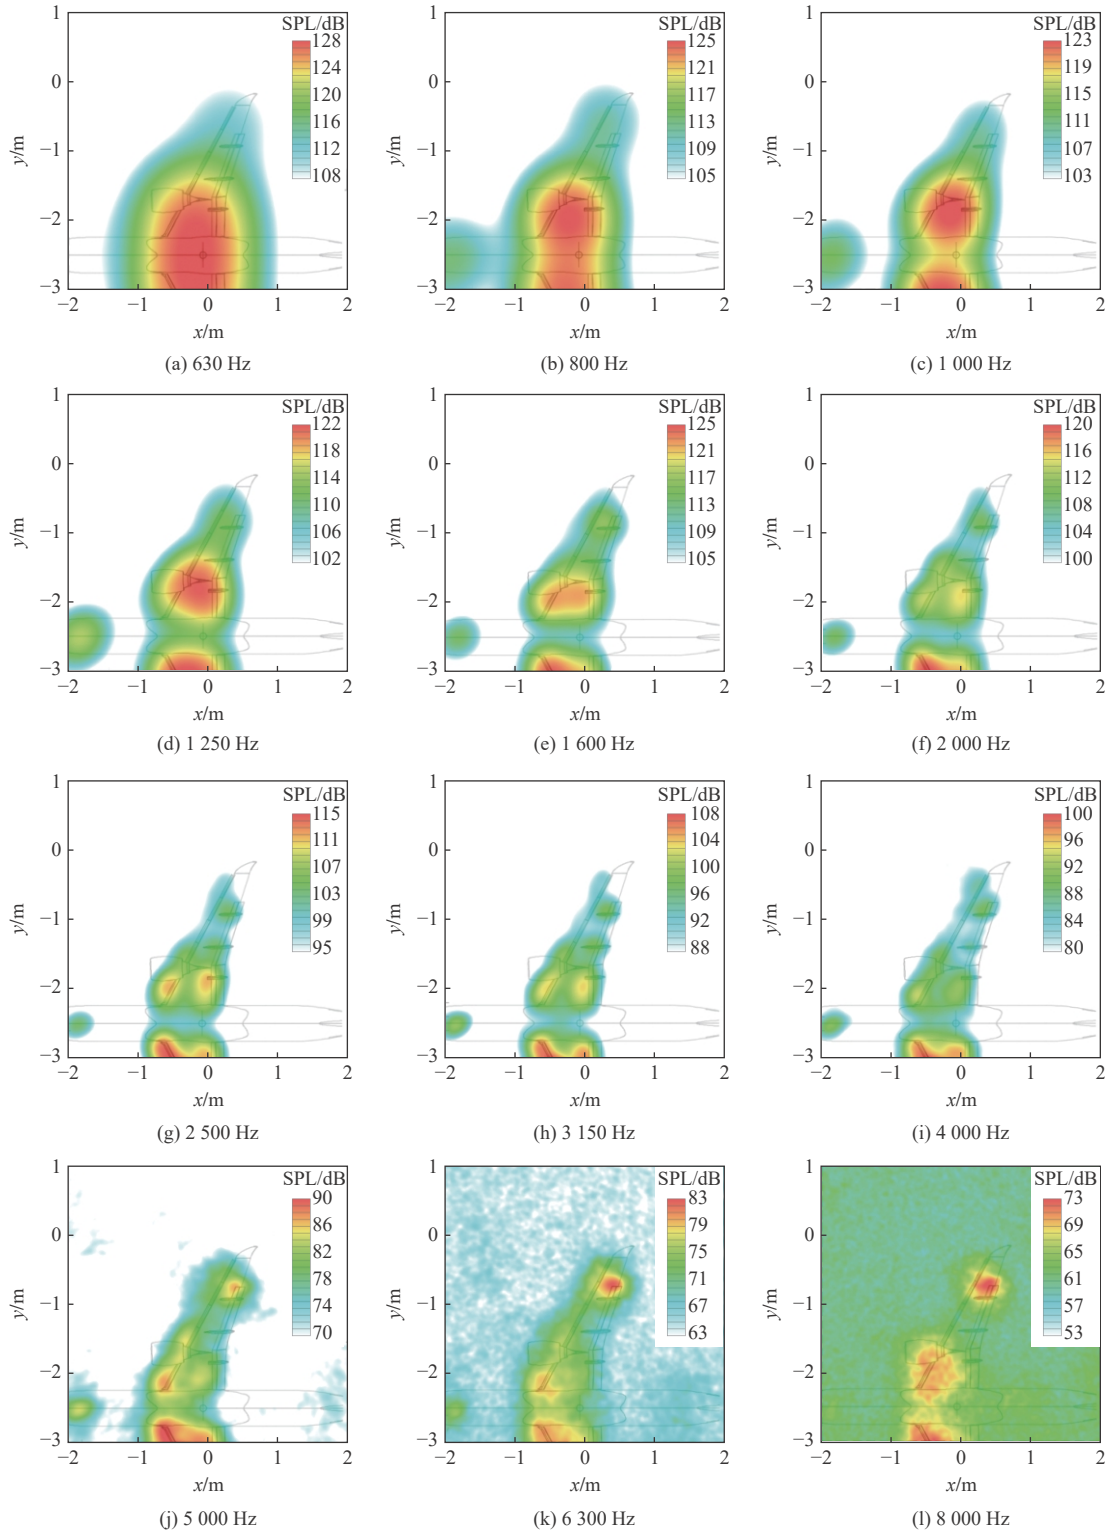


图 24　着陆构型噪声源定位结果(有起落架，风速 70 m/s，迎角 3°)

Fig. 24　Noise source localization results of landing configuration (without landing gear, wind speed is 70 m/s, angle of attack is 3°)

声幅值相近的声源；另一方面，大襟翼偏度下，由襟翼上下表面压差引起的上卷涡强度增大，与襟翼侧缘的相互作用增强，由此产生的襟翼侧缘噪声也显著增强，成为主要噪声源之一。由于襟翼边缘噪声对应的特征长度为襟翼边缘厚度，这部分噪声主要集中在高频段，在图 20 中的频谱曲线及图 24 中声源定位结果中均得以体现。

6　结　论

本文介绍了在 FL-10 大型低速风洞中开展民机大尺寸全机缩比模型气动噪声试验研究情况，以及试验所采用的风洞、支撑设备、模型、测试设备和数据处理与修正方法。通过试验研究了风速、迎角、起落架、襟翼偏度等对民机机体远场噪声的影

响，并分析了机体噪声源分布特性。结果表明：

1）机体噪声在不同频段满足不同的马赫数幂次律关系，在 St=1～4 范围内，幂次律系数约为 6.5，在 St=4～20 范围内，幂次律系数约为 5；在 St=20～200 范围内，幂次律系数约为 4。

2）迎角对起飞构型噪声的影响更明显，总声压级变化超过 1 dB，对着陆构型噪声的影响相对较小，噪声变化约为 0.3 dB。

3）机体噪声在过顶和边线方向均表现出指向性，且边线方向的指向性更强；起落架噪声与着陆构型下增升装置噪声量级接近，对飞机机体噪声的贡献相当。

4）增升装置与短舱的干扰在低频段引起了明显的噪声源分布；起飞构型下，缝翼是机体噪声的主要噪声源，尤其是靠近机身的内侧缝翼；着陆构型下，缝翼、起落架、襟翼是机体噪声的主要噪声源，在高频段外侧襟翼边缘噪声增加明显。

参考文献（References）

[1] Dobrzynski W. Almost 40 years of airframe noise research: what did we achieve?[J]. Journal of Aircraft, 2010, 47(2): 353-367.

[2] 李强, 陈迎春, 李亚林, 等. 民用飞机增升装置气动噪声学风洞试验初步研究[J]. 民用飞机设计与研究, 2013(3): 6-11.
Li Q, Chen Y C, Li Y L, et al. Preliminarily investigation on high lift system aerodynamic noise in wind tunnel tests of civil aircraft[J]. Civil Aircraft Design and Research, 2013(3): 6-11(in Chinese).

[3] 刘沛清, 李玲. 大型飞机增升装置气动噪声研究进展[J]. 民用飞机设计与研究, 2019(1): 1-10.
Liu P Q, Li L. Development of investigation on high-lift device noise for large aircrafts[J]. Civil Aircraft Design & Research, 2019(1): 1-10(in Chinese).

[4] Rackl R G, Miller G, Guo Y P, et al. Airframe noise studies-review and future direction: NASA/CR-2005-213767[R]. Washington, D. C. : NASA Langley Research Center, 2005.

[5] Dobrzynski W, Ewert R, Pott-Pollenske M, et al. Research at DLR towards airframe noise prediction and reduction[J]. Aerospace Science and Technology, 2008, 12(1): 80-90.

[6] Brooks T F, Humphreys W M. Flap-edge aeroacoustic measurements and predictions[J]. Journal of Sound and Vibration, 2003, 261(1): 31-74.

[7] 周国成, 谭啸, 陈宝. 襟翼边缘噪声的端板抑制技术试验研究[J]. 空气动力学学报, 2016, 34(3): 379-385.
Zhou G C, Tan X, Chen B. Experiment research of the noise reduction technology based on flap edge side fence[J]. Acta Aerodynamica Sinica, 2016, 34(3): 379-385(in Chinese).

[8] Humphreys W, Brooks T. Noise spectra and directivity for a scale-model landing gear[C]//Proceedings of the 13th AIAA/CEAS Aeroacoustics Conference. Reston: AIAA, 2007: 3458.

[9] Schmitz F H, Allmen J R, Soderman P T. Modification of the Ames 40- by 80-foot wind tunnel for component acoustic testing for the second generation supersonic transport: NASA-TM-108850[R]. Washington, D. C. : NASA Ames Research Center, 1994.

[10] Dobrzynski W, Chow L C, Smith M, et al. Experimental assessment of low noise landing gear component design[C]//Proceedings of the 15th AIAA/CEAS Aeroacoustics Conference. Reston: AIAA, 2009: 3276.

[11] Bergmann A. The aeroacoustic wind tunnel DNW-NWB[C]//Proceedings of the 18th AIAA/CEAS Aeroacoustics Conference. Reston: AIAA, 2012: 2173.

[12] 赵鲲, 梁俊彪, Kopiev Victor, 等. 基于大型声学风洞的飞行器起落架噪声试验研究[J]. 振动与冲击, 2022, 41(22): 160-172.
Zhao K, Liang J B, Victor K, et al. Experimental study on the aircraft landing gear noise in a large-scale aeroacoustic wind tunnel[J]. Journal of Vibration and Shock, 2022, 41(22): 160-172(in Chinese).

[13] Dobrzynski W, Gehlhar B, Buchholz H. Model and full scale high-lift wing wind tunnel experiments dedicated to airframe noise reduction[J]. Aerospace Science and Technology, 2001, 5(1): 27-33.

[14] Oerlemans S, Sijtsma P. Acoustic array measurements of a 1: 10.6 scaled airbus A340 model[C]//Proceedings of the 10th AIAA/CEAS Aeroacoustics Conference. Reston: AIAA, 2004: 2924.

[15] Horne W C, Burnside N J, Soderman P T, et al. Aeroacoustic study of a 26%-scale semi-span model of a Boeing 777 wing in the NASA Ames 40 by 80 feet wind tunnel: NASA/TP-2004-212802[R]. Washington, D. C. : NASA, 2004.

[16] Khorrami M R, Humphreys W M, Lockard D P, et al. Aeroacoustic evaluation of flap and landing gear noise reduction concepts[C]//Proceedings of the 20th AIAA/CEAS Aeroacoustics Conference. Reston: AIAA, 2014: 2478.

[17] 宋玉宝, 张俊龙, 唐道锋, 等. 大型飞机增升装置噪声特性风洞试验[J]. 空气动力学学报, 2022, 40(6): 14-28.
Song Y B, Zhang J L, Tang D F, et al. Wind tunnel experimental study of noise characteristics of large aircraft high-lift devices[J]. Acta Aerodynamica Sinica, 2022, 40(6): 14-28(in Chinese).

[18] 周国成, 陈宝, 李周复, 等. 大型航空声学风洞消声室建设与校测[J]. 应用声学, 2022, 41(6): 891-900.
Zhou G C, Chen B, Li Z F, et al. Anechoic chamber establishment and calibration of large scale aeroacoustic wind tunnel[J]. Journal of Applied Acoustics, 2022, 41(6): 891-900(in Chinese).

[19] Zhou G C, Bao A Y, Chen B, et al. An overview of aero-acoustic experimental technology in AVIC FL-10 wind tunnel[C]//Proceedings of the 33rd ICAS Congress. [S.l.]: ICAS, 2022.

[20] 范洁川. 风洞试验手册[M]. 北京: 航空工业出版社, 2002.
Fan J C. Handbook of wind tunnel test[M]. Beijing: Aviation Industry Press, 2002(in Chinese).

[21] Mueller T J. Aeroacoustic measurements[M]. Berlin: Springer, 2002.

[22] Amiet R. Correction of open jet wind tunnel measurements for shear layer refraction[C]//Proceedings of the 2nd Aeroacoustics Conference. Reston: AIAA, 1975: 532.

[23] 声学 户外声传播衰减 第 1 部分: 大气声吸收的计算[S]. GB/T 17247.1—2000.
Acoustics-attenuation of sound during propagation outdoors-Part 1: calculation of the absorption of sound by the atmosphere[S]. GB/T 17247.1—2000(in Chinese).

Experimental research on airframe noise of large-scale full-scaled civil aircraft model in wind tunnel

ZHOU Guocheng[1, 2, *]，SUN Yifeng[3]，BAO Anyu[1, 2]，DING Cunwei[1, 2]

(1. AVIC Aerodynamics Research Institute，Harbin 150001，China；
2. Aerodynamic Noise and Control Key Laboratory of Heilongjiang Province，Harbin 150001，China；
3. Shanghai Aircraft Design and Research Institute，COMAC，Shanghai 200135，China)

Abstract：Carrying out aero-acoustic experiments using a large scale model is an important means to accurately grasp the noise characteristics of civil aircraft airframes and validate the effectiveness of noise reduction strategies. The airframe noise experiment for a large-scale civil aircraft model is conducted in the 8 m × 6 m aero-acoustic wind tunnel using its associated measuring and support equipment. The ground linear array, 1/4 arc array, and horizontal microphone phase array are adopted to measure flyover noise, sideline noise and noise source distribution. The experimental equipment and methods adopted are introduced in this paper, and the influence of wind speed, angle of attack, and configuration on airframe noise is analyzed. According to the test results, civil aircraft airframe noise poses broadband characteristics; different Mach number scaling laws apply for different frequency ranges. The lift device and landing gear both contribute to the overall airframe noise. The airframe noise increases with angle of attack and flap deflection angle, and presents certain directionality in flyover and lateral directions. Source distribution of different configurations has significant differences, and the flap side edge noise becomes major noise source in the high frequency range at large flap deflection angles.

Keywords：civil aircraft; airframe noise; wind tunnel experiment; far field noise; source localization

Received：2024-09-05；**Accepted**：2024-11-14；**Published Online**：2024-12-04 08：50
URL：link.cnki.net/urlid/11.2625.V.20241203.0858.001

* **Corresponding author**. E-mail：zhougc@avic.com

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0545

基于情感表征校准的图文情感分析模型

张顺香[1,2,3,*]，刘佳佳[1,2]，焦熠璇[1,2]，张玉雷[1,2]，李自亮[1,2]

(1. 安徽理工大学 计算机科学与工程学院，淮南 232001；2. 合肥综合性国家科学中心人工智能研究院，合肥 230000；
3. 淮南师范学院 计算机学院，淮南 232038)

摘　　要：随着社交媒体用户更多地使用图文表达观点，挖掘多模态数据关联性以辅助分析用户情感成为挑战。目前的研究方法对模态间信息的交互不充分，且跨模态交互易引入噪声，导致学习到的图文表示出现情感表征偏移。为此，提出一种基于情感表征校准的图文情感分析模型。通过特征提取模块获取图文特征；在跨模态交互模块中，利用跨模态的注意力进行“图-文”和“文-图”2个方向上的双向交互，以充分利用模态间的互补信息，再通过门控校准模块过滤交互后特征中的噪声信息，来校准交互后图文表示的情感表征偏移；通过多头注意力融合图文特征进行情感识别。在2个公开的多模态数据集上进行实验，结果表明：所提方法优于CLMLF、MVCN等先进方法，能提高情感识别的准确性。

关 键 词：多模态；图文情感分析；跨模态交互；情感表征偏移；注意力机制
中图分类号：TP391.41
文献标志码：A　　**文章编号**：1001-5965(2026)11-3724-11

随着社交网络媒体的发展，人们拥有更多的方式去表达自己的情感，如同时发布图像和文字表达自己的情绪或观点[1]。多模态情感分析的目的是从多种模态的数据中分析出其中的情感，相较基于单一模态的情感分析，能够更准确地理解人们的情感表达，因此，受到越来越多的关注和研究[2]，并在情感跨模态检索[3]、观点挖掘[4]、图文匹配[5]等领域逐渐得到广泛应用。

本文的研究重点是识别图文评论中的情感。该任务需要根据图像和文本的内容，判断出该言论表达的情感。与单模态情感分析相比，基于图文的情感分析面临的主要挑战在于如何交互不同模态间的信息，以挖掘图文间的语义关联性。通常来说，图像和文本具有互补性，在用户表达情感时，只有同时结合图像和文本才能更好地理解其中的情感。

现有的图文情感分析方法中，许多研究将图像作为文本的附加信息，通过跨模态交互，利用图像帮助模型定位文本中的情感信息以用于情感识别，但这种单向的交互方式没有充分利用图文间的互补关系。同时，跨模态交互过程中，容易引入其他模态的冗余信息，导致交互结果含噪声，无法准确表征真实情感。这种情感表征的偏移，从空间上看，会导致模型学习到的图文特征向量与其他情感类别数据的特征向量混杂在一起，区分度不足，降低情感识别的效果。

为解决上述问题，本文提出一种基于情感表征校准的图文情感分析模型(sentiment representation calibration-based model for image-text sentiment analysis, SRC-Model)。首先，将图文对输入特征提取模块，获得重要的图像和文本表示，用于跨模态交互。然后，使用一种跨模态的注意力交互机制，在“图-文”和“文-图”2个方向上进行模态间的双向

收稿日期：2024-07-18；**录用日期**：2024-09-23；**网络出版时间**：2024-11-19 15:27
网络出版地址：link.cnki.net/urlid/11.2625.V.20241119.1312.002
基金项目：国家自然科学基金面上项目(62076006)；认知智能全国重点实验室开放课题(COGOS-2023HE02)；安徽高校协同创新项目(GXXT-2021-008)
* **通信作者**. E-mail：sxzhang@aust.edu.cn

引用格式：*张顺香，刘佳佳，焦熠璇，等. 基于情感表征校准的图文情感分析模型 [J]. 北京航空航天大学学报，2026，52（11）：3724-3734.*
Zhang S X，Liu J J，Jiao Y X，et al. Sentiment representation calibration-based model for image-text sentiment analysis[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：3724-3734（in Chinese）.

交互。该注意力机制结合图文模态的信息, 调整图文 2 个模态的注意力权重矩阵, 从而突出图像和文本中与情感表达有关的重要特征信息。针对交互结果可能出现的情感表征偏移, 进一步设计出一种简单有效的门控校准模块, 该模块基于门控机制过滤交互所得特征中的噪声, 提高交互后特征的情感表征能力。最后, 将图文特征输入多头注意力情感识别模块中, 进行特征融合和情感识别。在 2 个公开的基准数据集上进行的实验表明, 相较于先进的图文情感分析模型, SRC-Model 具有更加优越的性能表现。

综上, 本文的主要贡献如下:

1) 提出 SRC-Model, 通过跨模态的注意力机制进行图文信息间的双向交互, 从而利用二者的语义互补关系, 突出重要的情感特征信息, 增强图文表征能力。

2) 针对跨模态交互后的图文表示可能存在情感表征偏移的问题, 设计门控校准机制, 校准情感表征偏移, 提升模型情感识别的准确性。

1　相关工作

1.1　文本情感分析

早期的文本情感分析主要通过提取文本中包含的情感词来建立情感词典用于情感分析。Wiebe 等[6] 构建了大型语料库, 利用机器学习分类器建立基于情感的预测模型。但是, 这种依靠构建词典的情感分析方法, 其准确率受限于词典和规则集的完备性。

因此, 随着机器学习的发展, 情感分析方法也越来越多样化。Zhang 等[7] 根据情感强度将数据集分为强情感和弱情感 2 个子集, 使虚假评论失去隐蔽性, 再通过半监督的 PU 算法进行检测。此外, 也有工作结合无监督技术和情感词典, 研究评论中的情感特征及其相关规范[8]。

受深度学习模型在自然语言处理上的卓越性能的影响, Kim[9] 使用多通道卷积神经网络提取文本的 N-gram 特征, 并形成最终的句子表示, 以便进行分类。Wang 等[10] 引入树状长短期记忆模型表示语法属性的树结构网络拓扑, 从而深入挖掘文本语义特征。此外, 由于 Transformer[11] 结构的出现, 预训练模型在提取文本特征方面展现出了卓越的性能。以 BERT[12] 为代表的文本预训练模型在情感分析领域得到广泛应用。Dai 等[13] 基于 RoBERTa[14] 生成以情感词为导向的依存句法树, 应用在文本方面级情感分析中, 提升了情感分析的准确性。

1.2　图文情感分析

由于图文模态异质性带来的挑战, 如何对图文进行交互, 有效挖掘出其中的情感语义联系是迫待解决的研究难题。

传统多模态研究主要根据不同模态的分析结果得出最终决策。Liu 等[15] 通过独立为图像和文本建立情感分类器, 并根据各自的预测得分分配权重后相加, 来判断最终的情感倾向。这种方法忽略了图文之间的情感语义关联, 因此, Xu[16] 通过图像描述提取视觉语义特征, 作为文本的辅助信息分析情感表达。为了更充分地利用图像中的深层语义特征, Xu 等[17] 又提出了 MultiSentiNet, 通过识别图像中的对象和场景等显著特征, 辅助提取关键情感词汇, 并与视觉语义特征、对象和场景信息相结合进行情感识别。Huang 等[18] 提出以文本为中心的跨模态对齐方法, 得到文本中与情感分析任务相关的特征信息。

这些方法虽初步考虑了图文交互, 但忽略了图文模态彼此间的相互作用, 对图文间语义关系的利用不够充分。Yang 等[19] 通过注意力记忆网络模块对文本和图像特征进行交互式学习, 实现对图像和文本之间跨模态依赖关系的建模。Zhu 等[20] 使用跨模态注意力对齐图像的情感区域和文本单词, 充分探索图文间的交互作用。这种使用注意力的方式能够有效地进行图文交互。为了进一步探索图文间的关联性, Chen 等[21] 引入图像-文本相关性分类器, 解决图像和文本描述存在矛盾的情况。吴思思等[22] 通过自注意力融合多个模态的特征信息, 从而综合分析多模态上下文信息, 解决模态间的一致性和差异性问题。Li 等[23] 利用多层融合模块对齐和融合文本与图像特征, 学习多模态情感相关特征, 同时引入对比学习, 但该方法粒度较粗, 未充分考虑图像中大量的冗余视觉信息的存在。因此, Wei 等[24] 考虑视觉冗余信息的影响, 利用标签信息估计情感质心, 通过限制样本与质心间的距离来校准特征偏移, 但其简单地以文本为中心, 未考虑图像在情感表达中的重要作用。

以上工作未充分利用图像和文本之间的互补关系, 或忽视了跨模态交互过程会引入冗余信息, 这 2 种原因都会导致模态交互不够充分, 交互所得的图文特征对真实情感的表征不准确。因此, 本文在跨模态交互阶段利用跨模态的注意力交互机制进行图文间的双向交互, 该注意力在每个方向上都通过引入另一模态的信息调整当前模态的自注意力权重, 从而精细化地为图文中的情感特征信息加权, 获取在情感表达中具有一致性的信息。在注意力交互后, 通过门控校准模块, 过滤交互后特征中的噪声, 以提升其情感表征能力。

2 本文方法

如图1所示，本文提出的SRC-Model包括3个部分：特征提取、跨模态交互和情感识别。首先，在特征提取模块，通过预训练的BERT[12]和ResNet50[25]分别提取文本和图像的特征信息；然后，输入跨模态交互模块中，在“图-文”和“文-图”2个方向上，通过跨模态的注意力交互机制实现图文间的双向交互，并利用门控校准模块校准交互后可能出现的情感表征偏移；最后，将校准所得的图文表示输入情感识别模块，利用多头注意力进行特征融合，再实现情感识别。

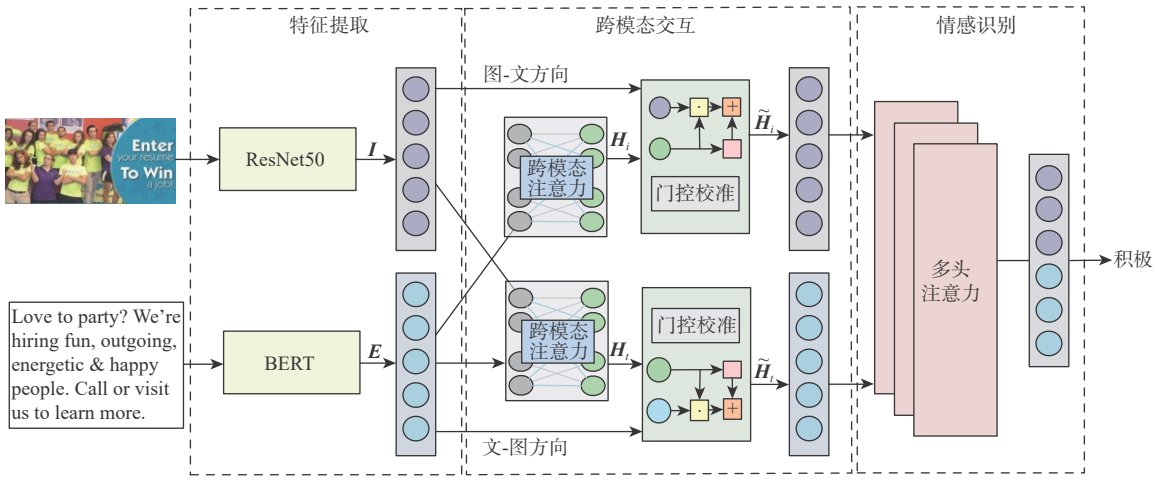


图1 SRC-Model结构

Fig. 1 Structure of SRC-Model

2.1 问题定义

图文情感分析的目的是根据用户发布的图像和文本预测其情感倾向。给定一个图文对(T,M)，图文对中句子$T=\{t_1,t_2,\cdots,t_n\}$，t_i为句子T的第i个词，M为文本T对应的一张图像。模型根据输入的图文对预测出该图文对表达的情感极性。

2.2 特征提取

为获得图文交互所需的图像和文本特征，本文使用2种不同的单模态编码器来提取其特征。

1）文本特征提取。BERT是一种基于Transformer的预训练语言模型，能够理解文本中的复杂语义关系。因此，本文使用预训练的BERT模型作为文本模态的编码器。

对于给定的图文对中的文本，将其最大长度设置为n，超过长度的部分截断，不足的补零。输入BERT模型中，编码为向量化的文本表示$\boldsymbol{E}$：

$$\boldsymbol{E}=\{\boldsymbol{e}_1,\boldsymbol{e}_2,\cdots,\boldsymbol{e}_n\}=\mathrm{BERT}(T)\in\mathbf{R}^{n\times d_t} \tag{1}$$

式中：n为文本的最大长度；d_t为BERT输出的词向量维度，d_t=768；$\boldsymbol{e}_i\in\mathbf{R}^{d_t}$为第$i$个单词经BERT编码后的词向量。

2）图像特征提取。ResNet是一种深度卷积神经网络，通过残差连接解决梯度消失问题，从而构建更深层的网络结构，捕获视觉特征。因此，本文使用预训练的ResNet50作为图像模态的编码器。

首先，将图像转换成224像素×224像素的尺寸，输入预训练的ReNet50模型中，将其最后一个卷积层得到的特征图$\boldsymbol{I}'$作为输出：

$$\boldsymbol{I}'=\mathrm{ResNet50}(M)\in\mathbf{R}^{p\times p\times 2\,048} \tag{2}$$

式中：p为特征图的高度和宽度，p=7；2 048为特征图的维度。该特征图$\boldsymbol{I}'$具有$p\times p$个视觉块，每个视觉块由一个2 048维的向量表示。

为将三维特征图表示矩阵转换为与文本一致的二维表示矩阵，以用于注意力交互，先通过全连接层降低特征图中每个视觉块的维度，避免过高的维度带来的计算负担，再通过Trans( )操作得到用于注意力交互的图像表示。Trans( )操作包括：先重塑特征图$\boldsymbol{I}'$，参考Li等的工作[23]，将形状为$p\times p\times 2\,048$的特征图的前2个维度展平成1个维度，得到由p^2个视觉块向量组成的图像表示$\tilde{\boldsymbol{I}}\in\mathbf{R}^{p^2\times d_i}$；再通过拼接零向量，使视觉块的数目与文本的最大长度相同，均为n，以用在后续的注意力交互中。表示如下：

$$\boldsymbol{I}=\mathrm{Trans}(\boldsymbol{I}'\boldsymbol{W}_{\boldsymbol{I}'}+\boldsymbol{b}_{\boldsymbol{I}'})=\{\boldsymbol{i}_1,\boldsymbol{i}_2,\cdots,\boldsymbol{i}_n\}\in\mathbf{R}^{n\times d_i} \tag{3}$$

式中：$\boldsymbol{W}_{\boldsymbol{I}'}$和$\boldsymbol{b}_{\boldsymbol{I}'}$为全连接层的可训练参数；$d_i=40$。

2.3 跨模态交互

2.3.1 跨模态注意力机制

不同模态的数据具有独特的情感信息，表达情感时又能互为补充，相互促进。用户在表达情感时，可能情感色彩更加偏向于图像，也可能更加偏

向于文本, 因此, 设计有效的方式去探索二者相互间的互补关系能够捕获更多、更准确的情感信息。本文通过一种跨模态注意力实现“图-文”和“文-图”2 个方向上的交互。该注意力机制引入另一方向上模态的信息, 来调整当前方向上模态的自注意力矩阵, 以利用模态间的互补关系关注在情感上具有联系的情感特征信息。经过注意力交互后的图像和文本表示, 既通过自注意力关注模态内部的特征信息, 又能捕获图文模态间的共性。

跨模态注意力应用在文本引导的“文-图”和图像引导的“图-文”2 个方向上。以“文-图”方向为例, 如图 2 所示。

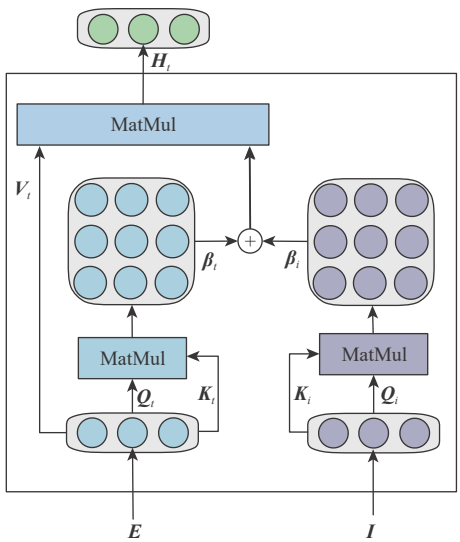


图 2　文-图方向上的跨模态注意力

Fig. 2　Cross-modal attention in text-to-image direction

对于文本模态, 定义注意力机制的 query 和 key 为文本的特征提取结果: $\boldsymbol{Q}_t = \boldsymbol{K}_t = \boldsymbol{E}$。对于图像模态, 定义注意力机制的 query 和 key 为图像的特征提取结果: $\boldsymbol{Q}_i = \boldsymbol{K}_i = \boldsymbol{I}$。分别计算文本和图像的自注意力分数矩阵, 文本自注意力分数矩阵$\boldsymbol{\beta}_t$和图像自注意力分数矩阵$\boldsymbol{\beta}_i$的计算过程如下:

$$\boldsymbol{\beta}_t = \mathrm{ReLU}\left(\boldsymbol{Q}_t \boldsymbol{K}_t^{\mathrm{T}}\right) \tag{4}$$

$$\boldsymbol{\beta}_i = \mathrm{ReLU}\left(\boldsymbol{Q}_i \boldsymbol{K}_i^{\mathrm{T}}\right) \tag{5}$$

为通过图文间的交互动态地调整文本中不同特征信息的权重, 受到 Yang 等[26] 在语音文本工作上的启发, 本文对文本自注意力分数矩阵$\boldsymbol{\beta}_t$和图像自注意力分数矩阵$\boldsymbol{\beta}_i$进行求和, 得到加权融合后的文本注意力分数矩阵$\boldsymbol{A}_t$。

$$\boldsymbol{A}_t = \boldsymbol{\beta}_t \boldsymbol{W}_{tt} + \boldsymbol{\beta}_i \boldsymbol{W}_{ti} + \boldsymbol{b}_{ti} \tag{6}$$

式中: $\boldsymbol{W}_{tt}$、$\boldsymbol{W}_{ti}$和$\boldsymbol{b}_{ti}$为加权融合计算的可训练参数。

将加权融合后得到的文本自注意力分数矩阵$\boldsymbol{A}_t$经过 Softmax 函数得到注意力权重矩阵, 为文本特征表示$\boldsymbol{E}$的不同特征赋予权重, 突出重要的情感信息, 计算出“文-图”方向上经过跨模态注意力交互后的输出$\boldsymbol{H}_t$, 如下:

$$\boldsymbol{H}_t = \mathrm{Softmax}\left(\boldsymbol{A}_t\right)\boldsymbol{E} \tag{7}$$

同理, 经过在“图-文”方向上的跨模态注意力, 得到图像在交互后的输出$\boldsymbol{H}_i$。

2.3.2　门控校准

跨模态交互易引入不同模态的冗余信息, 导致输出结果中含噪声。由于受到噪声信息的掩盖, 跨模态注意力的输出$\boldsymbol{H}_t$和$\boldsymbol{H}_i$中, 情感特征信息不能很好地表达, 因而产生情感表征偏移。为解决该问题, 一种可行的方式是从未经交互的原始图文表示($\boldsymbol{E}$和$\boldsymbol{I}$)中获取信息来增强情感特征的表达。因此, 本文利用门控机制去校准跨模态注意力的输出可能存在的情感表征偏移。

以图 3 中“文-图”方向上的门控校准模块的结构为例:

$$\boldsymbol{g}_t = \sigma\left(\boldsymbol{H}_t \boldsymbol{W}_{\mathrm{g}}\right) \tag{8}$$

$$\boldsymbol{H}'_t = \boldsymbol{g}_t \odot \boldsymbol{H}_t + (\boldsymbol{O} - \boldsymbol{g}_t) \odot \boldsymbol{E} \tag{9}$$

式中: σ表示 Sigmoid 函数; $\boldsymbol{W}_{\mathrm{g}}$为可训练参数; $\odot$表示矩阵间的逐元素乘法; $\boldsymbol{g}_t$为门控值; $\boldsymbol{O}$为全 1 矩阵。当$\boldsymbol{g}_t$值较高时, 说明$\boldsymbol{H}_t$中含有较少的噪声, 门控会偏向于来自跨模态注意力交互后的文本信息, 因此给出更高的门控值, 当$\boldsymbol{g}_t$值较低时, 说明$\boldsymbol{H}_t$中含有较多的噪声, 在一定程度上掩盖了情感特征的表达, 门控会偏向于来自跨模态注意力交互前的文本信息, 因此给出较低的门控值。根据门控值的动态调控, 模型可以在跨模态注意力的输出$\boldsymbol{H}_t$存在较多噪声时, 更多地选择$\boldsymbol{E}$中的低噪信息融合进来, 从而过滤噪声, 加强$\boldsymbol{H}_t$中情感特征的表达, 以校准情感表征偏移。经过该计算, 得到校准了情感表征偏移的文本特征表示$\boldsymbol{H}'_t$。

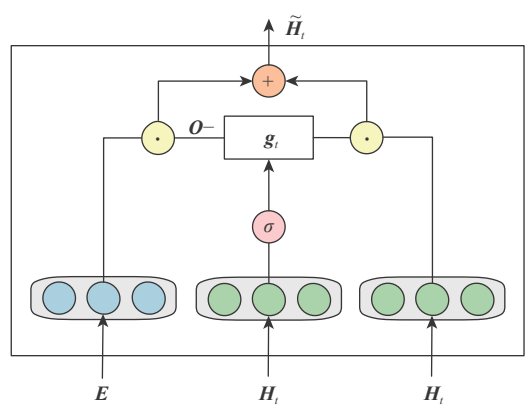


图 3　文-图方向上的门控校准模块

Fig. 3　Gated calibration module in text-to-image direction

进一步，为保证值的区间稳定，将$\boldsymbol{H}_t'$归一化，如下：

$$\tilde{\boldsymbol{H}}_t = \mathrm{ReLU}\left(\boldsymbol{H}_t'\boldsymbol{W}_c + \boldsymbol{b}_c\right) \tag{10}$$

式中：$\boldsymbol{W}_c$、$\boldsymbol{b}_c$为可训练参数。

经过式(8)～式(10)，得到跨模态交互模块最终输出的文本特征表示$\tilde{\boldsymbol{H}}_t$。

与上述在“文-图”方向上计算原理一致，可以获得在“图-文”方向上经过门控校准模块的图像特征表示$\tilde{\boldsymbol{H}}_i$。

2.4 情感识别

为使用图文中的情感特征信息进行情感识别，将跨模态交互输出的图像和文本特征拼接在一起，作为情感识别阶段的输入。

$$\boldsymbol{F} = \left[\tilde{\boldsymbol{H}}_t;\tilde{\boldsymbol{H}}_i\right] \tag{11}$$

式中：[;]表示拼接操作；$\boldsymbol{F}$为包含全部情感信息的图文情感特征表示。

由于图像和文本中的不同情感特征信息在表达情感时的贡献不同，不适合直接用来进行情感识别，因此，参考Du等的工作[27]，本文使用多头自注意力对图文特征进行融合，来分析不同特征之间的关系用于情感识别。$\boldsymbol{F}_x$是$\boldsymbol{F}$在多头注意力中每个头的输入，公式如下：

$$\boldsymbol{Q}_j = \boldsymbol{F}_x\boldsymbol{W}_{\boldsymbol{Q}_j} + \boldsymbol{b}_{\boldsymbol{Q}_j} \tag{12}$$

$$\boldsymbol{K}_j = \boldsymbol{F}_x\boldsymbol{W}_{\boldsymbol{K}_j} + \boldsymbol{b}_{\boldsymbol{K}_j} \tag{13}$$

$$\boldsymbol{V}_j = \boldsymbol{F}_x\boldsymbol{W}_{\boldsymbol{V}_j} + \boldsymbol{b}_{\boldsymbol{V}_j} \tag{14}$$

式中：$\boldsymbol{W}_{\boldsymbol{Q}_j}$、$\boldsymbol{W}_{\boldsymbol{K}_j}$、$\boldsymbol{W}_{\boldsymbol{V}_j}$为全连接层的权重矩阵，$\boldsymbol{b}_{\boldsymbol{Q}_j}$、$\boldsymbol{b}_{\boldsymbol{K}_j}$、$\boldsymbol{b}_{\boldsymbol{V}_j}$为偏置项，均为可训练参数，$j$为多头注意力的第$j$个头，本文将多头个数设置为8。

多头注意力每个头都进行相同的注意力计算，其中，注意力的计算公式如下：

$$\mathrm{Attention}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V}) = \mathrm{Softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}}}{\sqrt{d_k}}\right)\boldsymbol{V} \tag{15}$$

通过上述多头注意力计算公式，可以计算出每个头的注意力结果，如下：

$$\boldsymbol{u}_j = \mathrm{Attention}\left(\boldsymbol{Q}_j,\boldsymbol{K}_j,\boldsymbol{V}_j\right) \tag{16}$$

得到每个头的注意力计算结果$\boldsymbol{u}_j$后，将其拼接起来，得到图文联合特征$\boldsymbol{U}'$，如下：

$$\boldsymbol{U}' = \mathrm{concat}(\boldsymbol{u}_1,\boldsymbol{u}_2,\cdots,\boldsymbol{u}_{\mathrm{num}}) \tag{17}$$

为充分利用图文联合特征$\boldsymbol{U}'$的所有特征信息去计算不同类别下的情感预测概率，将$\boldsymbol{U}'$展开得到一个高维向量，再通过全连接层映射到不同情感类别的目标空间，得到预测情感向量，公式如下：

$$\boldsymbol{U} = \mathrm{flatten}(\boldsymbol{U}') \tag{18}$$

$$\boldsymbol{Y} = \mathrm{Tanh}\left(\boldsymbol{U}\boldsymbol{W}_f + \boldsymbol{b}_f\right) \tag{19}$$

式中：flatten( )表示展平操作；$\boldsymbol{W}_f$和$\boldsymbol{b}_f$为全连接层的可训练参数；Tanh为激活函数；s为标签数目；$\boldsymbol{Y} \in \mathbf{R}^s$为映射到$s$个情感类别空间的预测情感向量。

使用Softmax计算不同情感类别的预测概率$\boldsymbol{\delta}$，具体公式如下：

$$\boldsymbol{\delta} = \mathrm{Softmax}(\boldsymbol{Y}) \in \mathbf{R}^s \tag{20}$$

取$\boldsymbol{\delta}$中最高预测概率值的索引为预测标签，如下：

$$p_t = \mathrm{argmax}(\boldsymbol{\delta}) \tag{21}$$

由于数据的类别不平衡会导致模型无法充分学习少类别样本的信息，损失函数使用Focal Loss[28]，使模型更加关注难分类的少类别样本。Focal Loss公式如下：

$$L = -\alpha_t(1-p_t)^{\gamma}\ln p_t \tag{22}$$

式中：p_t为模型预测的结果；α_t为类别权重系数，是可训练参数；γ为可调节因子，默认为2；L为计算到的损失值。

3 实验结果与分析

3.1 数据集

本文在2个公开的多模态数据集[29]上进行实验：MVSA-Single和MVSA-Multiple。2个数据集的样本均是从Twitter上爬取到的图文评论。MVSA-Single包括5 129个图文对，每个图文对由单个注释者分别标注为积极、中性或消极情感标签。而MVSA-Multiple则包括19 600个图文对，每个图文对由3个注释者独立标注情感标签。

由于图文标签存在不一致，本文采取与文献[24]相同的预处理策略。对于MVSA-Single数据集，若图像和文本的标签感情极性相反，则舍弃该条数据；若其中一方为中性，则采用另一方标签作为该图文对的最终情感标签。对于MVSA-Multiple数据集，则选择出现次数最多的注释标签作为图文对的最终情感标签。处理好的数据集中每个标签数据个数的统计信息如表1所示。

表1 MVSA数据集数据

Table 1 Statistics of MVSA datasets

数据集	积极	中性	消极	总计
MVSA-Single	2 683	470	1 358	4 511
MVSA-Multiple	11 318	4 407	1 299	17 024

3.2 实验细节

3.2.1 参数设置

所有代码均在pytorch框架下完成，模型的训

练在一块 3080Ti GPU 上进行。对数据集按照 8∶1∶1 的比例拆分为训练集、验证集和测试集。

BERT 的词嵌入维度为 768。由于数据集文本属于短评, 大部分文本长度处于 50 以内, 因此, 最大文本长度设置为 50。所有图像均转换为 224 像素×224 像素的三通道 RGB 图像, 输入 ResNet50 中。模型使用 Adam 优化器更新参数。多头注意力的头数为 8。其余有关参数设置如表 2 所示。

表 2　参数设置

Table 2　Parameter settings

数据集	批大小	学习率	权重衰减系数	训练轮数	γ
MVSA-Single	16	1×10^{-5}	1×10^{-4}	10	2
MVSA-Multiple	32	8×10^{-5}	1×10^{-4}	10	2

3.2.2　评价指标

对模型的评价指标, 同 Wei 等[24] 的工作一致, 使用准确率和 Weighted-F1 作为评价指标, 其中, 准确率和 F_1 定义如下:

$$A=\frac{T_P+T_N}{T_P+T_N+F_P+F_N} \tag{23}$$

$$P=\frac{T_P}{T_P+F_P} \tag{24}$$

$$R=\frac{T_P}{T_P+F_N} \tag{25}$$

$$F_1=\frac{2PR}{P+R} \tag{26}$$

式中: T_P、T_N、F_P、F_N分别表示真正例的数量、真负例的数量、假正例的数量、假负例的数量。Weighted-F1 即对每个类别的 F_1 值进行加权平均, 每个类别的权重为该类别样本占全部样本数量的比重。

3.3　对比实验

3.3.1　对比模型

为对比模型在图文情感分析上的表现, 本文选择以下具有代表性的对比模型在 MVSA-Single 和 MVSA-Multiple 数据集上进行对比。

1) BERT[12]: 一种基于 Transformer 架构的预训练语言模型, 经过微调用于文本情感分析。

2) ResNet50[25]: 一种深度残差网络结构, 经过微调进行基于图像的情感分析。

3) Vision Transformer (ViT)[30]: 一种基于 Transformer 的视觉感知模型, 在图像分类等任务上具有出色的能力, 因此用于基于图像的情感分析。

4) HSAN[16]: 一种基于图像描述的分层语义注意力网络。对于输入的图像-文本对, 使用图像描述提取视觉语义特征, 作为文本的附加信息。

5) MultiSentiNet[17]: 从图像中提取物体和场景作为视觉语义信息, 通过注意力引导提取文本重要单词, 将所有的视觉和语义特征聚合在一起进行预测。

6) Co-MN-Hop6[31]: 迭代地对图文交互进行建模, 即利用文本查询图像中的关键信息, 并利用图像信息来定位文本重要词语。

7) MGNNS[32]: 用于图像文本情感识别的多通道图神经网络, 通过多通道图神经网络学习多模态数据集的全局特征。

8) CLMLF[23]: 通过基于标签和数据的对比学习对齐和融合文本和图像模态, 提高模型提取和融合多模态数据特征的能力。

9) MVCN[24]: 文本引导的融合模块, 基于情感的一致性约束和用于多模态情感识别的自适应损失校准策略, 以系统地解决来自不同视图的模态异构问题。

3.3.2　对比实验结果及分析

将本文模型与 3.3.1 节对比模型在 2 个基准数据集上进行对比, 结果如表 3 所示。可知, 在 MVSA-Single 数据集上, SRC-Model 性能优于其他的对比模型, 准确率为 78.32%, Weighted-F1 值为 76.79%, 较 SOTA 模型 MVCN 分别提高了 2.26% 和 2.24%; 在 MVSA-Multiple 数据集上, SRC-Model 的准确率为 72.81%, Weighted-F1 值为 70.13%, 较先进模型 MVCN 分别提高了 0.74% 和 0.12%。这主要是因为: MVCN 将图像作为文本的附加信息, 利用图像模态增强文本模态的表示。这种方式对图文间的互补关系利用不足, 因此交互不够充分。而本文通过跨模态的注意力进行图文间的双向交互, 并利用门控校准机制对交互结果中的噪声进行过滤, 能够充分利用模态间的互补关系增强每个模态的情感表征能力。

与单模态模型 BERT、ResNet50 和 ViT 相比, SRC-Model 在 2 个基准数据集上的对比指标均提高了约 10%。仅仅基于单个模态(如文本或图像), 难以有效针对用户的多元化表达方式分析其情感倾向, 因此, 结合图文的多模态模型整体上的实验结果均优于单模态模型。同时也可以发现, 基于文本的模型在情感识别时的效果优于基于图像的模型, 这种实验结果在一定程度上可以表明, 文本中的情感信息比图像更为丰富, 反映真实情感的能力更强。

与 MultiSentiNet 和 HSAN 模型相比, SRC-Model 在 MVSA-Single 数据集上的准确率和 Weighted-F1 值均提升了近 10%, 在 MVSA-Multiple 数据集上的准确率和 Weighted-F1 值均提升了约 5%。以上 2 个模型均采用了图文间的单向交互机制, 即将图像作为文本的附加信息, 利用图像增强文本模态的

表3 不同模型在MVSA-Single和MVSA-Multiple数据集上的对比实验结果

Table 3 Comparative experimental results of different models on MVSA-Single and MVSA-Multiple datasets

模态	模型	准确率/%		Weighted-F1/%	
		MVSA-Single	MVSA-Multiple	MVSA-Single	MVSA-Multiple
文本	BERT[12]	72.35	67.70	70.81	67.10
图像	ResNet50[25]	67.04	62.83	64.41	60.94
	ViT[30]	67.92	65.12	67.88	62.99
多模态	HSAN[16]	69.88	67.96	66.90	67.76
	MultiSentiNet[17]	69.84	68.86	69.63	68.11
	Co-MN-Hop6[31]	70.51	68.92	70.01	68.83
	MGNNS[32]	73.77	72.49	72.70	69.34
	CLMLF[23]	75.33	72.00	73.46	69.83
	MVCN[24]	76.06	72.07	74.55	70.01
	SRC-Model(本文)	78.32	72.81	76.79	70.13

情感表达信息,这种方法忽视了图文在情感表达时具有相互补充的关系,因此对图像中表达的情感信息利用不足。

与Co-MN-Hop6、MGNNS和CLMLF模型相比,SRC-Model在2个数据集上均具有优势。这3种模型直接对图文数据进行交互和融合,在结合图文进行挖掘情感信息的同时,也会引入更多的冗余信息,这使得模型较难准确聚焦于重点的信息上。而本文通过跨模态注意力和门控校准机制建立起图文间的双向交互,不仅能够有效地利用图文间的互补关系挖掘情感信息,并且过滤了交互结果的噪声,准确获取图文中的重要情感信息,为情感分析提供有力支撑。

3.4 消融实验

本文在MVSA-Single和MVSA-Multiple数据集上对模型进行了消融实验,进一步评估了模型的不同组成模块对情感识别的贡献程度。具体实施方案如下:

1) BERT: 仅基于文本模态,使用BERT模型进行情感识别。

2) ResNet50: 仅基于图像模态,使用ResNet50进行情感识别。

3) SRC+M: 分别独立地使用BERT和ResNet50提取文本和图像的特征,利用多头注意力融合图文特征,再预测情感标签。

4) SRC+M+A: 在SRC+M的基础上添加跨模态注意力交互模块,进行图像和文本间的双向交互。

5) SRC-TI: 在SRC+M+A的基础上添加门控校准模块,并且仅实现“文-图”方向的交互。

6) SRC-Model(本文模型): 在SRC+M+A的基础上添加门控校准模块,进行图文间双向交互。

由表4、表5可以看出:

1) SRC+M在2个数据集上的准确率和Weighted-F1值都高于独立处理文本和图像的BERT和ResNet50模型,说明加入的多头注意力能够有效整合图像和文本中的情感信息。

2) SRC+M+A相比SRC+M,在2个数据集上的指标均有所提升,主要是因为:跨模态注意力能够捕捉图文模态间的情感联系,从而准确地发现图文中的情感特征信息。

3) SRC-Model相比SRC+M+A有进一步的提升,这表明加入门控校准模块能够提升跨模态交互的效果。主要原因在于:门控校准模块可以通过门控机制自适应地增强跨模态注意力输出中的情感特征信息,从而过滤掉噪声的影响,校准情感表征偏移。

表4 MVSA-Single数据集上的消融实验结果

Table 4 Ablation results on MVSA-Single dataset

模型	准确率/%	Weighted-F1/%
BERT	72.35	70.81
ResNet50	67.04	64.41
SRC+M	74.56	74.54
SRC+M+A	76.33	76.07
SRC-TI	77.21	76.72
SRC-Model	78.32	76.79

表5 MVSA-Multiple数据集上的消融实验结果

Table 5 Ablation results on MVSA-Multiple dataset

模型	准确率/%	Weighted-F1/%
BERT	67.70	67.10
ResNet50	62.83	60.94
SRC+M	69.41	67.47
SRC+M+A	71.99	67.89
SRC-TI	72.58	68.72
SRC-Model	72.81	70.13

4) SRC-Model 的 2 个评测指标值要优于 SRC-TI, 这是因为 SRC-TI 仅采取了“文-图”方向上的单向交互, 这种利用图像增强文本的方法并不能很好地利用图文间的互补性, 因此性能不足。

总体而言, SRC-Model 通过跨模态注意力机制进行图文间的双向交互, 可以引入模态间的互补关系, 从而发现图像和文本中与情感相关的特征信息。此外, 门控校准机制的引入解决了注意力交互结果可能含噪声产生的情感表征偏移问题。因此, SRC-Molde 充分探索了模态间的交互作用, 实验结果也验证了本文方法在情感识别任务上的有效性。

3.5　注意力头数分析

为探究不同多头注意力头数对实验的影响, 根据以往工作[11]将头数设置为 1、4、8、12、16。在 MVSA-Single 数据集上进行实验, 结果如图 4 所示。

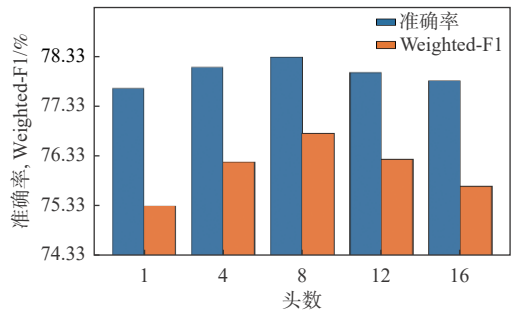


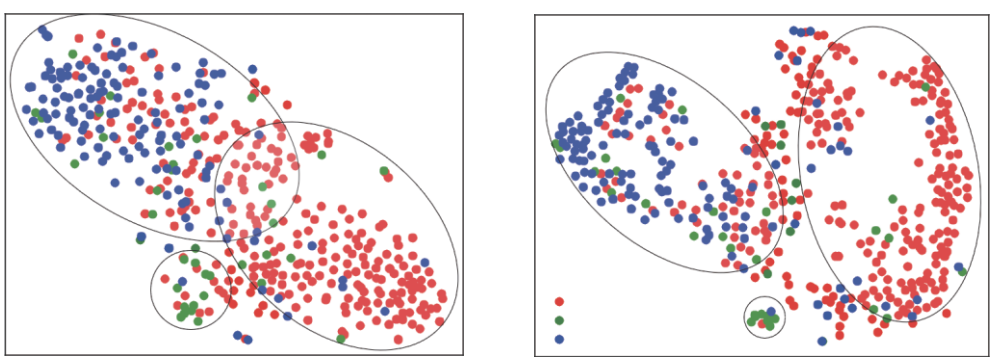
图 4　注意力头数对准确率和 Weighted-F1 值的影响

Fig. 4　Effect of attention heads on accuracy and Weighted-F1

通过观察可知, 注意力头数为 8 时, 模型的性能最优。注意力头数大于 8 时, 效果逐渐下降。说明增加注意力头数可以较好地融合图像和文本特征, 这是因为头数增加, 模型可以从更多的子语义空间关注图文内容与情感具有联系的相关特征信息。但注意力头数过多时, 也会导致语义空间过于碎片化, 使模型更容易记住一些不重要的信息, 造成注意力分散, 导致每个头无法捕捉到有价值的信息片段, 使得模型整合来自每个注意力头的信息时效果不理想。因此, 在利用多头注意力融合图像和文本信息时, 需要合适的头数设置, 模型才能更好地学习图文模态间的复杂关系, 从而提升对情感的识别能力。

3.6　特征分布可视化

为验证门控校准模块是否校准了图文特征的情感表征偏移, 本文设计了直观的可视化实验观察这一现象。在 MVSA-Single 数据集上, 运用 TSNE 降维算法对跨模态交互模块输出的特征向量进行了可视化分析。图 5(a)为去除门控校准模块后的可视化结果, 图 5(b)为添加门控校准模块后的可视化结果。



(a) 去除门控校准模块后的可视化结果　　(b) 添加门控校准模块后的可视化结果

图 5　特征分布可视化

Fig. 5　Feature distribution visualization

通过对比可以发现, 模型加入门控校准模块后, 跨模态交互得到的图文特征表示向量有明显的聚合趋势, 情感表征能力得到提高。具体分析如下: 图像和文本中客观存在大量与情感识别无关的特征, 被引入到交互过程, 导致交互到的图文特征向量中存在噪声, 无法准确地表征情感。因此, 相同情感类别数据的特征向量在空间中分布更为分散, 不同情感类别数据的特征向量混淆程度较高。然而, 在引入门控校准模块后, 由于对交互后结果中的噪声进行了过滤, 其中的情感信息得到增强, 各类别样本数据的特征向量区分度明显提高, 数据的聚合效果得到增强, 因此, 校准情感表征偏移能够优化不同情感类别数据的特征向量的情感表征能力, 有效提高图文情感分析的准确性。

3.7　案例分析

为进一步证明本文模型的有效性, 比较了基于 BERT、ResNet50 和 SRC-Model 的分类结果, 如表 6 所示。

通过观察分类结果可以看出, 在单模态内容没有传达出明确的情感时, 单模态模型容易判断错

表6 不同模型的分类结果示例

Table 6 Examples classified by different models

图像	文本	真实情感	BERT	ResNet50	SRC-Model
	RT@dynamitefilm: A light hearted moment on set with our actor@IANMHARDING	积极	积极(√)	积极(√)	积极(√)
	Martha said for Valentine's Day she wanted a heart shaped pancake for lunch. Being the doting husband I am...	积极	积极(√)	中性(×)	积极(√)
	I HAVE NO WORDS IM SPEECHLESS	积极	消极(×)	积极(√)	积极(√)

误,而多模态模型能够较好地结合多模态内容给出正确的判断。例如,第1行的图像和文本分别通过笑脸和“light hearted moment”等内容表达了明确的积极情绪,因此模型均判断正确。第2行的图像中无法查询与情绪相关的线索,第3行中,仅根据文本内容难以确定其表达了积极还是消极的情绪,因此单模态模型均出现判断错误。

总体而言,图像和文本模态在表达情感上具有相互补充的作用,只有结合多模态内容,才能更全面准确地理解用户表达的情感。

4 结 论

1)本文针对社交媒体上的图文情感分析任务,提出一种基于情感表征校准的图文情感分析模型,在基准数据集MVSA上进行了大量实验,验证了模型的有效性。

2)引入门控校准机制,来校准特征空间中情感表征向量的情感表征偏移问题,消融实验和可视化实验的结果表明了该机制的有效性。

本文工作假设图文具有相互促进的作用,但部分情况下,图像和文本表达的语义并非一致,如有关讽刺的表达。图文语义的不一致为模态交互带来了挑战。未来将从模态间语义的一致性和不一致性出发,更加全面地分析多模态数据中的情感。

参考文献(References)

[1] 张亚洲, 戎璐, 宋大为, 等. 多模态情感分析研究综述[J]. 模式识别与人工智能, 2020, 33(5): 426-438.
Zhang Y Z, Rong L, Song D W, et al. A survey on multimodal sentiment analysis[J]. Pattern Recognition and Artificial Intelligence, 2020, 33(5): 426-438(in Chinese).

[2] Das R, Singh T D. Multimodal sentiment analysis: a survey of methods, trends, and challenges[J]. ACM Computing Surveys, 2023, 55(13s): 1-38.

[3] Kaur P, Pannu H S, Malhi A K. Comparative analysis on cross-modal information retrieval: a review[J]. Computer Science Review, 2021, 39: 100336.

[4] Serrano-Guerrero J, Romero F P, Olivas J A. Fuzzy logic applied to opinion mining: a review[J]. Knowledge-Based Systems, 2021, 222: 107018.

[5] 郑祎豪, 郭奕君, 毋立芳, 等. 知识驱动的多模态语义理解研究综述[J]. 模式识别与人工智能, 2023, 36(12): 1127-1138.
Zheng Y H, Guo Y J, Wu L F, et al. A survey on knowledge-driven multimodal semantic understanding[J]. Pattern Recognition and Artificial Intelligence, 2023, 36(12): 1127-1138(in Chinese).

[6] Wiebe J M, Bruce R F, O'Hara T P. Development and use of a gold-standard data set for subjectivity classifications[C]//Proceedings of the 37th Annual Meeting of the Association for Computational Linguistics on Computational Linguistics. New York: ACM, 1999: 246-253.

[7] Zhang S X, Zhu A Q, Zhu G L, et al. Building fake review detection model based on sentiment intensity and PU learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(10): 6926-6939.

[8] Pashchenko Y, Rahman M F, Hossain M S, et al. Emotional and the normative aspects of customers' reviews[J]. Journal of Retailing and Consumer Services, 2022, 68: 103011.

[9] Kim Y. Convolutional neural networks for sentence classification [C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing. Kerrville: ACL, 2014: 1746-1751.

[10] Wang L, Cao H, Yuan L. Gated tree-structured RecurNN for detecting biomedical event trigger[J]. Applied Soft Computing, 2022, 126: 109251.

[11] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [C]//Proceedings of the 31st International Conference on Neural In-

formation Processing Systems. New York: ACM, 2017: 6000-6010.

[12] Devlin J, Chang M W, Lee K, et al. BERT: pre-training of deep bidirectional Transformers for language understanding[C]//Proceedings of the Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1. Kerrville: ACL, 2019: 4171-4186.

[13] Dai J Q, Yan H, Sun T X, et al. Does syntax matter? a strong baseline for aspect-based sentiment analysis with RoBERTa[C]// Proceedings of the Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Kerrville: ACL, 2021: 1816-1829.

[14] Liu Y H, Ott M, Goyal N, et al. RoBERTa: a robustly optimized BERT pretraining approach[PP/OL]. arXiv (2019-07-26)[2024-07-14]. https://arxiv.org/abs/1907.11692.

[15] Liu N N, Dellandréa E, Chen L M, et al. Multimodal recognition of visual concepts using histograms of textual concepts and selective weighted late fusion scheme[J]. Computer Vision and Image Understanding, 2013, 117(5): 493-512.

[16] Xu N. Analyzing multimodal public sentiment based on hierarchical semantic attentional network[C]//Proceedings of the IEEE International Conference on Intelligence and Security Informatics. Piscataway: IEEE Press, 2017: 152-154.

[17] Xu N, Mao W J. MultiSentiNet: a deep semantic network for multimodal sentiment analysis[C]//Proceedings of the ACM on Conference on Information and Knowledge Management. New York: ACM, 2017: 2399-2402.

[18] Huang C Q, Zhang J L, Wu X M, et al. TeFNA: text-centered fusion network with crossmodal attention for multimodal sentiment analysis[J]. Knowledge-Based Systems, 2023, 269: 110502.

[19] Yang X C, Feng S, Wang D L, et al. Image-text multimodal emotion classification via multi-view attentional network[J]. IEEE Transactions on Multimedia, 2021, 23: 4014-4026.

[20] Zhu T, Li L D, Yang J F, et al. Multimodal sentiment analysis with image-text interaction network[J]. IEEE Transactions on Multimedia, 2023, 25: 3375-3385.

[21] Chen D L, Su W, Wu P, et al. Joint multimodal sentiment analysis based on information relevance[J]. Information Processing & Management, 2023, 60(2): 103193.

[22] 吴思思, 马静. 基于感知融合的多任务多模态情感分析模型[J]. 数据分析与知识发现, 2023, 7(10): 74-84.
Wu S S, Ma J. Multi-task & multi-modal sentiment analysis model based on aware fusion[J]. Data Analysis and Knowledge Discovery, 2023, 7(10): 74-84(in Chinese).

[23] Li Z, Xu B, Zhu C H, et al. CLMLF: a contrastive learning and multi-layer fusion method for multimodal sentiment detection[C]// Proceedings of the Findings of the Association for Computational Linguistics. Kerrville: ACL, 2022: 2282-2294.

[24] Wei Y W, Yuan S Z, Yang R S, et al. Tackling modality heterogeneity with multi-view calibration network for multimodal sentiment detection[C]//Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics. Kerrville: ACL, 2023: 5240-5252.

[25] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 770-778.

[26] Yang K C, Xu H, Gao K. CM-BERT: cross-modal BERT for text-audio sentiment analysis[C]//Proceedings of the 28th ACM International Conference on Multimedia. New York: ACM, 2020: 521-528.

[27] Du Y P, Liu Y, Peng Z, et al. Gated attention fusion network for multimodal sentiment classification[J]. Knowledge-Based Systems, 2022, 240: 108107.

[28] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[PP/OL]. arXiv (2018-02-07)[2024-07-14]. https://doi.org/10.48550/arxiv.1708.02002.

[29] Niu T, Zhu S A, Pang L, et al. Sentiment analysis on multi-view social data[C]//Proceedings of the MultiMedia Modeling. Berlin: Springer, 2016: 15-27.

[30] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16×16 words: Transformers for image recognition at scale[PP/OL]. arXiv (2021-06-03)[2024-07-14]. https://doi.org/10.48550/arxiv.2010.11929.

[31] Xu N, Mao W J, Chen G D. A co-memory network for multimodal sentiment analysis[C]//Proceedings of the 41st International ACM SIGIR Conference on Research & Development in Information Retrieval. New York: ACM, 2018: 929-932.

[32] Yang X C, Feng S, Zhang Y F, et al. Multimodal sentiment detection based on multi-channel graph neural networks[C]//Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing. Kerrville: ACL, 2021: 328-339.

Sentiment representation calibration-based model for image-text sentiment analysis

ZHANG Shunxiang[1, 2, 3, *], LIU Jiajia[1, 2], JIAO Yixuan[1, 2], ZHANG Yulei[1, 2], LI Ziliang[1, 2]

(1. School of Computer Science and Engineering, Anhui University of Science and Technology, Huainan 232001, China;
2. Institute of Artificial Intelligence, Hefei Comprehensive National Science Center, Hefei 230000, China;
3. School of Computer Science, Huainan Normal University, Huainan 232038, China)

Abstract: Exploring the association of multi-modal data for sentiment analysis is made more difficult by the growing trend of social media users expressing their opinions through both text and visuals. Existing research methods lack sufficient interaction between modalities and cross-modal interactions often introduce noise, which leads to sentiment representation bias of learned image and text representations. To address this issue, we introduce a sentiment representation calibration-based model for image-text sentiment analysis. Firstly, we encode the image and text through a feature extraction module to capture image and text features. In order to fully utilize the inter-modal complementary information, the cross-modal attention is then employed in the cross-modal interaction module to carry out bidirectional interaction in the "image-to-text" and "text-to-image" directions. Next, noise is filtered out from the interaction-enhanced features through a gated calibration module to correct the sentiment representation bias in the interaction-enhanced features. Finally, in the sentiment detection module, feature fusion is achieved by using multi-head attention to integrate the calibrated feature representations for sentiment detection. Experimental results on two public benchmark datasets demonstrate that the proposed model outperforms state-of-the-art image-text sentiment analysis methods, such as CLMLF and MVCN, thereby improving the accuracy of sentiment recognition.

Keywords: multimodal; image-text sentiment analysis; cross-modal interaction; sentimental representation bias; attention mechanism

Received: 2024-07-18; **Accepted**: 2024-09-23; **Published Online**: 2024-11-19 15:27

URL: link.cnki.net/urlid/11.2625.V.20241119.1312.002

Foundation items: General Program of National Natural Science Foundation of China (62076006); Opening Foundation of State Key Laboratory of Cognitive Intelligence (COGOS-2023HE02); University Synergy Innovation Program of Anhui Province (GXXT-2021-008)

* **Corresponding author**. E-mail: sxzhang@aust.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0713

融合注意力机制的飞机蒙皮损伤 LHN-YOLO 小目标检测算法

李耀华*，陈杰
(中国民航大学 交通科学与工程学院，天津 300300)

摘　　要：针对飞机蒙皮损伤小目标检测精度低、参数量大等问题，以飞机蒙皮铆钉损伤为研究对象，基于 YOLOv8n 算法提出了一种融合注意力机制的 LHN-YOLO 算法。为增强模型对小目标的检测能力，在骨干部分引入优化后的高效多尺度注意力 (EMA) 机制，通过轻量化卷积 LightConv 对 EMA 机制进行优化，形成 Light-EMA 模块，提高检测精度，降低计算复杂度；同时，引入 Haar 小波降采样模块和归一化高斯 Wasserstein 距离损失函数替换原模型的下采样操作和 CIoU 损失函数以提升预测性能。实验结果表明：LHN-YOLO 算法的准确率、召回率、平均精度均值分别为 92.7%、87.0%、91.7%，相较于改进前的原模型提升了 2.2%、3.5%、2.8%，参数量减少了 10%，有效提升了飞机蒙皮损伤小目标检测的效果。

关　键　词：YOLOv8n；注意力机制；小目标检测；铆钉损伤；蒙皮损伤检测
中图分类号：V267+.2; TP391.4
文献标志码：A　　**文章编号**：1001-5965(2026)11-3735-10

随着民航业的快速发展，飞机的设计和维护技术也有了很大进步，铆钉作为飞机结构中广泛使用的连接方式，若其松动脱落或腐蚀且不及时修理，将严重威胁飞机的飞行安全。飞机蒙皮采用了大量的铆钉进行连接，传统的飞机蒙皮缺陷检测主要依靠人工来进行，要求技术人员通过目视或光学仪器辅助的方式来识别飞机蒙皮上存在的缺陷。这种检测方法不仅存在耗时长、技术人员高空作业的风险，而且检测结果严重依赖技术人员的专业知识和主观判断[1-2]。因此，研究采用快速而准确的目标检测算法对飞机蒙皮进行小目标损伤检测意义重大。

目标检测技术体系当前主要包含两大研究分支：①基于传统视觉特征的检测算法，这类算法通过提取目标区域的边缘响应、亮度分布、直方图统计及光谱特征等人工设计特征完成缺陷识别与区域分割[3]，但在环境适应性、实时性及定位精度等关键性能上仍存在明显瓶颈；②基于深度学习的智能检测算法，该方向可进一步划分为单阶段与双阶段检测架构，单阶段架构以 SSD、YOLO 等端到端检测框架为代表，双阶段架构则以 Faster R-CNN 等网络为典型实现[4]。

相较于传统算法，基于深度学习的检测框架在系统稳定性、处理效率和识别精度等多个维度实现了显著改进。特别是在单阶段检测领域，YOLO 系列算法通过持续迭代优化，在检测实时性与准确度的平衡性方面表现突出。值得关注的是，该系列最新推出的 YOLOv8 开源版本(2023 年 1 月发布)，通过改进网络结构与训练策略，在保持毫秒级推理速度的同时，使平均精度均值(mean average precision, mAP)指标获得了显著提升。

原始 YOLOv8 模型用于飞机蒙皮损伤检测遇到的问题主要在于：小目标特征信息在提取过程中

收稿日期：2024-09-27；**录用日期**：2024-12-19；**网络出版时间**：2025-02-18 15:03
网络出版地址：link.cnki.net/urlid/11.2625.V.20250218.1111.001
基金项目：国家自然科学基金委员会-中国民航局民航联合研究基金重点支持项目 (U2033209)
*通信作者. E-mail：yh_li@cauc.edu.cn

引用格式：李耀华，陈杰. 融合注意力机制的飞机蒙皮损伤 LHN-YOLO 小目标检测算法 [J]. 北京航空航天大学学报，2026，52（11）：3735-3744. Li Y H，Chen J. Aircraft skin damage LHN-YOLO small target detection algorithm incorporating attention mechanisms[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：3735-3744 （in Chinese）.

容易丢失[5-6], YOLOv8原模型适用于标准尺度的目标[7-8], 对于小目标检测效果不佳, 传统的损失函数对小目标对象偏差过于敏感, 不利于模型的收敛等[9]。针对以上问题, 现有研究人员提出的解决方法有: 对特征融合机制进行改进, 在网络中添加小目标检测层, 充分利用目标的浅层特征信息, 提高对小目标检测的准确性, 但因为增加了模型复杂度, 影响模型的计算效率[10]; 通过在模型的合适位置嵌入注意力机制模块, 增加对输入特征的有效信息利用率, 能够对特定尺寸的目标起到较好的检测效果[11-12]; 用轻量化的卷积替换颈部网络层和C2f模块的标准卷积, 大幅降低模型参数, 提升模型的计算效率, 但在面对大量的小目标对象时存在漏检现象[13]; 设计新的卷积块结构, 在减少特征图尺寸的同时捕获特征图的全局信息, 以取代池化和跨步卷积层, 从而提高小目标特征表示能力[14]; 考虑到检测对象的形状与分布, 提出更符合检测目标的损失函数和图像处理算法, 在特定形状和尺寸的对象上能够取得较好的检测效果[15]。

目前的目标检测算法在对飞机蒙皮损伤进行小目标检测时, 容易遇到检测精度不佳、模型收敛速度慢、模型参数量大的问题, 为解决这些问题, 本文引入了高效多尺度注意力(efficient multi-scale attention, EMA)模块; 为避免引入注意力机制模块带来的参数量增加, 将原模块中内部卷积核为1×1和3×3的卷积块替换为轻量化卷积LightConv, 形成Light-EMA模块, 减少参数量, 提升检测精度; 为防止特征信息丢失和更快地收敛模型, 引入Haar小波降采样(Haar wavelet downsample, HWD)模块[16]和归一化高斯Wasserstein距离(normalized Gaussian Wasserstein distance, NWD)[17]损失函数, 提升模型对小目标特征的提取能力和收敛速度。

1 飞机蒙皮损伤LHN-YOLO小目标检测算法

1.1 LHN-YOLO网络结构建立

YOLOv8n的总体结构包括输入、骨干网络、颈部网络、头部网络4部分。根据具体需要, 将模型按照网络模型的大小分为YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l和YOLOv8x等5种模型[18]。

LHN-YOLO是在YOLOv8n网络的基础上进行改进后得到的, 为增强网络对小目标的检测能力, 通过使用LightConv对EMA机制进行优化, 形成了Light-EMA模块, 将Light-EMA模块应用于骨干网络部分; 同时, 引入HWD模块和NWD损失函数替换原模型的下采样操作和CIoU损失函数, 分别用于骨干网络、颈部网络和头部网络。改进后的LHN-YOLO网络结构如图1所示。

LHN-YOLO网络在骨干网络部分的4个C2f模块后加入Light-EMA模块。骨干网络用于提取输入信息的特征, 通过卷积块、快速空间金字塔池化(spatial pyramid pooling-fast, SPPF)和C2f模块组合实现了不同尺度特征的高效融合, 加强了浅层与深层特征间的信息传递。Light-EMA模块通过使用LightConv优化了EMA机制, 使其能够在减少参数量和计算复杂度的基础上提升对小目标对象的检测精度, 将其置于骨干网络的C2f模块后有助于融合不同尺度的特征信息, 提高模型的检测精度。颈部网络部分借助路径聚合网络(path aggregation network, PAN)、特征金字塔网络(feature pyramid network, FPN)增强了局部与全局特征的融合, 丰富了目标特征信息。本文在颈部网络和骨干网络部分使用HWD模块替换了原模型的卷积块, 减少了下采样过程中小目标特征的丢失。在头部网络部分使用NWD损失函数替换原模型的CIoU损失函数, 提升模型对小目标的检测性能。

1.2 融合轻量化卷积的Light-EMA模块

由于数据集中的铆钉损伤绝大部分属于小目标对象, 在使用原模型进行预测时容易出现错检、漏检的情况, 本文引入了EMA机制, 提高模型对小目标对象的检测能力, 同时利用LightConv对注意力机制进行改进, 形成了Light-EMA机制, 在不增加参数量的基础上提高检测精度。

Ouyang等[19]提出的新型EMA模块主要通过3个关键机制提高特征提取的效率和性能: ①将输入特征图沿通道维度划分为多个子特征组, 以学习不同语义; ②采用并行的1×1和3×3分支, 同时捕获深层和浅层的特征依赖关系, 并利用3条并行路径提取注意力权重描述符; ③建立通道和空间位置之间的相互依赖关系, 提供跨空间信息聚合的方法, 融合1×1和3×3分支的输出以获得最终的特征表示。EMA模块通过这些设计有效捕获了多尺度的语义特征, 从而提高了模型的性能。但在模型中加入EMA模块会导致参数量增加, 其中的二维卷积Conv2d参数量较大、计算复杂度较高, 存在提升空间。

为解决该问题, 本文引入LightConv对EMA机制进行优化。LightConv是一种轻量化卷积操作, 用于减少模型的计算量和参数量[20]。

LightConv通过权重共享操作减少模块的参数量。在其使用的深度卷积中, 对通道的参数进行绑定, 使其相比于普通正则卷积, 参数量减少一半。例如, 对于特征维度d=1 024, 卷积核大小k=7, 正则

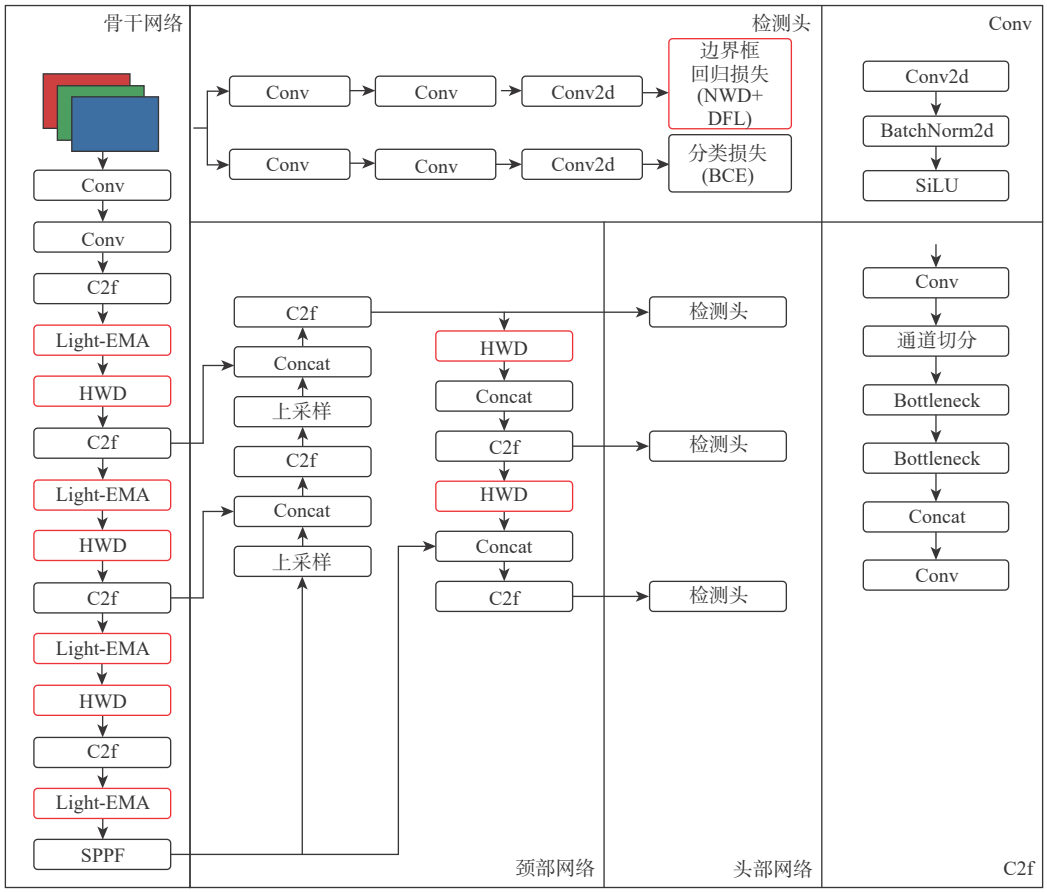


图 1　LHN-YOLO 网络结构

Fig. 1　LHN-YOLO network structure

卷积需要 7 340 032 权重 ($d^2\times k$), 深度可分离卷积需要 7 168 权重 ($d\times k$), 而在权重共享的情况下, 权重共享分组数 $H=16$, 只有 112 权重 ($H\times k$)。通过权重共享的方式, LightConv 实现了计算复杂度降低和浮点运算数减少。

LightConv 计算列表中, 第 i 个元素和输出通道 c 的计算过程如下:

$$\text{LightConv}\left(\boldsymbol{X},\boldsymbol{W}_{\left[\frac{cH}{d}\right],:},i,c\right)=\text{DepthwiseConv}\left(\boldsymbol{X},\text{Softmax}\left(\boldsymbol{W}_{\left[\frac{cH}{d}\right],:}\right),i,c\right)\tag{1}$$

深度卷积在每个通道上独立地执行卷积, 参数个数可以从 d^2k 减少到 dk。式(1)中: $\boldsymbol{X}$ 为输入序列特征张量; LightConv() 表示轻量化卷积操作; DepthwiseConv() 表示深度卷积操作; Softmax() 表示 Softmax 操作; k 为卷积核大小。对于元素 i 和输出维数 c, 权重为 $\boldsymbol{W}\in\mathbf{R}^{d\times k}$ 的深度卷积的输出定义为

$$\text{DepthwiseConv}(\boldsymbol{X},\boldsymbol{W}_{c,:},i,c)=\sum_{j=1}^{k}W_{c,j}X_{\left(i+j-\left\lfloor\frac{k+1}{2}\right\rfloor\right),c}\tag{2}$$

LightConv 使用 Softmax 操作在时间维度 k 上归一化权重 $\boldsymbol{W}\in\mathbf{R}^{H\times k}$:

$$\text{Softmax}(\boldsymbol{W})_{h,j}=\exp\left(W_{h,j}\right)\Big/\sum_{j'=1}^{k}\exp\left(W_{h,j'}\right)\tag{3}$$

LightConv 结构如图 2 所示。图中: LConv 表示轻量级卷积。

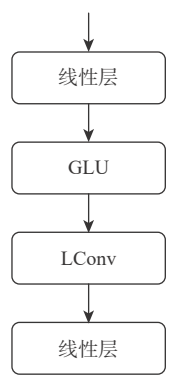


图 2　LightConv 结构

Fig. 2　LightConv structure

门控线性单元 (gated linear unit, GLU) 的计算公式如下:

$$U_l(\boldsymbol{X})=(\boldsymbol{X}*\boldsymbol{W}+\boldsymbol{b}_1)\otimes\sigma(\boldsymbol{X}*\boldsymbol{V}+\boldsymbol{b}_2)\tag{4}$$

式中: σ 表示 Sigmoid 函数; $\otimes$ 表示逐元素相乘; $\boldsymbol{b}_1$、$\boldsymbol{b}_2$ 为偏置项; $\boldsymbol{V}$ 为可学习权重。

综上所述，LightConv以较低的计算复杂度使得模型能够更快速地进行目标检测和推理，并且拥有不错的泛化性。观察到，在EMA机制中，1×1和3×3分支使用了卷积核分别为1×1和3×3的卷积，在网络中加入EMA模块后，参数量有所增加，这不利于提升模型的预测性能，并且会影响模型的运行速度，因此，本文使用LightConv模块对EMA模块中的Conv(1×1)和Conv(3×3)进行替换，减少了参数量、计算复杂度的同时提升了检测精度。

改进后的Light-EMA模块网络结构如图3所示。

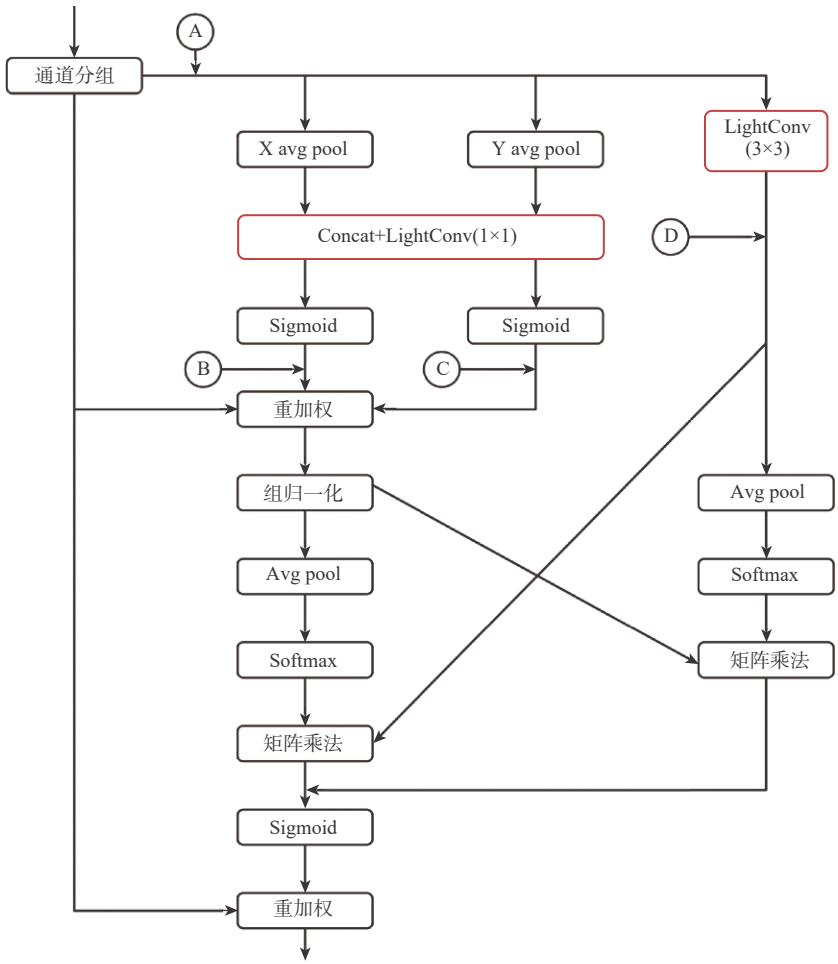


图3 Light-EMA结构

Fig. 3 Light-EMA structure

在Light-EMA运算过程中：

$$\boldsymbol{F}_{\mathrm{B}}=\boldsymbol{F}_{\mathrm{C}}=\sigma\left(f_{\mathrm{LightConv}}^{1\times1}\left(\mathrm{cat}\left(\mathrm{XAvg}(\boldsymbol{F}_{\mathrm{A}}),\mathrm{YAvg}(\boldsymbol{F}_{\mathrm{A}})\right)\right)\right) \tag{5}$$

$$\boldsymbol{F}_{\mathrm{D}}=f_{\mathrm{LightConv}}^{3\times3}(\boldsymbol{F}_{\mathrm{A}}) \tag{6}$$

式中：$\boldsymbol{F}_{\mathrm{A}}\in\mathbf{R}^{C'\times H'\times W'}$，$C'$、$H'$、$W'$分别为输入数据的通道数、高度、宽度；$f_{\mathrm{LightConv}}^{1\times1}$表示卷积核为1×1的LightConv卷积运算；$f_{\mathrm{LightConv}}^{3\times3}$表示卷积核为3×3的LightConv卷积运算；cat表示拼接操作；$\mathrm{XAvg}(\boldsymbol{F}_{\mathrm{A}})$表示水平维度平均池化，$\mathrm{YAvg}(\boldsymbol{F}_{\mathrm{A}})$表示垂直维度平均池化，$\mathrm{XAvg}(\boldsymbol{F}_{\mathrm{A}})\in\mathbf{R}^{C'\times H'\times1}$，$\mathrm{YAvg}(\boldsymbol{F}_{\mathrm{A}})\in\mathbf{R}^{C'\times1\times W'}$。

1.3 HWD模块

在提取铆钉等小目标对象的特征信息时，往往需要进行下采样操作，但原模型中的下采样操作在缩放图像的同时容易丢失小目标对象的特征信息，导致模型对小目标对象预测性能不高，为此本文引入HWD模块。

Xu等[16]提出基于HWD模型。HWD模块在深度神经网络的编码器部分能够尽可能地保留图像的信息，更容易提取出更具判别性的特征，从而有助于提高分割性能。因此，针对传统下采样方法直接降低特征图的空间分辨率，容易造成信息丢失的情况，本文引入HWD模块替换骨干网络层和颈部网络层中的部分卷积进行下采样操作。HWD模块包括无损特征编码块和特征学习块。首先，在不损失信息的前提下，利用无损特征编码块中的Haar小波变换先进行近似信息和高频信息提取，再进行下采样操作；然后，在特征学习块（由标准卷积层、批量归一化和ReLU激活层组成）中使用卷积操作进行特征学习，以过滤冗余信息。

一维 Haar 变换的小波基函数ϕ_1和尺度函数ψ_1可以定义如下:

$$\begin{cases}\phi_1 = \dfrac{1}{\sqrt{2}}\phi_{1,0}(x)+\dfrac{1}{\sqrt{2}}\phi_{1,1}(x)\\ \psi_1 = \dfrac{1}{\sqrt{2}}\phi_{1,0}(x)-\dfrac{1}{\sqrt{2}}\phi_{1,1}(x)\end{cases} \tag{7}$$

式中: $\phi_{j,k}(x)$定义为

$$\phi_{j,k}(x) = \sqrt{2^j}\phi(2^j x-k) \tag{8}$$

其中: $k=0,1,2,\cdots,2^j-1$, j和k为基函数的阶数。

通过以上操作, HWD 模块能在有效减少计算开销的前提下, 提升训练的速度和精度。HWD 模块的结构示意图如图 4 所示。

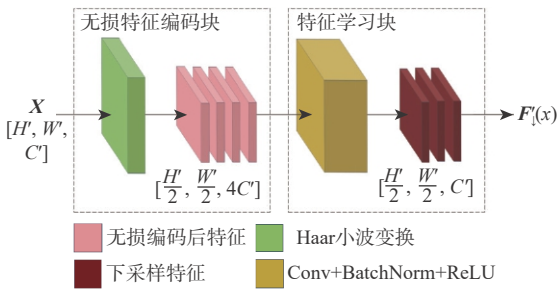


图 4　HWD 模块结构示意图

Fig. 4　HWD module structure

1.4　NWD 损失函数

在对飞机蒙皮铆钉损伤进行预测时, 由于数据集中铆钉的形状多为正圆形或椭圆形, 有效信息集中于预测框中心部位, CIoU 损失函数在对这类目标进行评估时, 往往将整个矩形预测框内的像素都作为目标对象, 对于不同尺度的对象敏感度差异较大, 尤其在进行小目标检测时, CIoU 较大的位置偏差敏感性不利于模型的收敛。

为解决该问题, 本文引入了 NWD 损失函数改进原模型的 CIoU 损失函数。Xu 等[17] 提出的 NWD 损失函数基于 Wasserstein 距离设计了一个更好的小目标度量, 针对小目标检测任务中普遍存在的几何特征适配问题, 实际场景中目标物体普遍存在非规则的几何形态特征, 导致矩形检测框难以避免地包含非目标区域像素。通过系统性分析可知, 目标有效像素与背景干扰像素在检测框内呈现显著空间分布规律: 前者主要集聚于检测框中心区域, 后者则密集分布于边界过渡区域。为精确量化检测框内各像素的空间贡献度差异, 可采用基于概率密度函数的建模方法, 将检测框表征为二维高斯分布模型。在该模型框架下, 中心像素对应概率密度峰值, 其响应强度随空间位置向边界移动呈现径向衰减特性, 这种机制可有效反映目标像素的空间梯度变化规律。

对于转化为二维高斯分布的边界框$N_a=(c_{x_a},c_{y_a},w_a,h_a)$和$N_b=(c_{x_b},c_{y_b},w_b,h_b)$之间的二阶 Wasserstein 距离, 可以简化为

$$W_2^2(N_a,N_b) = \left\| \left(\left[c_{x_a},c_{y_a},\frac{w_a}{2},\frac{h_a}{2}\right]^{\mathrm{T}}, \left[c_{x_b},c_{y_b},\frac{w_b}{2},\frac{h_b}{2}\right]^{\mathrm{T}} \right) \right\|_2^2 \tag{9}$$

式中: c_{x_a}、c_{y_a}、c_{x_b}、c_{y_b}分别表示对应边界框的中心点的横纵坐标; w_a、h_a、w_b、h_b分别表示边界框N_a、N_b的宽度和高; $W_2^2(N_a,N_b)$表示取值范围为$[0,+\infty)$且不能直接作为分配标签的相似性度量。为得到与 IoU(使其取值在 0～1 之间) 相似的取值范围, 并使度量值平滑到位置偏差, NWD 选择了一个指数非线性变换函数, 将高斯 Wasserstein 距离重新映射到另一个空间, 从而将其取值范围归一化得到了归一化高斯 Wasserstein 距离:

$$\mathrm{NWD}(N_a,N_b) = \exp\left(-\frac{\sqrt{W_2^2(N_a,N_b)}}{C'}\right) \tag{10}$$

2　实验验证分析

2.1　数据集处理

数据集来自中国民航大学机坪拍摄和某航空公司提供的飞机蒙皮图像, 去除因模糊、拍摄角度不佳等而不能使用的图像后, 得到共 556 张飞机蒙皮铆钉损伤图像。为增加模型的鲁棒性和泛化能力, 减少过拟合的影响, 对该数据集进行数据增强, 使用包括水平翻转、对比度变化、高斯噪声等 9 种数据增强方法, 扩充比例为 1:9, 扩充后的数据集包括铆钉损伤图像 5 004 张。扩充后的数据集效果如图 5 所示。对扩充后的数据集按照训练集、验证集和测试集以 8:1:1 的比例进行划分。图 6 为数据集目标分布统计结果。

2.2　对比实验

2.2.1　评价指标

实验硬件配置包括 NVIDIA GeForce RTX 4060

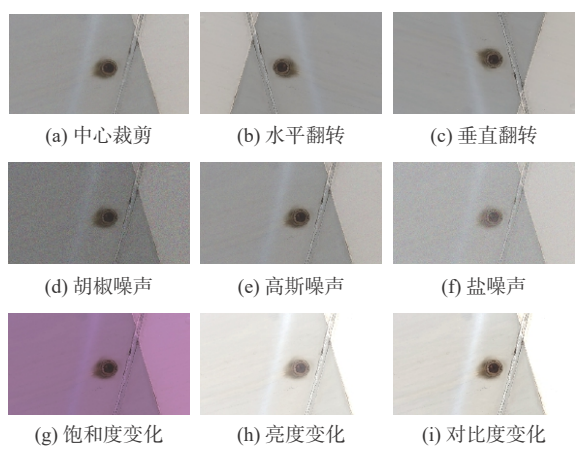


图 5　数据增强后的数据集效果

Fig. 5　Dataset after data enhancement

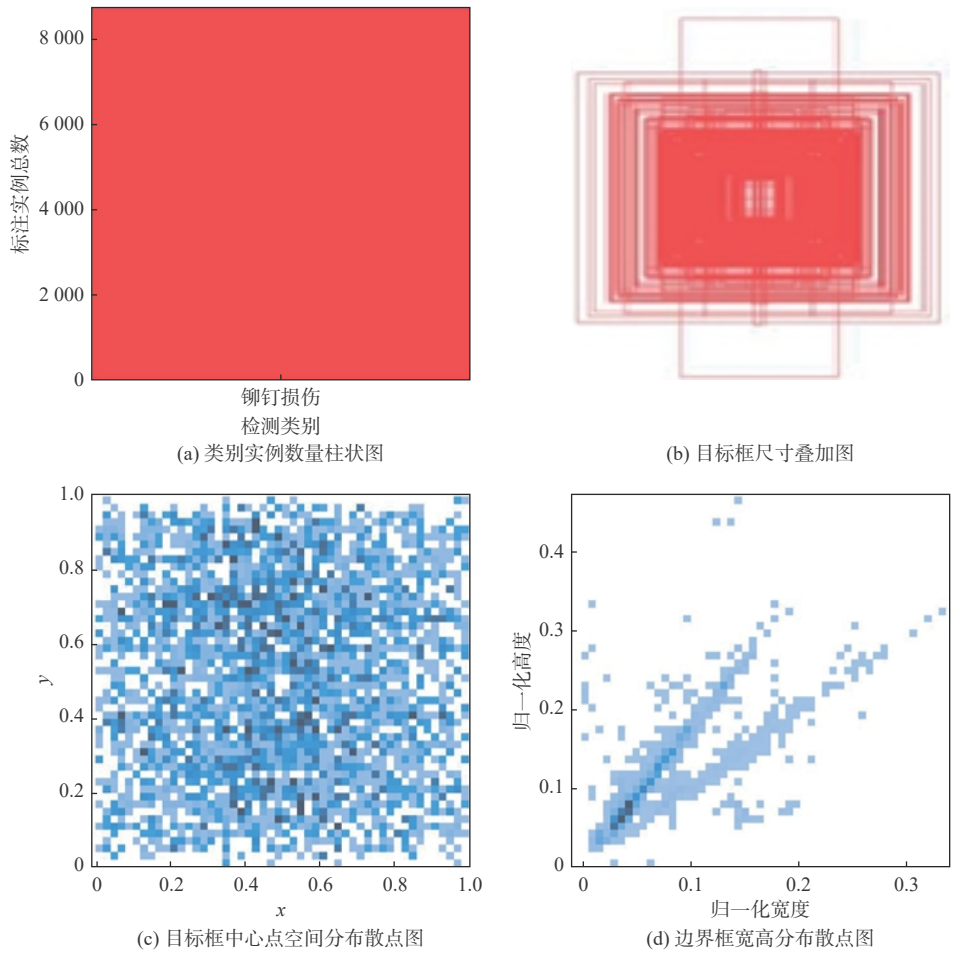


图6 数据集的目标尺寸分布

Fig. 6 Target sizes distribution of dataset

Ti GPU和Intel(R) Core(TM) i5-13400F 2.50 GHz, 其中, GPU的内存为8 GB RAM。软件方面, 本文使用Python3.11.9、PyTorch2.2.1和Cuda12.4深度学习框架。实验中, 使用SGD优化器, 初始学习率设置为0.01, 批处理大小为16, 输入图像尺寸为640像素×640像素。

采用精确度P、召回率R、mAP@0.5、参数量、浮点运算数和检测速度等6个指标对网络性能进行评估。

P是指所有样本中预测正确样本所占比例, R是指预测正确样本占所有正样本的比例, 两者具体计算公式如下:

$$P=\frac{T_P}{T_P+F_P}\times 100\% \tag{11}$$

$$R=\frac{T_P}{T_P+F_N}\times 100\% \tag{12}$$

式中: T_P为正样本中预测正确的数量; F_P为负样本中预测错误的数量; F_N为将正样本预测为负样本的数量。

mAP@0.5表示所有类别的平均精度(average precision, AP)在交并比(intersection over union, IoU)阈值为0.5时的平均值, 计算公式如下:

$$S_{\mathrm{mAP}}=\frac{\sum_{i=1}^{N}S_{\mathrm{AP}_i}}{N}\times 100\% \tag{13}$$

式中: N为检测总类别数; S_{AP}表示以P为横轴、R为纵轴所围成的P-R曲线下的面积; S_{mAP}表示mAP的值, 为AP的平均值。

2.2.2 Light-EMA模块对比实验

在YOLOv8结构中添加EMA模块时, 本文对比了将EMA模块置于颈部网络的C2f模块后和置于骨干网络的C2f模块后的网络预测性能, 对比实验结果如表1所示。通过对比实验可知, 与将EMA模块置于颈部C2f模块之后相比, 将其置于骨干C2f模块之后时R值、mAP@0.5值略有下降, 但P值提升了1.8%, 因此, 本文采用将EMA模块置于骨干部分的C2f模块后。

为验证加入EMA模块能增强模型对小目标的识别能力, 使用梯度加权类激活映射(gradient-weighted class activation mapping, Grad-CAM)视觉解释方法输出网络在预测过程中的热力图, 在目标检测领域, 小目标通常被定义为尺寸小于图像总尺寸

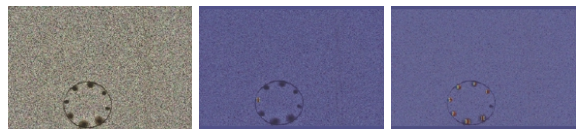
表 1　在不同位置应用 EMA 模块的网络效果对比

Table 1　Comparison of network effects of applying EMA modules at different locations

模型	*P*/%	*R*/%	mAP@0.5/%	参数量	检测速度/(帧·s^{-1})	浮点运算数/10^{9}次
YOLOv8n	90.5	83.5	88.9	3.0×10^6	159	8.1
EMA-颈部	89.2	85.2	89.9	2.9×10^6	140	8.4
EMA-骨干	91.0	85.0	89.4	3.1×10^6	123	8.4

0.5% 的物体, 其对比度通常低于 0.15[14], 本文选取数据集中符合小目标特征定义的图像进行可视化, 热力图如图 7 所示。可知, 加入 EMA模块后, 模型对小目标特征的检测能力显著提高。

观察到, 在 EMA 模块中, 1×1分支和3×3分支分别使用了卷积核为1×1和3×3的卷积, 相比于 LightConv, 参数量大、浮点运算数大, 从而影响了整体算法的运算效率。因此, 本文使用 LightConv 对 EMA 模块中的 Conv1×1 的 Conv3×3 进行替换, 使用一维 LightConv 替换1×1卷积、使用三维 LightConv 替换3×3卷积。在进行对比实验时, 将 Conv1×1的位置标记为 1 位置、Conv3×3的位置标记为 2 位置, 分别对 1 位置进行替换、对 2 位置进行替换和对 1、2 位置同时进行替换, 并且分别命名为 EMA (L1)、EMA(L2)、EMA(L12)。对比实验结果如表 2 所示。可见, 对 1、2 位置同时进行替换, 在 *P* 值、*R* 值和 mAP@0.5 值上均得到了提升, 同时减少了模型的参数量, 最终选择对 1、2 位置均使用 LightConv 进行替换形成 Light-EMA 模块。



(a) 原图　(b) YOLOv8n　(c) YOLOv8n+EMA

图 7　通过 Grad-CAM 可视化添加 EMA 机制后预测热力图

Fig. 7　Predicted heat map after adding EMA mechanism through Grad-CAM visualization

表 2　改进 EMA 模块对比实验结果

Table 2　Comparative experimental results of improved EMA module

模型	*P*/%	*R*/%	mAP@0.5/%	参数量	检测速度/(帧·s^{-1})	浮点运算数/10^{9}次
YOLOv8n	90.5	83.5	88.9	3.0×10^6	159	8.1
EMA(L1)	90.8	84.7	90.2	3.0×10^6	120	8.6
EMA(L2)	91.0	85.5	90.1	3.0×10^6	123	8.5
EMA(L12)	91.3	87.5	90.4	2.9×10^6	117	8.7

2.2.3　消融实验

为验证本文改进的有效性, 对比了改进过程中依次加入 Light-EMA 模块、HWD 模块和 NWD 损失函数的网络模型预测性能。消融实验结果如表 3 所示。

表 3　LHN-YOLO 的消融实验结果

Table 3　Results of ablation experiments with LHN-YOLO

模型	*P*/%	*R*/%	mAP@0.5/%	参数量	检测速度/(帧·s^{-1})	浮点运算数/10^{9}次
YOLOv8n	90.5	83.5	88.9	3.0×10^6	159	8.1
YOLOv8n+Light-EMA	91.3	87.5	90.4	2.9×10^6	117	8.7
YOLOv8n+Light-EMA+HWD	92.0	84.5	90.0	2.7×10^6	126	8.0
YOLOv8n+Light-EMA+HWD+NWD	92.7	87.0	91.7	2.7×10^6	119	8.2

从消融实验结果可知, 在原模型的骨干部分中加入 Light-EMA 模块, *P* 值、*R* 值和 mAP@0.5 值较 YOLOv8n 模型分别提升了 0.8%、4.0% 和 1.5%, 并且减少了 0.1×10^6 的参数量。表明 Light-EMA 模块在嵌入模型后, 减少参数量的同时提升了模型的检测精度; 将骨干部分和颈部中的卷积块替换为 HWD 模块, 形成 YOLOv8n+Light-EMA+HWD 模型, 较改进前 YOLOv8n 模型的 *P* 值、*R* 值和 mAP@0.5 值分别提升了 1.5%、1.0% 和 1.1%, 同时参数量下降了 0.3×10^6, 有效达到了减少模型参数量的同时提升检测精度的目标; 引入 NWD 模块替换原模型中的 CIoU 损失函数, 最终的 YOLOv8n+Light-EMA+HWD+NWD 模型相比于改进前 YOLOv8n 模型的 *P* 值、*R* 值和 mAP@0.5 值分别提升了 2.2%、3.5% 和 2.8%, 加入 NWD 模块使原模型更加聚焦于小目标特征, 在小目标特征占比较大时能更快收敛, 稳定性更好。最终模型的 *P* 值、*R* 值、mAP@0.5 值分别为 92.7%、87.0% 和 91.7%, 能有效地进行飞机蒙皮小目标检测任务。

2.2.4　不同模型实验及预测效果对比分析

为验证本文算法的优越性, 在使用相同实验条件、相同数据集的情况下, 将改进后的算法与其他算法进行对比。在对比实验中选取参数量与 YOLOv8n 相近的模型进行比较, 包括 YOLOv5n、YOLOv6n、YOLOv7-tiny、YOLOv8n、YOLOv9c。

分析表 4 可知, 与其他 YOLO 系列算法相比, LHN-YOLO 算法在参数量上要高于 YOLOv5n, 但在 *P* 值、*R* 值和 mAP@0.5 值上的提升达到了 2.5%、2% 和 2.8%; 对比 YOLOv8n 算法, LHN-YOLO 的检

表4 不同模型的网络预测性能对比

Table 4 Comparison of network prediction performance of different models

模型	P/%	R/%	mAP@0.5/%	参数量	检测速度/(帧·s^{-1})	浮点运算数/10^9次
YOLOv5n	90.2	85.0	88.9	2.5×10^6	145	7.1
YOLOv6n	88.5	83.2	87.9	4.7×10^6	137	11.8
YOLOv7-tiny	78.3	77.5	77.3	6.0×10^6	127	13.2
YOLOv8n	90.5	83.5	88.9	3.0×10^6	159	8.1
YOLOv9c	89.8	82.6	88.0	25.3×10^6	94	102.3
LHN-YOLO	92.7	87.0	91.7	2.7×10^6	119	8.2

测速度提升了25.2%，但在P值、R值和mAP@0.5值方面提升了2.2%、3.5%和2.8%。对比其他算法，LHN-YOLO也在P值、R值和mAP@0.5值上更有优势，同时参数量少于大部分模型，证明模型对比其他算法具有一定的优越性。

2.2.5 LEVIR-ship数据集下的模型性能验证

为验证本文算法在小目标检测性能方面相较于YOLOv8n算法有所提升，使用由卫星拍摄的小目标数据集LEVIR-ship进行验证[21]。

LEVIR-ship数据集使用了高分一号和高分六号卫星的多光谱相机所拍摄的图像，只使用R、G和B波段，在像素分辨率为10 000像素×10 000像素～50 000像素×20 000像素的数据集中采集了85个场景。对原始图像进行裁剪，最终得到1 973个正样本和1 903个负样本，大小为512像素×512像素。数据集包含了一类对象：船舶类对象，且船舶类对象像素尺寸几乎都在20像素×20像素以下，集中在10像素×10像素左右。因此，该数据集能够很好地验证改进后算法相较于基准算法在小目标检测领域的性能提升，对比实验结果如表5所示。

表5 改进前后模型在LEVIR-ship数据集上的精度对比

Table 5 Comparison of accuracy of model before and after improvement on LEVIR-ship dataset

模型	P/%	R/%	mAP@0.5/%	参数量	检测速度/(帧·s^{-1})	浮点运算数/10^9次
YOLOv8n	80.4	78.3	81.7	3.0×10^6	294	8.1
LHN-YOLO	85.4	77.6	82.4	2.7×10^6	232	8.2

由表5可得，在LEVIR-ship数据集中，LHN-YOLO算法在R值略微下降的情况下，P值得到了显著提升，增加了5.0%，mAP@0.5值也提升了0.7%。通过对比实验验证了算法在小目标检测性能方面相较于YOLOv8n算法有所提升。

3 结 论

1）为了对飞机蒙皮存在的小目标特征进行有效检测，同时尽可能地降低网络的参数量，针对飞机蒙皮铆钉损伤这一典型缺陷，提出融合注意力机制的轻量化飞机蒙皮损伤小目标检测算法LHN-YOLO。

2）设计了Light-EMA机制，使用轻量化卷积LightConv对EMA机制中的二维卷积进行优化，并将其应用于骨干网络部分，在减少模型参数量和计算复杂度的情况下，提升了网络对小目标特征的检测能力；在骨干网络和颈部网络中使用HWD模块代替原模型的下采样操作，能在下采样操作的同时尽可能地保留小目标的特征信息；在损失函数中使用NWD损失函数代替CIoU损失函数，对小目标特征进行检测时更稳定，有助于模型进一步收敛。

3）在自制数据集下，LHN-YOLO算法在较YOLOv8n网络参数量减少了10%的情况下，准确率、召回率、平均精度均值分别提升了2.2%、3.5%和2.8%；在公开小目标船舶数据集LEVIR-ship下，准确率较YOLOv8n网络提升了5.0%，验证了本文算法在小目标检测领域的有效性。

LHN-YOLO算法虽然在小目标检测性能和参数量上对比原模型和其他模型都有所优化，但在检测速度和网络参数量上仍有优化空间，未来改进后可以更好地应用于飞机蒙皮损伤检测任务中。

参考文献（References）

[1] 章东平, 王杼涛, 夏岳键, 等. 基于改进YOLOv8的飞机蒙皮缺陷检测算法[J]. 北京航空航天大学学报, 2026, 52(1): 38-48.
Zhang D P, Wang Z T, Xia Y J, et al. Aircraft skin defect detection algorithm based on enhanced YOLOv8[J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(1): 38-48(in Chinese).

[2] Wang P, Luo Y, Zhu Z L. FDI-YOLO: feature disentanglement and interaction network based on YOLO for SAR object detection[J]. Expert Systems with Applications, 2025, 260: 125442.

[3] Tao X, Zhang D P, Ma W Z, et al. Automatic metallic surface defect detection and recognition with convolutional neural networks [J]. Applied Sciences, 2018, 8(9): 1575.

[4] Ding M, Wu B E, Xu J, et al. Visual inspection of aircraft skin: automated pixel-level defect detection by instance segmentation[J]. Chinese Journal of Aeronautics, 2022, 35(10): 254-264.

[5] 刘振江, 张会娟, 姬淼鑫, 等. 轻量级多尺度特征融合增强的空间非合作小目标检测算法[J/OL]. 北京航空航天大学学报, 2024 [2024-09-20]. https://doi.org/10.13700/j.bh.1001-5965.2024.0509.
Liu Z J, Zhang H J, Ji M X, et al. Lightweight multi-scale feature fusion enhanced spatial non-cooperative small target detection algorithm[J/OL]. Journal of Beijing University of Aeronautics and Astronautics, 2024[2024-09-20]. https://doi.org/10.13700/j.bh.1001-5965.2024.0509(in Chinese).

[6] 郭艳, 王智文, 赵润星. YOLO-POD: 基于多维注意力机制的高精度PCB微小缺陷检测算法[J]. 电子学报, 2024, 52(7): 2515-2528.
Guo Y, Wang Z W, Zhao R X. YOLO-POD: high-precision PCB tiny-defect detection algorithm based on multi-dimensional atten-

tion mechanism[J]. Acta Electronica Sinica, 2024, 52(7): 2515-2528 (in Chinese).

[7] 吴一全, 童康. 基于深度学习的无人机航拍图像小目标检测研究进展[J]. 航空学报, 2025, 46(3): 130755.
Wu Y Q, Tong K. Research advances on deep learning-based small object detection in UAV aerial images[J]. Acta Aeronautica et Astronautica Sinica, 2025, 46(3): 130755(in Chinese).

[8] 刘延芳, 佘佳宇, 袁秋帆, 等. 无人机遥感图像实时小目标检测方法[J]. 航空学报, 2024, 45(14): 53-72.
Liu Y F, She J Y, Yuan Q F, et al. Real-time small target detection networks for UAV remote sensing[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(14): 53-72(in Chinese).

[9] 张光华, 李聪发, 李钢硬, 等. 基于改进 YOLOv7-tiny 的无人机航拍图像小目标检测算法[J]. 工程科学与技术, 2025, 57(3): 235-246.
ZHANG G H, LI C F, LI G Y, et al. Small target detection algorithm for UAV aerial images based on improved YOLOv7-tiny[J]. Advanced Engineering Sciences, 2025,57(3): 235-246(in Chinese).

[10] 桑嘉更, 张志佳, 肖传民, 等. 基于 YOLOv8s 模型改进的道路交通目标检测方法研究[J]. 红外与激光工程, 2024, 53(11): 20240256.
Sang J G, Zhang Z J, Xiao C M, et al. An improved YOLOv8s method and its application in road traffic target detection[J]. Infrared and Laser Engineering, 2024, 53(11): 20240256(in Chinese).

[11] 李子豪, 王正平, 贺云涛. 基于自适应协同注意力机制的航拍密集小目标检测算法[J]. 航空学报, 2023, 44(13): 239-249.
Li Z H, Wang Z P, He Y T. Aerial-photography dense small target detection algorithm based on adaptive cooperative attention mechanism[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(13): 239-249(in Chinese).

[12] 李耀华, 刘传召. 融合注意力机制的轻量化航空发动机表面缺陷检测算法[J]. 航空动力学报, 2025, 40(6): 20240096.
Li Y H, Liu C Z. Lightweight aero-engine surface defect detection algorithm fused with attention mechanism[J]. Journal of Aerospace Power, 2025, 40(6): 20240096(in Chinese).

[13] Wang J X, Liu M, Du Y R, et al. PG-YOLO: an efficient detection algorithm for pomegranate before fruit thinning[J]. Engineering Applications of Artificial Intelligence, 2024, 134: 108700.

[14] Zhu J X, Qin C, Choi D. YOLO-SDLUWD: YOLOv7-based small target detection network for infrared images in complex backgrounds[J]. Digital Communications and Networks, 2025, 11(2): 269-279.

[15] 王海燕. 基于图像识别的飞机蒙皮铆接质量检测技术研究[D]. 沈阳: 沈阳航空航天大学, 2019.
Wang H Y. Research on quality detection technology of aircraft skin riveting based on image recognition[D]. Shenyang: Shenyang Aerospace University, 2019(in Chinese).

[16] Xu G P, Liao W T, Zhang X, et al. Haar wavelet downsampling: a simple but effective downsampling module for semantic segmentation[J]. Pattern Recognition, 2023, 143: 109819.

[17] Xu C, Wang J W, Yang W, et al. Detecting tiny objects in aerial images: a normalized Wasserstein distance and a new benchmark[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2022, 190: 79-93.

[18] JOCHERG.UltralyticsYOLOv8[EB/OL].[2023-01-10].https://github.com/ultralytics/ultralytics.

[19] Ouyang D L, He S, Zhang G Z, et al. Efficient multi-scale attention module with cross-spatial learning[C]//Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE Press, 2023: 1-5.

[20] Wu F, Fan A, Baevski A, et al. Pay less attention with lightweight and dynamic convolutions[PP/OL]. arXiv (2019-02-22)[2024-09-01]. https://doi.org/10.48550/arxiv.1901.10430.

[21] Chen J Q, Chen K Y, Chen H, et al. A degraded reconstruction enhancement-based method for tiny ship detection in remote sensing images with a new large-scale dataset[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5625014.

Aircraft skin damage LHN-YOLO small target detection algorithm incorporating attention mechanisms

LI Yaohua*, CHEN Jie

(School of Transportation Science and Engineering, Civil Aviation University of China, Tianjin 300300, China)

Abstract: Aiming at the problems of low detection accuracy and a large number of parameters for small targets in aircraft skin damage detection, an LHN-YOLO algorithm incorporating the attention mechanism is proposed based on the YOLOv8n algorithm with aircraft skin rivet damage as the research object. To augment the model's capacity for detecting small targets, an optimized efficient multi-scale attention (EMA) mechanism is integrated into the backbone, with the EMA mechanism refined through the lightweight convolution LightConv, resulting in the Light-EMA module that enhances detection precision while minimizing computational complexity; concurrently, the Haar wavelet downsampling module and normalized Gaussian Wasserstein are incorporated to supplant the original model's downsampling module. Distance is introduced to replace the downsampling operation and CIoU loss function of the original model to improve the prediction performance. The results of the experiment reveal that the LHN-YOLO algorithm's average accuracy, recall, and precision are 92.7%, 87.0%, and 91.7%, respectively, which are improvements of 2.2%, 3.5%, and 2.8% over the original model, alongside a 10% reduction in parameters, significantly boosting the detection of small target damage on aircraft surfaces.

Keywords: YOLOv8n; attention mechanism; small target detection; rivet damage; skin damage detection

Received: 2024-09-27; **Accepted**: 2024-12-19; **Published Online**: 2025-02-18 15:03

URL: link.cnki.net/urlid/11.2625.V.20250218.1111.001

Foundation item: National Natural Science Foundation of China-Civil Aviation Joint Research Fund of Civil Aviation Administration of China (CAAC) Key Supporting Projects (U2033209)

* **Corresponding author**. E-mail: yh_li@cauc.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0540

基于改进时空模型的终端区多航班航迹预测方法

贺怀清*，史小爽，刘浩翰，惠康华
(中国民航大学 计算机科学与技术学院，天津 300300)

摘　　要：由于终端区历史航迹数据量较大、存在丰富的时空特征和航迹位置点数据突变等特点，使得在进行终端区4D航迹预测时充满不确定性和复杂性。为此，给出一种基于改进时空模型的解决方法。该模型包括3部分：将时间卷积网络(TCN)和双向门控循环单元(BiGRU)引入航迹预测领域，并对TCN进行改进，提出双层多尺度时间卷积网络MMTCN，分别从全局和局部2个方面提取时间特征；将层归一化和残差引入图注意力网络GAT，以捕捉航班之间的复杂空间依赖关系；针对航迹位置点数据突变导致的数据不确定性问题，将得到的时空特征输入到条件变分自编码器(CVAE)中，以学习航迹数据的潜在表示，生成多条预测轨迹。在训练过程中采用学习率调整策略，加速模型训练。实验结果表明：改进模型在平均位移误差(ADE)和最终位移误差(FDE)2个指标上均表现最优，分别为0.082 6和0.111 1，显著优于其他基准模型；在通用航空数据集上，所提模型的ADE和FDE误差最大降低了约9.59%和7.75%，表明该模型能够更有效地提取时空特征，且具有训练稳定性。

关 键 词：终端区；航迹预测；改进时空模型；双层多尺度时间卷积；不确定性
中图分类号：V355; TP391
文献标志码：A　　**文章编号**：1001-5965(2026)11-3745-13

在空中交通管理(air traffic management, ATM)中，传统的航班进离场管理均以当前航班位置点、扇区运行为判断基础，缺乏对航班未来航迹的准确预测，在外界因素(如其他空域用户活动或复杂天气)的扰动下，很容易出现预判错误的情况，从而导致运行效率和安全水平的大幅度降低。同时，现有进离场管理系统的航班排序少有引入人工智能技术，决策的智能化程度不高，运行机制也较为僵化，难以快速适应运行环境的变化，不利于保障能力和运行效率的提升。为此，欧美等航空发达国家提出的基于航迹运行(trajectory-based operation, TBO)模式概念越来越受到关注，因为其可实现在高密度、大流量、小间隔条件下的有效空域管理。而4D航迹预测是实现TBO的基础，精准的4D航迹预测可以推进智慧化空管的发展。

ATM的繁忙区域为终端区，其涵盖了航班降落和起飞过程中的关键航段。航班需要在终端区有限的空间内合理调整航迹，确保航班安全、高效地降落，并与其他航班协同运行。通过准确预测航班在这一区域的航迹，ATM系统可以更好地协调航班的运动，规划航班的降落和起飞顺序，提高机场容量，减少等待时间，提高航班出发和到达效率，实现更高效的交通管理，加速空管自动化与智能化技术的应用与实施。

当前的航迹预测方法主要分为3类：采用动力学模型进行航迹预测、利用状态估计方法建立航迹预测模型、利用深度学习方法进行航迹预测。面向的对象有单航班航迹预测和终端区多航班航迹预

收稿日期：2024-07-18；**录用日期**：2024-11-01；**网络出版时间**：2025-01-02 09:40
网络出版地址：link.cnki.net/urlid/11.2625.V.20241231.1432.001
基金项目：国家重点研发计划(2020YFB1600101)
*通信作者. E-mail：hqhe@cauc.edu.cn

引用格式：贺怀清，史小爽，刘浩翰，等. 基于改进时空模型的终端区多航班航迹预测方法[J]. 北京航空航天大学学报，2026，52(11)：3745-3757. He H Q，Shi X S，Liu H H，et al. Multi-flight trajectory prediction method in terminal area based on an improved spatio-temporal model[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3745-3757 (in Chinese).

测。单航班航迹预测能够准确地预测航班到达的时间及航迹点,在航班严重偏离航线时能及时发出警报。而终端区多航班航迹预测可以有效帮助管制员进行机场容量的调节,防止航班之间碰撞。传统的单航班航迹预测已无法满足高频次的终端区起降需求。因此,需要更准确、高效的多航班航迹预测方案,以应对复杂的终端区环境,并保障航班的安全运行。基于动力学方法[1-2]的航迹预测涉及大量参数,为简化模型,大多数研究是在理想假设下进行实验。因此,终端区多航班航迹预测研究主要集中在状态估计及机器学习或深度学习方法上。

在状态估计方法的研究中,Seah等[3]采用一种混合估计算法,开发了基于典型航班着陆剖面、起飞剖面和机场周围标准飞行路线的飞行模式转换方法。Lymperopoulos等[4]将多航班传感器融合问题表述为高维状态估计问题,并用实验证明了几种序列蒙特卡罗算法在涉及多航班问题可行性研究上的低效性,开发了一种新的粒子滤波算法来实现多航班航迹预测。Song等[5]利用数据挖掘提取航迹模式,通过聚类算法将具有相同时空特征的航迹聚类为一组,并采用混合估计算法进行航迹预测。Ayhan等[6]将空域视为三维网格网络,通过随机模型(即隐马尔可夫模型)来预测航迹点。状态估计算法通过不断地更新当前估计的状态,以适应传感器测量的新信息。因此,对传感器测量误差具有一定的鲁棒性。

基于深度学习的单航班航迹预测将航迹问题转换为时间序列问题,对大量历史航迹数据进行学习,从而预测未来航迹。目前,很多研究采用反向传播(back propagation, BP)神经网络、长短期记忆网络(long short-term memory, LSTM)、门控循环单元(gated recurrent unit, GRU)、时间卷积网络(temporal convolutional network, TCN)等进行航迹预测。Shi等[7]提出基于LSTM的航迹预测模型,LSTM中重复模块的4个交互层使其能够将长期依赖关系连接到当前的预测任务。Tran等[8]利用卷积层和GRU构建编码器和解码器结构进行建模,实现航迹预测。Huang等[9]提出一种基于TCN和双向门控循环单元(bidirectional gated recurrent unit, BiGRU)的新型航迹预测模型,并用贝叶斯算法对模型的超参数进行优化。焦卫东等[10]提出一种融合多尺度的TCN航迹预测方法,并通过时空双重注意力自适应地关注重要信息。

单航班航迹预测虽然只关注单个航班的时间特征趋势,但其也为多航班预测提供了研究基础。目前,越来越多的研究者利用深度学习处理多航班航迹预测问题。李楠等[11]提出一种基于遗传算法(genetic algorithm, GA)和BP神经网络的预测模型。针对4D航迹预测的实时性不强和存在迭代误差的问题,李旭娟等[12]提出了一种自动生成的条件变分自编码器(conditional variational autoencoder, CVAE)应用于终端区航迹预测。Zeng等[13]提出了一种序列间深度长短期记忆网络(sequence-to-sequence deep long short-term memory, SS-DLSTM),该网络可以有效地捕捉长短时间依赖关系和航迹之间的相似性。Xu等[14]提出一种基于社会长短期记忆网络(social long short-term memory, S-LSTM)的多航班航迹协同预测模型,通过建立池化层整合相关航班的隐藏状态,有效捕捉它们之间的交互。Pang等[15]提出了一种基于贝叶斯神经网络的3D航迹概率预测方法,但未考虑高度属性。除此之外,Pang等[16]还提出了基于Transformer的时空架构来模拟多个航班的空间和时间关系,并引入贝叶斯神经网络模拟航班之间的不确定性关系,但依旧未考虑航迹点的高度属性。Xu等[17]采用聚类算法挖掘典型的飞行模式,针对每类飞行模式训练时空卷积模型推断未来多个时间步长的航迹点。韩萍等[18]提出DBSCAN和GRU相结合的预测模型,使用聚类算法将航迹按照不同飞行模式进行聚类,并通过GRU对不同飞行模式航迹进行建模。尽管这些研究在航迹预测方面表现出一定的有效性,但聚类过程需要提前固定聚类参数,选择不合适的参数值可能导致航迹的聚类效果不佳,特别是在密度变化较大的区域。

综上所述,尽管目前先进的航迹预测方法在终端区航迹预测方面已经应用,但在预测维度上往往会忽略高度属性,在航迹生成时未考虑数据的不确定性,采用聚类算法时需要提前设置合适的参数值。本文针对以上问题,将改进时空模型应用在4D的航迹预测问题上。基于TCN的模型在并行处理、长时间依赖捕捉能力、梯度稳定性、参数共享和感受野灵活性方面均优于BP、LSTM和GRU,而基于BiGRU的模型能够提取双向特征信息。因此,本文模型以双层多尺度时间卷积网络MMTCN、BiGRU为基础提取航迹的时间特征;引入层归一化和残差的图注意力网络GAT提取终端区航班的交互信息,即航迹的空间特征;CVAE生成航迹分布解决数据不确定性。由此,该模型不会受到传感器的影响,不用提前选择参数值,是对时间、经度、纬度、高度的4D航迹预测,生成航迹时考虑了数据不确定性的影响。通过实验验证了模型在4D航迹预测方面的有效性。

1　航迹特征描述和数据预处理

1.1　数据源

本文实验数据源自上海浦东国际机场一周内的所有进出港航班，采样时间从 2023 年 7 月 1 日至 2023 年 7 月 7 日，采样时间间隔为 10 s，7 天共提取了 2 800 条以上海浦东国际机场为出发地或目的地的进出港航班飞行轨迹。经数据处理后，所有数据被划分为 179 个终端区飞行场景文件。随机选取部分场景终端区数据，其在数据重构和归一化前可视化结果如图 1 所示。

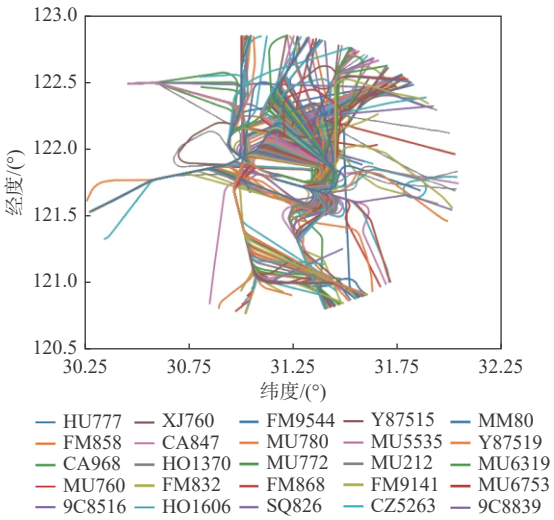


图 1　上海浦东国际机场部分场景终端区航迹

Fig. 1　Flight trajectory of some scene terminal areas of Shanghai Pudong International Airport

1.2　数据处理

1.2.1　提取终端区数据

根据《民用航空空中交通管理规则》(CCAR-93TM-R6)[19]，终端区域通常定义为水平范围 50 km 以内，垂直范围 6 000 m 以下、最低高度层以上。由于上海浦东国际机场与上海虹桥国际机场在同一个区，将水平范围划分在 100 km 以内。为方便预测，将经纬度转化为极坐标，删除高度超过 6 000 m 且距离机场超过 100 km 的数据点。

1.2.2　数据清洗和时序特征处理

由于传输错误、接收延迟、重复传输等原因，数据可能出现缺失、重复等问题。为了更好地训练，需要对数据进行清洗和重构，得到连续的时间序列数据。对于缺失问题，本文采用三次样条插值方法对数据进行插值处理，时间间隔为 10 s。对于重复问题，删除同一航班时间点重复的航迹数据。

1.2.3　数据重构

在进行归一化前，将“高度”属性值除以 1 000，减小数值幅度，能够提高模型的稳定性和收敛性。经纬度和高度属性值转化为直角坐标系下对应的坐标 x、y、z，方便后续预测。计算每个时间戳相对于第 1 个时间戳的时间差，整理成时间序列形式。为保证每个文件都是连续的时间序列，检查当前行的时间戳与前一行的时间戳之间的时间差是否大于 10 s，大于 10 s 就进行序列分割。最终，分割好的每个场景文件都是连续的时间序列。

1.2.4　数据归一化

对航迹数据中的 x、y、z 进行归一化处理，以消除不同特征间因量纲和类别不同而产生对数据分析结果的影响。本文采用最大-最小归一化方法，对 x 处理见式 (1)，对 y 和 z 采用类似处理。

$$x_i' = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \tag{1}$$

式中：$x_{\min}$ 为 x 维度的最小值；$x_{\max}$ 为 x 维度的最大值；x_i 为归一化前的数据；x_i' 为归一化后的数据。归一化后的数据分布在 [0,1] 区间内，并保持了原数据的完整性。

图 1 中的场景数据经上述数据处理后的航迹路线如图 2 所示。可以看出，一方面，上述数据处理操作不会破坏数据的整体空间布局，即该处理方法不会影响航迹预测的准确性；另一方面，终端区航迹比较复杂，在同一时间段内可能会有多个航班处于终端区范围内，为保证终端区起飞和降落安全及合理调度机场容量，准确的 4D 航迹预测是非常重要的。

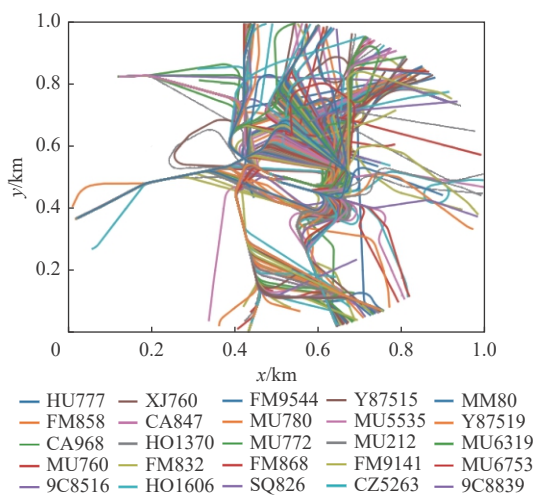


图 2　图 1 采用的数据经重构和归一化后的航迹数据

Fig. 2　Flight trajectory data after reconstruction and normalization of data used in Fig. 1

1.3　数据表示

假设预处理后航迹数据集合由 $\boldsymbol{I}$ 表示，如下：

$$\boldsymbol{I} = \{\boldsymbol{I}_1, \boldsymbol{I}_2, \cdots, \boldsymbol{I}_a, \cdots\} \qquad a \in R \tag{2}$$

式中：$\boldsymbol{I}_a$ 为航班 a 的航迹集合；R 为航班集合。

每条航迹由数量不等的航迹点组成，假设$\boldsymbol{d}_{ai}$表示航班a的第i个航迹点，航班a的航迹点集合如下：

$$\boldsymbol{I}_a=\{\boldsymbol{d}_{a1},\boldsymbol{d}_{a2},\cdots,\boldsymbol{d}_{ai},\cdots\} \tag{3}$$

每个航迹点包括时间、航班号、经度、纬度、高度所对应的直角坐标系下的坐标，如下：

$$\boldsymbol{d}_{ai}=(c_t,c_{\mathrm{id}},c_x,c_y,c_z) \tag{4}$$

式中：c_t为采样时间；c_{id}为航班号；c_x、c_y、c_z分别为经度、纬度、高度在直角坐标系下对应坐标。

2 改进时空模型

2.1 改进思想

航迹含有丰富的时空特征，通常情况下，航迹预测模型提取的时空特征越丰富，其预测结果越准确。因此，为了能够充分提取航迹数据的时间特征，根据对现有时间序列预测模型的分析，本文采用TCN和BiGRU。但是，随着TCN网络层数的增加，感受野也增大，较大的感受野会导致卷积应用在较大的时间跨度上，难以提取局部信息。因此，本文在TCN基础上引入双扩张层(dual dilated layer, DDL)[20]，既能考虑长期依赖关系，也能考虑短期依赖关系。DDL使用不同的卷积核提取多尺度信息，从而得到MMTCN。而BiGRU能够同时捕捉序列数据的前向和后向信息，从而更好地理解和预测序列中的模式。采用GAT提取航迹序列的空间特征，并受Transformer的启发，在GAT中引入层归一化和残差，提高模型收敛能力。针对航迹位置点数据突变导致的数据不确定性问题，使用CVAE去捕捉这种分布并学习航迹数据的潜在表示，通过采样的方式生成多条预测轨迹。为了下文叙述方便，将本文模型命名为改进时空预测模型(improved spatio-temporal prediction model, ISPM)。

2.2 模型结构

ISPM模型共包含3个核心部分：时间特征学习部分、空间特征学习部分及预测轨迹生成部分。模型的总体结构如图3所示。

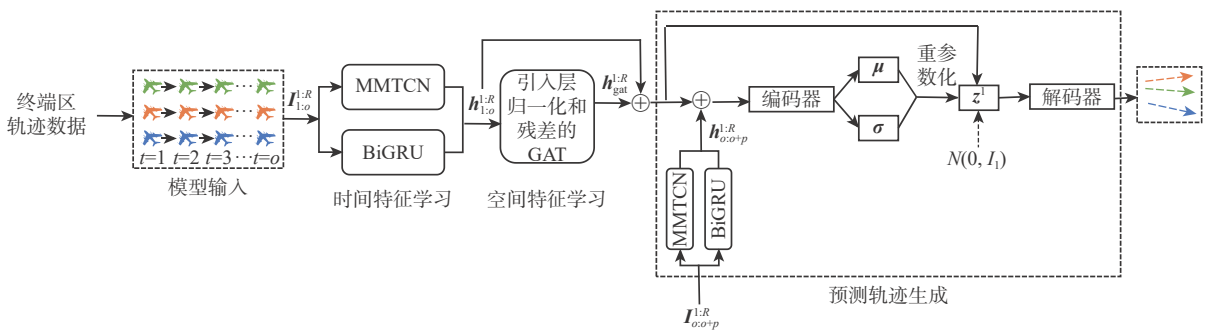


图3 ISPM模型的总体结构

Fig. 3 Overall structure of ISPM model

2.2.1 网络的输入

考虑预测某段时间内所有航班的未来航迹分布问题，设$\boldsymbol{I}_t^a=(x_t^a,y_t^a,z_t^a)$表示$t$时刻航班$a$的位置信息，并令$\boldsymbol{I}_{t_1:t_2}^{1:R}$表示$t_1\sim t_2$时间范围内所有航班的位置集合，上标表示航班集合，下标表示时间段。将航迹预测问题定义为：根据历史航迹信息$\boldsymbol{I}_{1:o}^{1:R}$找到未来航迹的分布$\boldsymbol{I}'^{1:R}_{o:o+p}$。

2.2.2 时间特征学习部分——MMTCN+BiGRU

时间特征学习是模型中用于处理时间序列信息的层，主要包含2个模块：MMTCN模块和BiGRU模块，以更全面地捕获时间序列数据中的特征和模式。

MMTCN模块是在传统TCN基础上引入了双层多尺度卷积。传统的TCN由残差结构组成，如图4所示。图中，残差连接由2个膨胀因子相同的卷积层组成，并采用权重初始化和正则化层解决梯度消失或爆炸问题。卷积操作后，通过残差连接将输入与卷积输出进行相加，即通过跨层连接来传递信息。膨胀卷积是在标准的卷积里注入空洞，以此来增加感受野。膨胀卷积的结构如图5所示。逐层膨胀因子d以2的指数增长，使得高层的感受野变大，很大的感受野会导致卷积应用在很大的时间跨度上，从而捕捉长期依赖关系，而短期的依赖关系很容易被忽略。因此，针对该问题，MMTCN在TCN基础上引入DDL和多尺度卷积。DDL结合了2种不同的膨胀卷积以增加模型对时间序列中长期和短期依赖关系的捕捉能力。DDL由2个并行的膨胀卷积层组成，每层使用不同的膨胀因子和卷积核。一个膨胀因子逐层递增捕捉长期依赖关系，另一个膨胀因子逐层递减更好地捕捉短期依赖关系，最终对提取的特征进行融合。MMTCN的结构如图6所示。

BiGRU是一种改进的循环神经网络(recurrent neural network, RNN)结构，如图7所示。通过结合2个独立的GRU层，一个沿正向处理序列，另一个

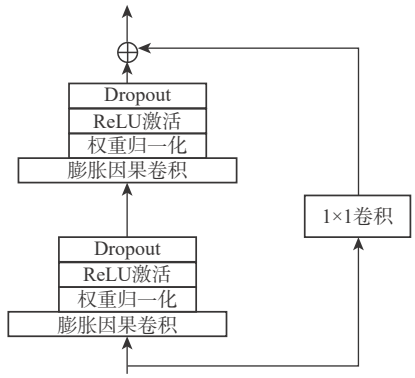


图 4　TCN 的残差结构

Fig. 4　Residual structure of TCN

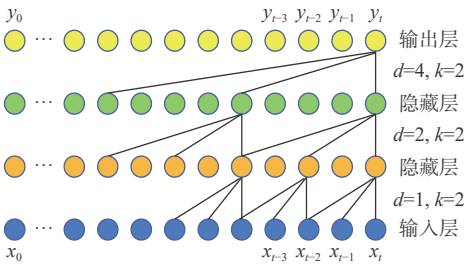


图 5　膨胀卷积结构

Fig. 5　Structure of dilated convolutional

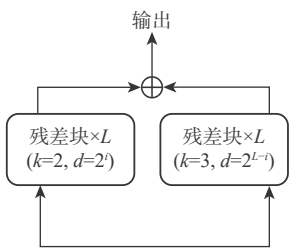


图 6　MMTCN 结构

Fig. 6　Structure of MMTCN

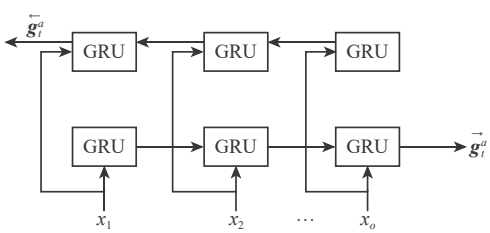


图 7　BiGRU 结构

Fig. 7　Structure of BiGRU

沿反向处理序列，增强了对时间序列数据中长距离依赖关系的捕捉能力。从图 7 可以看出，输入序列数据 $\boldsymbol{I}_{1:o}^{a}$ 得到正向隐藏状态输出 $\overrightarrow{\boldsymbol{g}}_t^a$ 和反向隐藏状态输出 $\overleftarrow{\boldsymbol{g}}_t^a$。BiGRU 通过双向处理序列数据，能够捕捉更复杂的时间模式和长距离依赖关系，从而提高预测的准确性。

2.2.3　空间特征学习部分——GAT*

GAT 通过引入注意力机制，为每个节点计算其邻居节点的重要性权重，根据这些权重来聚合邻居节点的空间位置和关系，即学习节点的空间特征。但随着网络深度的加深，网络参数更新可能导致训练不稳定，训练时往往需要很长时间收敛。因此，受 Transformer 启发，为提高训练效率，对 GAT 进行改进，得到 GAT*。Transformer 在进行自注意力后，使用残差连接和层归一化来加速训练和提高模型性能。类似地，可以将残差连接和层归一化引入到 GAT 中，以加速梯度传播和模型收敛，并降低训练过程中的梯度消失问题。与 GAT 一样，GAT*引入了注意力机制，使得每个航班节点可以根据与邻居节点的关系动态地分配不同的注意力权重，使得模型能够更加灵活地捕获节点之间的相互影响。GAT*网络结构如图 8 所示，图中，不同颜色代表多个头部，多个头部计算完注意力权重后进行拼接得到最终的输出特征。

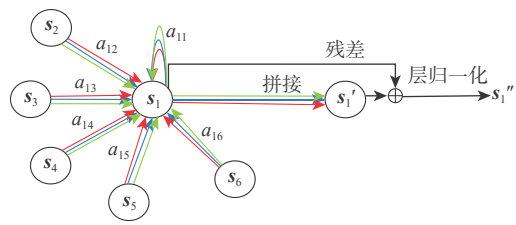


图 8　GAT*网络结构

Fig. 8　Structure of GAT* network

GAT*输入节点特征集合表示为

$$\boldsymbol{s}=\{\boldsymbol{s}_1,\boldsymbol{s}_2,\cdots,\boldsymbol{s}_i,\cdots\} \tag{5}$$

式中：$\boldsymbol{s}_i$ 为 i 航班初始节点特征向量。

经过 GAT*得到最终的嵌入向量集合，如下：

$$\boldsymbol{s}''=\{\boldsymbol{s}_1'',\boldsymbol{s}_2'',\cdots,\boldsymbol{s}_i'',\cdots\} \tag{6}$$

本文使用权值矩阵 $\boldsymbol{W}$ 作用在每个航班节点，用式 (7) 计算每个节点的权重系数：

$$e_{ij}=\frac{\mathrm{LeakyReLU}(\boldsymbol{a}_1^{\mathrm{T}}[\boldsymbol{W}\boldsymbol{s}_i\|\boldsymbol{W}\boldsymbol{s}_j])}{\sqrt{d_{\mathrm{model}}}}\qquad j\in N_i \tag{7}$$

式中：d_{model} 为 GAT*输入时嵌入向量的维度；$\boldsymbol{a}_1^{\mathrm{T}}$ 为可学习的参数向量；N_i 为节点 i 的邻居节点。

使用 Softmax 函数对当前航班节点的邻居节点做归一化处理。归一化后的权重系数为

$$\alpha_{ij}=\mathrm{softmax}(e_{ij})=\frac{\exp(e_{ij})}{\sum_{j\in N_i}\exp(e_{ij})} \tag{8}$$

为稳定注意力机制的学习过程，GAT*选择使用多头注意力层。最终计算得到输出特征为

$$\boldsymbol{s}_i'=\mathrm{sigmoid}\left(\frac{1}{K}\sum_{k=1}^{K}\sum_{j\in N_i}\alpha_{ij}^{k}\boldsymbol{W}^{k}\boldsymbol{s}_j\right) \tag{9}$$

式中：$\boldsymbol{s}_i'$ 为融合了邻域信息的嵌入向量；sigmoid为激活函数；K 为多个头部。

引入残差连接和层归一化后的嵌入向量 $\boldsymbol{s}_i''$ 为

$$\boldsymbol{s}_i''=\mathrm{LayerNorm}(\boldsymbol{s}_i+\boldsymbol{s}_i') \tag{10}$$

GAT*为每个节点生成嵌入向量$\boldsymbol{s}_i''$。这些嵌入向量综合了节点自身的特征及其邻居节点的特征，反映了每个节点的空间位置和关系。这可以表示航班节点在空间中的位置及其运动趋势。

2.2.4 预测轨迹生成部分

在航迹数据中固然存在一些不确定性，对潜在变量$\boldsymbol{z}^1$进行多次采样，通常是为了在给定相同的输入和条件下，生成多样化的输出。据此，CVAE方法利用了变分自编码器潜在空间中的随机性来生成不同的样本，从而可以更好地捕捉数据分布中的多样性，其结构如图9所示。

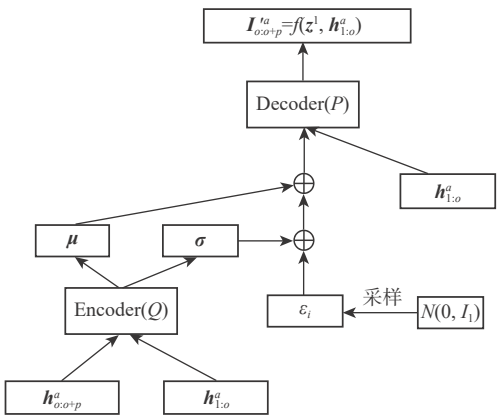


图9 CVAE网络结构

Fig. 9 Structure of CVAE network

将提取到的观察值特征$\boldsymbol{h}^a_{1:o}$作为数据内容，提取到的目标值特征$\boldsymbol{h}^a_{o:o+p}$作为标签一同输入CVAE的编码器Encoder(Q)中。Encoder(Q)的任务是将输入数据映射到潜在空间中的分布参数：均值向量$\boldsymbol{\mu}$和方差向量$\boldsymbol{\sigma}$。模型训练时，需要从学习到的潜在分布中采样，为使模型可微分，通常使用重参数化技巧。重参数化技巧是从标准正态分布$N(0,I_1)$中采样得到多个随机变量ε_i，随机变量ε_i与$\boldsymbol{\mu}$和$\boldsymbol{\sigma}$结合起来，得到多个潜在空间中的样本点$\boldsymbol{z}_i^1=\boldsymbol{\mu}+\varepsilon_i\boldsymbol{\sigma}$。从潜在空间中采样得到的样本点$\boldsymbol{z}_i^1$和观察值特征$\boldsymbol{h}^a_{1:o}$一同输入到解码器Decoder($P$)，生成多个预测值。

2.3 网络的输出和损失

在2.2.4节所述采样过程中，设置采样次数为M，即对于输入数据，经过M次采样后得到M个不同的随机变量ε_i，分布参数和对应的随机变量结合后得到不同的潜在空间样本点$\boldsymbol{z}_i^1$。最终进入解码器生成M组不同的航迹数据，并计算M条航迹与真实航迹的损失，选择损失最小的一条航迹作为最终预测结果。

CVAE的损失函数由2部分组成，即重构损失和KL散度。

$$L^{\mathrm{Loss}}=L_{\mathrm{RL}}^{\mathrm{Loss}}+L_{\mathrm{KL}}^{\mathrm{Loss}} \tag{11}$$

式中：L^{Loss}为整体损失；$L_{\mathrm{RL}}^{\mathrm{Loss}}$为重构损失；$L_{\mathrm{KL}}^{\mathrm{Loss}}$为KL散度。

重构损失是衡量解码器生成数据与原始数据之间的差异，使用均方误差(mean squared error, MSE)来计算：

$$L_{\mathrm{RL}}^{\mathrm{Loss}}=\left\|\boldsymbol{I}^a_{o:\,o+p}-\boldsymbol{I}'^a_{o:\,o+p}\right\|^2 \tag{12}$$

式中：$\boldsymbol{I}^a_{o:\,o+p}$为实际目标值；$\boldsymbol{I}'^a_{o:\,o+p}$为预测值。

KL散度可以衡量潜在分布与标准正态分布之间的差异，促使学习到的潜在分布接近于标准正态分布：

$$L_{\mathrm{KL}}^{\mathrm{Loss}}=\mathrm{KL}\{N(\boldsymbol{\mu},\boldsymbol{\sigma}),N(0,I_1)\} \tag{13}$$

式中：$N(\boldsymbol{\mu},\boldsymbol{\sigma})$为潜在空间分布；$N(0,I_1)$为标准正态分布。

2.4 模型训练时学习率的调整策略

适当的学习率(learning rate, LR)可以帮助模型更快地收敛到最优解，从而提高预测精度。如果学习率过高，可能导致模型在参数空间中跳跃太大，错过最优解，甚至无法收敛。如果学习率过低，模型更新的步长太小，可能会导致训练过程非常缓慢，甚至停滞不前。采用合适的学习率调整策略可以在训练过程中平衡速度和精度。

学习率调整策略可以分为如下4种：

1) 固定学习率。在整个训练过程中，保持学习率不变。这是最简单的策略之一，但在训练过程中可能无法很好地适应模型参数的变化。固定学习率为0.001，其他动态学习率初始值也为0.001。

2) 学习率衰减。随着训练的进行，逐渐减小学习率。LambdaLR是一种自定义学习率调整策略，定义lambda函数为1/(e+1)，随着e的增加(e为训练轮数)，学习率会按照该函数的规则进行调整。

3) 学习率增加。在训练初期逐渐增加学习率，这可以帮助模型更快地找到合适的参数范围。ConstantLR在设置的周期内将初始学习率乘以0.1，设置的周期外恢复原学习率。

4) 其他调整策略。①CosineAnnealingLR是余弦退火学习率，在训练周期内通过一系列的学习率循环来调整学习率，而不是像其他调整策略那样单调地递减或递增学习率，因为最佳学习率可能会出现在上升或下降过程中。该策略余弦周期设为20，学习率最小值设为0.000 1，最大设为0.001。②ReduceLROnPlateau根据性能指标自动调节学习率，当性能指标停止改善时，其会逐渐减小学习率，以便模型更好地收敛。

不同的学习率调整策略导致ISPM模型训练时的学习率变化趋势如图10所示。

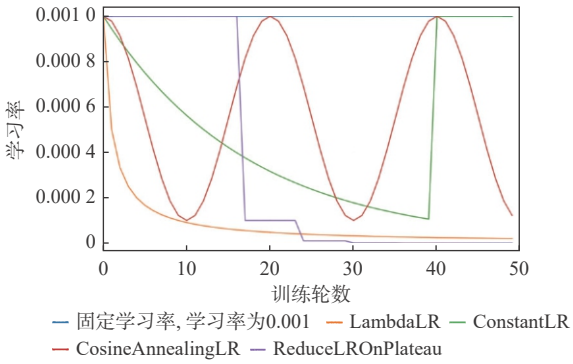


图 10　不同学习率调整策略的学习率变化趋势

Fig. 10　Trends in learning rates for different learning rate adjustment strategies

图 11～图 13 为采用不同的学习率调整策略得到的 ISPM 模型训练损失、平均位移误差 (average displacement error, ADE) 和最终位移误差 (final displacement error, FDE)。

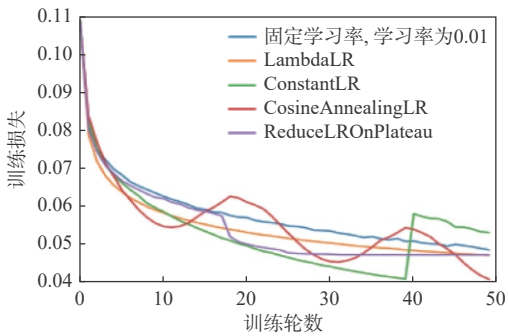


图 11　不同学习率调整策略的训练损失变化趋势

Fig. 11　Trends in training loss for different learning rate adjustment strategies

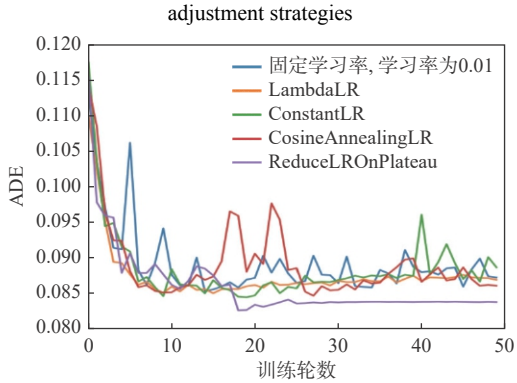


图 12　不同学习率调整策略的 ADE 变化趋势

Fig. 12　ADE trends of different learning rate adjustment strategies

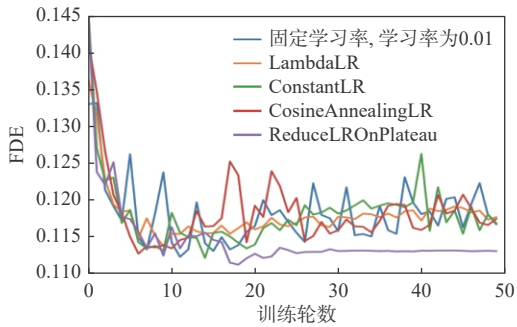


图 13　不同学习率调整策略的 FDE 变化趋势

Fig. 13　FDE trends of different learning rate adjustment strategies

综上所述，动态的学习率调整策略要比固定的学习率更有效，且经过实验测试，ReduceLROnPlateau 是 ISPM 模型最适合的学习率调整策略，因为其在降低训练和测试损失方面提供了良好的平衡，确保了模型的良好泛化和稳定性。

3　实　验

实验步骤包括数据处理、数据集划分、模型训练过程、结果评估和分析等，详见图 14。

3.1　实验数据和实验环境

航迹数据按时间顺序分布，经第 1 部分处理后的数据样本示例如表 1 所示。表中，时间列是处理后的，时间间隔 1 表示 10 s，后 3 列表示归一化后的直角坐标系下的经纬度和高度坐标。每条航班的时间总步各不相同。每个航迹点包含航班号、时间、经度、纬度和高度信息，以前 5 天的数据作为训练集，后 2 天的数据作为测试集。实验基于 Ubuntu 18.04 系统搭建，使用 Python 3.7.16 语言与 PyTorch1.7.0(CUDA10.1)深度学习框架，开发工具为 VS Code；硬件搭载 Intel Xeon Silver 4214 CPU、Quadro RTX 5000 GPU，内存容量 32 GB。

3.2　试验超参数设置

超参数的设置对模型的训练至关重要，合适的参数设置才能发挥出模型的较大潜力。本文模型超参数设置均源于实验测试，最终结果如表 2 所示。

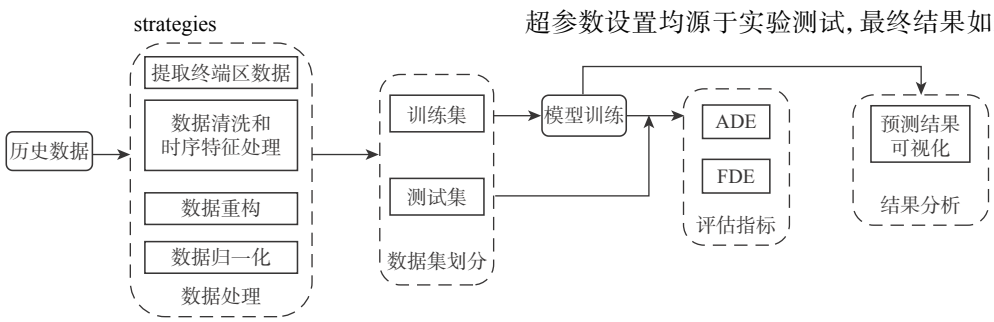


图 14　航迹预测实验过程

Fig. 14　Process of flight trajectory prediction experiment

表1 航迹数据样本示例

Table 1 Sample example of flight trajectory data

时间	航班号	x	y	z
364	MM898	0.525 287 060 658 0	0.755 073 711 662 53	0.670 43
365	MM898	0.531 720 409 931 5	0.762 855 410 616 43	0.692 91
366	MM898	0.537 913 300 176 0	0.770 273 390 965 28	0.719 70
367	MM898	0.544 069 273 704 9	0.777 706 549 421 61	0.737 87
368	MU779	0.487 693 439 718 6	0.509 826 542 767 41	0.070 76
368	MM898	0.550 259 272 881 3	0.785 354 425 281 30	0.748 79
369	MU779	0.483 954 572 085 1	0.511 351 278 489 04	0.094 10
369	MM898	0.556 525 940 959 7	0.793 172 262 586 36	0.756 92
370	MM898	0.562 468 920 606 6	0.801 642 702 915 90	0.762 63
370	MU779	0.480 143 921 949 0	0.512 975 391 587 61	0.111 63

表2 模型超参数设置

Table 2 Model hyperparameter settings

参数	数值
TCN卷积层输出的总通道数	256
TCN层数	2
TCN中卷积核的大小	[2,3]
TCN中的膨胀系数(i为卷积层数, G为总层数)	$[2^i, 2^{(G-1-i)}]$
TCN中的Dropout	0.2
BiGRU网络层数	2
BiGRU中隐藏层大小	128
GAT*中的注意力头数量	16
GAT*模型中隐藏层大小	256
GAT*中激活函数的负斜率参数	0.2
CVAE中隐藏层大小	128
CVAE中卷积层输出的通道数	128
CVAE网络层数	2
采样次数M	5

3.3 实验类型和指标

通过对比实验、参数敏感性实验验证ISPM模型的收敛性、准确性和时空特征提取的强有效性，以及历史时间步长对预测结果的影响，并通过消融实验验证各功能模块的作用。

本文评价指标采用ADE和FDE。目前，航迹预测常用的指标有平均绝对误差(mean absolute error, MAE)和MSE。MAE和MSE衡量经纬度和高度3个维度上真实值与预测值之间差异的整体情况，但在轨迹预测中，MAE和MSE没有针对性地考虑轨迹的时间序列特性及最终位置的准确性，无法很好地体现轨迹预测的关键要点。经过文献查阅比较，最终本文采用了行人轨迹预测中常用的ADE和FDE。

ADE为在所有时间上真实航迹和预测航迹之间的平均位移误差：

$$A_m^{\mathrm{ADE}} = \frac{1}{R}\cdot\frac{1}{T}\min_{m=1}^{M}\sum_{a=1}^{R}\sum_{t=o}^{o+p}\left\|\boldsymbol{I}_t^{a,m}-\boldsymbol{I}_t^{a,m}\right\|^2 \tag{14}$$

式中：$\boldsymbol{I}_t^{a,m}$为真实航迹；$\boldsymbol{I}_t^{a,m}$为预测航迹；T为时间段内时间点的数量；A为这段时间内所存在的航班数。

FDE表示最终时间的真实航迹和预测航迹之间的位移误差：

$$F_m^{\mathrm{FDE}} = \frac{1}{R}\min_{m=1}^{M}\sum_{a=1}^{R}\left\|\boldsymbol{I}_{o+p}^{a,m}-\boldsymbol{I}_{o+p}^{a,m}\right\|^2 \tag{15}$$

3.3.1 实验1

随着训练轮次的增加，收敛良好的模型的损失函数值逐渐减少并趋于稳定，这表明模型在训练数据上的表现越来越好。在TCN基础上进行实验，并通过损失函数曲线分析模型的收敛性。

为简化实验，初始模型为TCN-GAT-CVAE，实验结果如图15所示。图中，蓝线Traj表示初始模型，学习率固定为0.001，可以看出，训练损失上下震荡非常大；橙线Traj+lr1是在初始模型基础上调整测试损失计算方式，并加入了学习率调整策略，初始测试损失计算方式是先对所有航班预测结果进行采样，找到采样的最优解，但对于不同的航班预测结果来说，可能最优解出现在不同的采样中，因此，选择对不同的航班预测轨迹分别采样；绿线Traj+lr1+AN表示在Traj+lr1方案基础上加入了层归一化和残差，可以加速模型的训练过程，使其更快地收敛。根据图15的结果，在模型中引入学习率调整策略及在GAT中引入层归一化及残差对加速模型收敛是有效的，其始终显示出最低的训练损失，并且相较于其他2种方式可以更快地稳定。

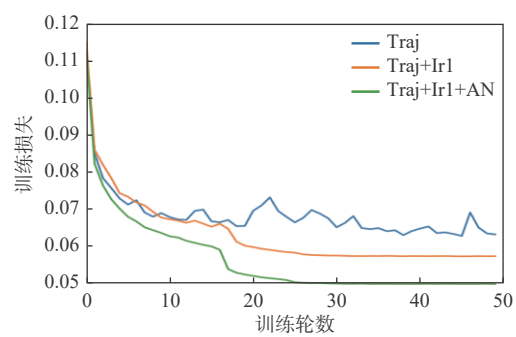


图15 模型训练过程收敛性对比实验分析

Fig. 15 Comparative experimental analysis of convergence of model training process

为验证模型性能，将本文模型与X-GAT*-CVAE在上海浦东国际机场数据集上做对比实验，所选基准模型X为LSTM、GRU、BP等网络，实验结果如表3所示。观察值时间步长为12，预测步长为60，

表 3　不同模型对比实验分析

Table 3　Comparative experimental analysis of different models

模型	ADE	FDE
BP-GAT*-CVAE	0.093 8	0.118 4
LSTM-GAT*-CVAE	0.089 9	0.121 9
GRU-GAT*-CVAE	0.089 5	0.121 2
ISPM	0.082 6	0.111 1

预测结果以每 6 个时间步输出一次。实验结果表明，ISPM 模型的预测误差低于所有基准模型，表明其在提取时空特征方面更有效。

以测试集中的一个场景为例进行可视化，可视化前需要将航迹数据进行反归一化，反归一化后的航迹是直角坐标系的坐标。可视化结果如图 16～图 19 所示。从该场景可视化结果分析，存在航班为 1,2,3,4 的情况，既包含了单航班，也包含了多航班的情况。因此，可以说明该模型既可以处理单航班 4D 航迹预测，也可以处理多航班 4D 航迹预测问题。且从可视化结果可以看出，ISPM 模型比其他基准模型的预测结果都更接近真实航迹。

3.3.2　实验 2

历史数据长度对航迹预测模型的精度影响很大，其决定了模型能够利用多少历史数据来进行预测。如果历史数据的长度较短，无法更好地捕捉数据的长期趋势和模式；如果历史数据的长度较长，可能会导致模型过度拟合历史数据，降低对未来数据的泛化能力。因此，在预测长度和其他参数不变的情况下，预测结果以每 6 个时间步输出一次，相当于预测间隔为 1 min。对不同长度历史数据进行实验对比，相关分析结果如表 4 所示。当观察时间步长为 12 时，预测结果最优。

3.3.3　实验 3

为证明模型的普适性，将本文模型运用在通用航空数据集中。该数据集是匹兹堡-巴特勒地区机场无塔式航站楼空域中的航迹数据，共包含 4 个连续 7 天的子数据集：7days1、7days2、7days3、7days4。由于该数据集考虑了天气属性，为方便和通用航空模型 Trajairnet[21] 作对比实验，本文在 ISPM 模型的结构上使用 CNN 提取天气特征。历史时间步长为 11，预测时间步长为 120，时间间隔为 1 s。实验对比结果如表 5 所示，实验证明模型在通用航空数据

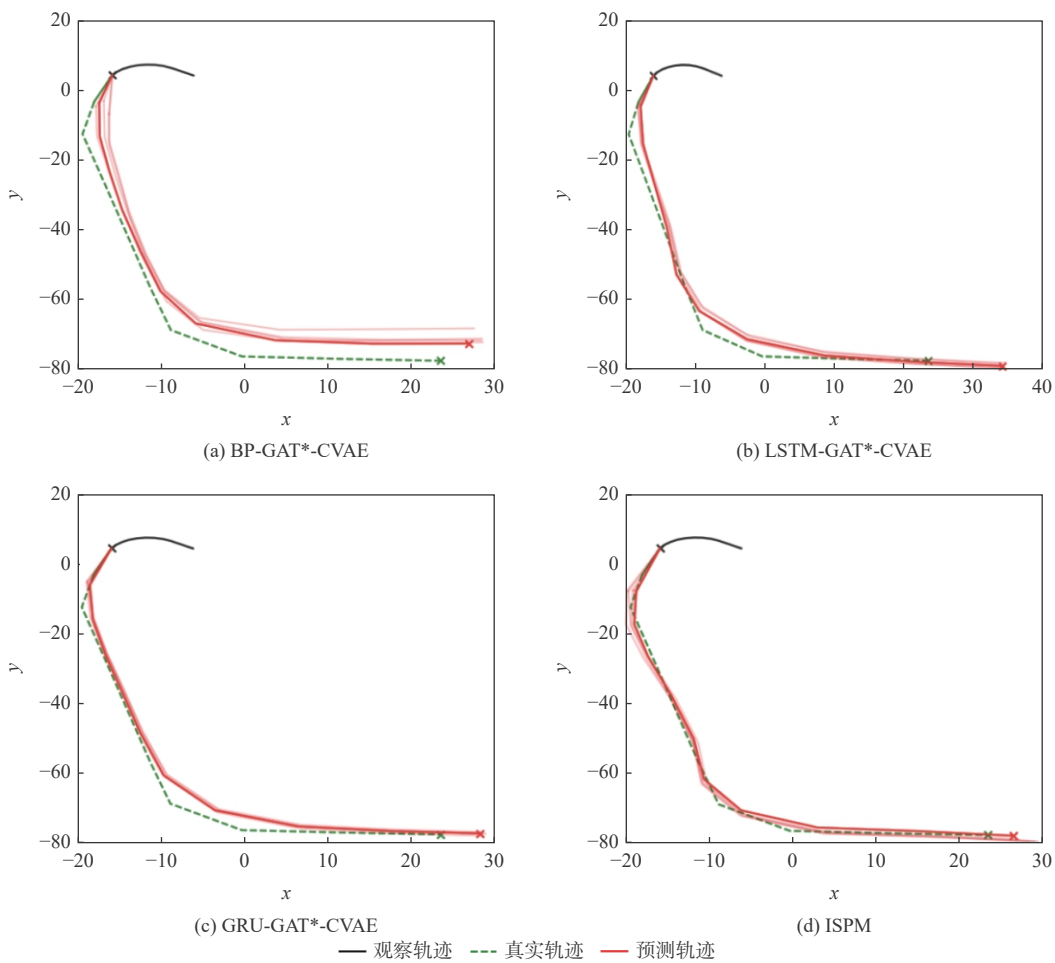


图 16　场景中只有 1 个航班时不同模型对比结果

Fig. 16　Comparison results of different models when there is one flight in the scene

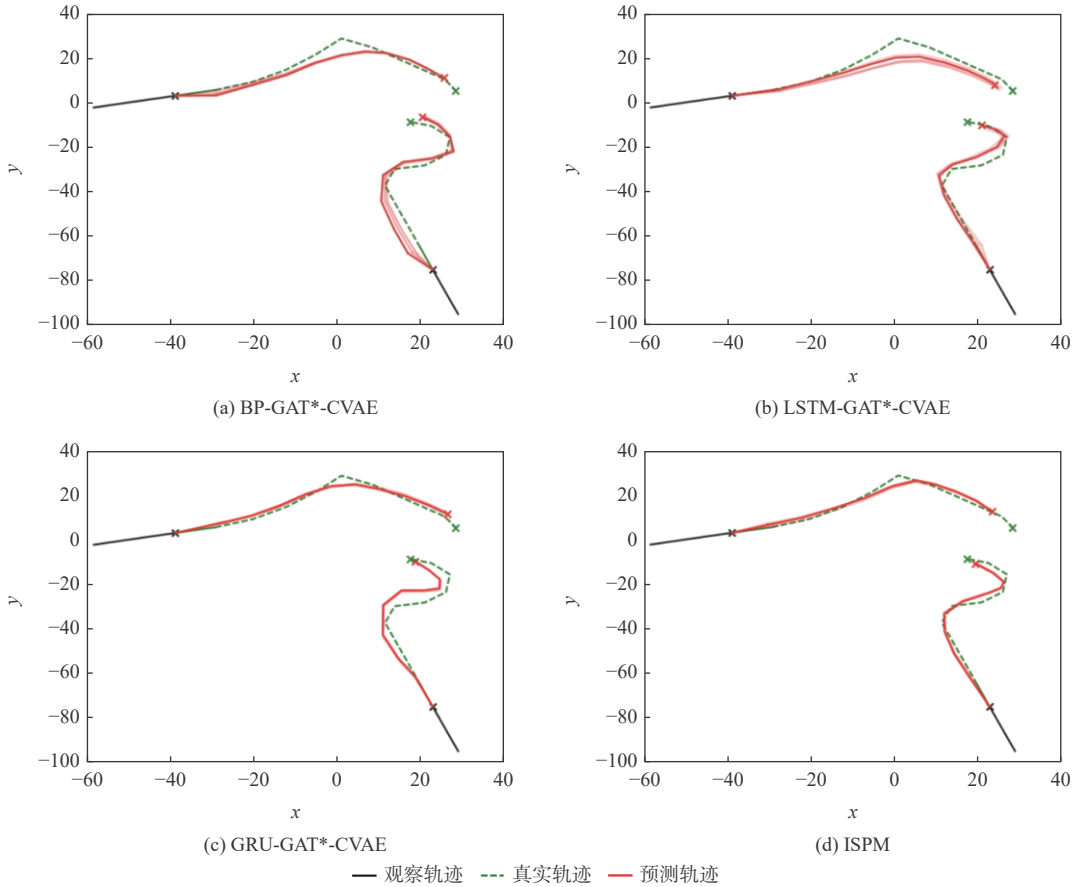


图 17 场景中有 2 个航班时不同模型对比结果

Fig. 17 Comparison results of different models when there are two flights in the scene

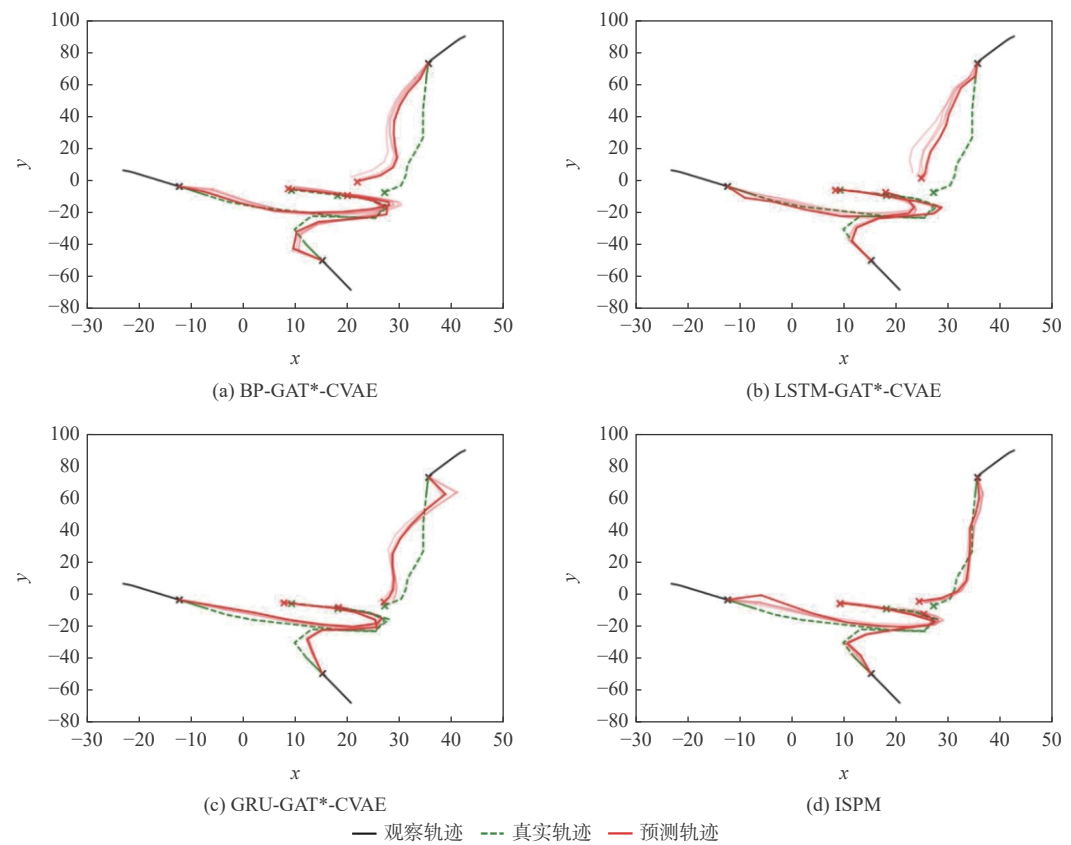


图 18 场景中有 3 个航班时不同模型对比结果

Fig. 18 Comparison results of different models when there are three flights in the scene

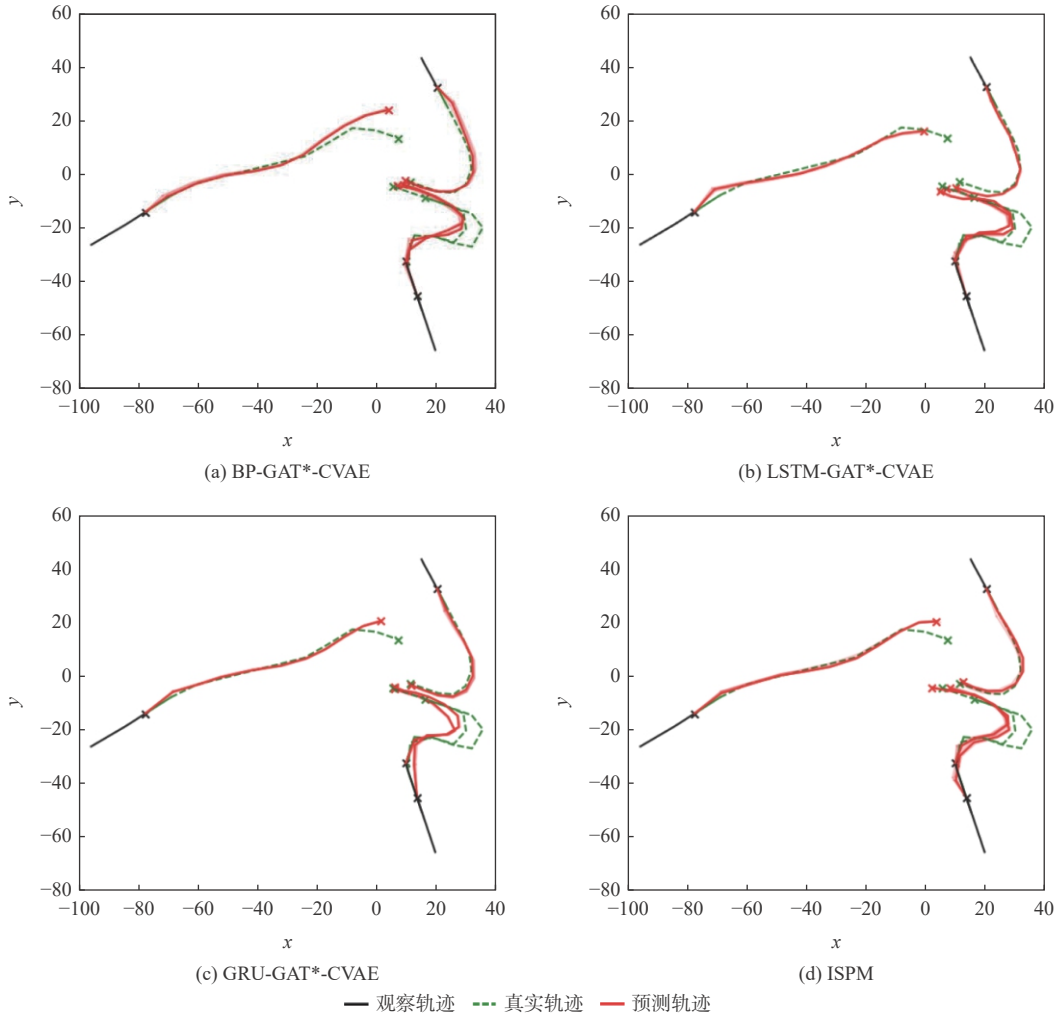


图 19　场景中有 4 个航班时不同模型对比结果

Fig. 19　Comparison results of different models when there are four flights in the scene

表 4　历史数据的长度敏感性分析

Table 4　Length sensitivity analysis of historical data

历史数据长度	预测时间步长	时间步	ADE	FDE
8	60	6	0.091 3	0.124 3
12	60	6	0.082 6	0.111 1
24	60	6	0.088 1	0.111 9
36	60	6	0.095 4	0.116 9

表 5　通用航空数据集上的对比结果

Table 5　Compare results on general aviation datasets

模型	数据集	ADE	FDE
Trajairnet	7days1	0.73	1.42
	7days2	0.81	1.63
	7days3	0.86	1.72
	7days4	0.71	1.41
ISPM	7days1	0.66	1.31
	7days2	0.73	1.44
	7days3	0.83	1.65
	7days4	0.66	1.33

集上的表现也较好。

3.3.4　实验 4

实验 1 已对本文模型与基线模型做了对比实验，结果说明了模型的有效性。为验证本文模型改进模块的作用，进行了一系列的消融实验。以 ISPM 模型为基础，分别移除 BiGRU、MMTCN、多尺度、DDL 等模块，实验结果如表 6 所示。表中：ISPM-B 模型是在整体的基础上去除 BiGRU，ISPM-T 模型是在原模型基础上去除 MMTCN 模块，ISPM-M 是在原模型基础上去除多尺度卷积，ISPM-D 是在原模型基础上去除 DDL。由表 6 表明，移除任何一个模块，实验预测精度都会有一定程度的下降，这说明每个模块对模型的预测性能都起到了一定的作用。

表 6　消融实验结果

Table 6　Results of ablation experiments

功能模块	ADE	FDE
ISPM-B	0.083 9	0.111 7
ISPM-T	0.085 4	0.113 7
ISPM-M	0.085 2	0.115 4
ISPM-D	0.084 6	0.114 2
ISPM	0.082 6	0.111 1

4 结 论

本文提出一种改进时空模型ISPM用于解决终端区4D航迹预测问题，基于航迹数据集完成对比实验，实验结果在2个评价指标ADE和FDE上均优于基准模型。主要结论如下：

1）ISPM模型架构的创新。融合了MMTCN和BiGRU的优势，以提取序列数据的时间特征；采用GAT计算当前航班的权重矩阵，提取空间特征；引入Transformer的设计理念，在GAT中加入残差连接和层归一化处理，以调节训练过程中的不稳定性。

2）训练策略。训练过程中采用学习率调整策略，提高了模型的收敛性和预测准确性。

3）模型性能。ISPM与X-GAT*-CVAE在上海浦东国际机场数据集上做对比实验，所选基准模型X为LSTM、GRU、BP等较为先进的航迹预测模型，实验结果表明，ISPM比其他基准模型的预测结果都更接近真实航迹。

4）模型的普适性。更换数据集，ISPM与通用航空模型Trajairnet在通用航空数据集上做对比实验，ISPM模型实验结果优于Trajairnet。

ISPM没有考虑天气、航空器故障等不确定性因素及航速航向对航迹预测的影响，因此下一步工作将解决这些问题，以进一步提升预测精度；同时探索在线更新模型参数的方式以便面对新的数据时能够及时调整和优化，进一步提升终端区航迹预测的准确性。

参考文献（References）

[1] Tang X M, Han Y X. 4D trajectory estimation for air traffic control automation system based on hybrid system theory[J]. PROMET-Traffic& Transportation, 2012, 24(2): 91-98.

[2] Lee J, Lee S, Hwang I. Hybrid system modeling and estimation for arrival time prediction in terminal airspace[J]. Journal of Guidance, Control, and Dynamics, 2016, 39(4): 903-910.

[3] Seah C E, Hwang I. Terminal-area aircraft tracking using hybrid estimation[J]. Journal of Guidance, Control, and Dynamics, 2009, 32(3): 836-849.

[4] Lymperopoulos I, Lygeros J. Sequential Monte Carlo methods for multi-aircraft trajectory prediction in air traffic management[J]. International Journal of Adaptive Control and Signal Processing, 2010, 24(10): 830-849.

[5] Song Y, Cheng P, Mu C D. An improved trajectory prediction algorithm based on trajectory data mining for air traffic management[C]//Proceedings of the IEEE International Conference on Information and Automation. Piscataway: IEEE Press, 2012: 981-986.

[6] Ayhan S, Samet H. Aircraft trajectory prediction made easy with predictive analytics[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2016: 21-30.

[7] Shi Z Y, Xu M, Pan Q, et al. LSTM-based flight trajectory prediction[C]//Proceedings of the International Joint Conference on Neural Networks. Piscataway: IEEE Press, 2018: 1-8.

[8] Tran P N, Nguyen H Q V, Pham D T, et al. Aircraft trajectory prediction with enriched intent using encoder-decoder architecture[J]. IEEE Access, 2022, 10: 17881-17896.

[9] Huang J, Ding W J. Aircraft trajectory prediction based on Bayesian optimised temporal convolutional network-bidirectional gated recurrent unit hybrid neural network[J]. International Journal of Aerospace Engineering, 2022, 2022. : 1-19.

[10] 焦卫东, 杨蓓. 一种融合MSC和时空注意力的TCN航迹预测方法[J]. 北京航空航天大学学报, 2026, 52(1): 15-27.
Jiao W D, Yang B. A TCN trajectory prediction method fusing MSC and spatio-temporal attention[J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(1): 15-27 (in Chinese).

[11] 李楠, 孙伯鑫, 焦庆宇, 等. 基于GA-BP神经网络的终端区航迹预测[C]//世界交通运输工程技术论坛. 北京: 中国公路学会, 2021: 396-405.
Li N, Sun B X, Jiao Q Y, et al. Trajectory prediction of terminal area based on GA-BP neural network[C]//Proceedings of the World Transport Convention. Beijing: China Highway and Transportation Society, 2021: 396-405(in Chinese).

[12] 李旭娟, 皮建勇, 黄飞翔, 等. 基于自生成深度神经网络的4D航迹预测[J]. 计算机应用, 2021, 41(5): 1492-1499.
Li X J, Pi J Y, Huang F X, et al. Self-generated deep neural network based 4D trajectory prediction[J]. Journal of Computer Applications, 2021, 41(5): 1492-1499(in Chinese).

[13] Zeng W L, Quan Z B, Zhao Z Y, et al. A deep learning approach for aircraft trajectory prediction in terminal airspace[J]. IEEE Access, 2020, 8: 151250-151266.

[14] Xu Z F, Zeng W L, Chu X, et al. Multi-aircraft trajectory collaborative prediction based on social long short-term memory network[J]. Aerospace, 2021, 8(4): 115.

[15] Pang Y T, Liu Y M. Probabilistic aircraft trajectory prediction considering weather uncertainties using dropout as Bayesian approximate variational inference[C]//Proceedings of the Scitech 2020 Forum. Reston: AIAA, 2020: 1413.

[16] Pang Y T, Zhao X Y, Hu J M, et al. Bayesian spatio-temporal graph Transformer network (B-STAR) for multi-aircraft trajectory prediction[J]. Knowledge-Based Systems, 2022, 249: 108998.

[17] Xu Z F, Liu Y, Chu X, et al. Aircraft trajectory prediction for terminal airspace employing social spatiotemporal graph convolutional network[J]. Journal of Aerospace Information Systems, 2023, 20(6): 319-333.

[18] 韩萍, 张启, 石庆研, 等. 基于DBSCAN-GRU算法的终端区4D航迹预测[J]. 信号处理, 2023, 39(3): 439-449.
Han P, Zhang Q, Shi Q Y, et al. 4D trajectory prediction of terminal area based on DBSCAN-GRU algorithm[J]. Journal of Signal Processing, 2023, 39(3): 439-449 (in Chinese).

[19] CCAR-93TM-R6 民用航空空中交通管理规则[S].
CCAR-93TM-R6 Civil aviation air traffic management rules[S] (in Chinese).

[20] Lin Z, Yue W Q, Huang J, et al. Ship trajectory prediction based on

the TTCN-attention-GRU model[J]. Electronics, 2023, 12(12): 2556.
[21] Patrikar J, Moon B, Oh J, et al. Predicting like a pilot: dataset and method to predict socially-aware aircraft trajectories in non-towered terminal airspace[C]//Proceedings of the International Conference on Robotics and Automation. Piscataway: IEEE Press, 2022: 2525-2531.

Multi-flight trajectory prediction method in terminal area based on an improved spatio-temporal model

HE Huaiqing*，SHI Xiaoshuang，LIU Haohan，HUI Kanghua

(College of Computer Science and Technology，Civil Aviation University of China，Tianjin 300300，China)

Abstract：4D trajectory prediction in this setting is extremely unpredictable and difficult due to the large amount of past trajectory data in the terminal area, its rich spatio-temporal properties, and the sudden changes in trajectory point placements. To address these challenges, we propose a solution based on an improved spatio-temporal model comprising three components. First, we introduce temporal convolutional networks (TCN) and bidirectional gated recurrent units (BiGRU) into the field of flight trajectory prediction, improving the TCN architecture. This leads to the development of a double-layer multi-scale temporal convolution network MMTCN that effectively extracts temporal features from both global and local perspectives. Second, we integrate layer normalization and residual connections into the graph attention network GAT to capture the intricate spatial dependencies among flights. Third, to mitigate data uncertainty stemming from abrupt changes in trajectory point locations, we input the extracted spatio-temporal characteristics into a conditional variational autoencoder (CVAE) to learn the latent representations of flight trajectory data, ultimately generating multiple predictive trajectories. Throughout the training process, a learning rate adjustment strategy is employed to enhance training efficiency. The experimental results demonstrate that the improved model achieves optimal performance on two metrics, with an average displacement error (ADE) of 0.082 6 and a final displacement error (FDE) of 0.111 1, significantly outperforming other baseline models. Additionally, the suggested model lowers the maximum error on the general aviation dataset by roughly 7.75% for FDE and 9.59% for ADE. This model not only effectively extracts spatio-temporal characteristics but also exhibits training stability.

Keywords：terminal area；trajectory prediction；improved spatio-temporal model；double-layer multi-scale temporal convolution；uncertainty

Received：2024-07-18；**Accepted**：2024-11-01；**Published Online**：2025-01-02 09：40

URL：link.cnki.net/urlid/11.2625.V.20241231.1432.001

Foundation item：National Key Research and Development Program of China (2020YFB1600101)

* **Corresponding author**. E-mail：hqhe@cauc.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2025.0007

Al-CFRP 复合结构黏接界面固化过程的超声透射检测

卜繁强[1]，刘勇[1]，王兴国[1,*]，李晓高[1]，沈国浪[1]，马成文[2]

(1. 景德镇陶瓷大学 机械电子工程学院，景德镇 333403；2. 江西昌兴航空装备股份有限公司，景德镇 333032)

摘 要：针对各向同性-各向异性复合结构黏接界面状态评价困难的问题，提出一种超声透射检测方法。基于传递矩阵法，采用无量纲参数 $\omega\tau$ 描述黏接界面状态，以 Al 与碳纤维增强复合材料 (CFRP) 树脂黏接获得的复合结构为对象，建立超声传播理论模型，分析黏接界面状态对超声透射特性的影响。理论分析结果表明，当 $\omega\tau$ 增大时，同种入射角度下的透射系数逐渐增大，透射系数峰值频率向高频移动。建立 Al-CFRP 复合结构的超声透射时域仿真模型，仿真结果表明，当 $\omega\tau$ 增大时，快速傅里叶变换 (FFT) 幅值逐渐增大，峰值频率逐渐向高频移动，透射系数随 $\omega\tau$ 的增大先迅速增大后缓慢增大，最终趋于稳定。对不同黏接状态下 Al-CFRP 黏接试件进行超声透射检测实验，FFT 幅值及透射系数随固化时间的变化趋势与仿真结果相似。

关 键 词：各向同性；各向异性；复合结构；黏接界面；超声透射

中图分类号：V467; TB553

文献标志码：A **文章编号**：1001-5965(2026)11-3758-12

各向同性与各向异性复合材料黏接结构具有比强度、比模量高及轻量化等优点，在航空航天、核工业等领域中得到了广泛应用，如直升机机翼、飞机蒙皮和固体火箭发动机外壳等[1-3]。在生产和使用过程中，由于载荷的作用会产生界面弱化甚至脱黏等问题[4-5]，黏接结构的无损检测与评估是关注的重点。目前，超声检测对界面特性的高敏感性成为评估黏接质量常用的方法之一[6-8]。

针对多层各向同性黏接结构中的超声波传播特性，研究人员进行了大量的理论分析和实验研究。基于 Thomson 传递矩阵模型[9]，Pilarski[10] 与丁俊才[11] 等分别建立了双层板和三层板黏接结构中的声波传播模型，分析了入射角、频率及基体材料等对声波反射和透射特性的影响。在此基础上，孙凯华[12] 和吴斌[13-14] 等均采用弹簧模型表征界面黏接强度，分别探究了刚度系数、刚度比与反射/透射系数的关系。与多层各向同性黏接结构相比，含各向异性介质的黏接结构中的超声波传播特性更为复杂[15]，这方面的研究也逐渐受到重视[16-18]。Maghsoodi[19] 和宋国荣[20] 等改进了传统的传递矩阵，通过全局矩阵的方法推导出各向异性黏接结构中声波的传播模型。Son 等[21] 研究了处于弹性层之间的横观各向同性多孔层中剪切波的传播特性，得到了相速度与孔隙率之间的变化关系。Wang 等[22] 建立了浸没在液体中的各向异性复合材料层合板的时域仿真模型，研究了随机纤维铺层方向和入射角对声波传播特性的影响。He 等[23] 针对具有厚胶层的 FRP-to-FRP 黏接结构，分析了单界面与双界面刚度变化对反射特性的影响。然而，关于各向同性与各向异性黏接结构的研究不多，此类黏接结构的超声传播机理尚不明确，缺乏理论和实验研究。

本文基于传递矩阵法，引用无量纲参数 $\omega\tau$ 来描述不同的黏接界面状态，推导出各向同性-各向异性黏接结构中纵波入射条件下反射/透射系数的表达式。同时，建立了声波接触式入射条件下各向同性-各向异性黏接结构 (Al-CFRP 结构) 的透射时

收稿日期：2025-01-06；**录用日期**：2025-02-07；**网络出版时间**：2025-02-27 14:23

网络出版地址：link.cnki.net/urlid/11.2625.V.20250227.1349.002

基金项目：国家自然科学基金 (52265020)；景德镇市基础研究和前沿技术项目 (2025JCYJ001)

* **通信作者**. E-mail：wangxingguo@jcu.edu.cn

引用格式：卜繁强，刘勇，王兴国，等. Al-CFRP 复合结构黏接界面固化过程的超声透射检测 [J]. 北京航空航天大学学报，2026，52（11）：3758-3769. Bu F Q，Liu Y，Wang X G，et al. Ultrasonic transmission testing of bonding interface curing process in Al-CFRP composite structures [J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：3758-3769（in Chinese）.

域仿真模型, 着重分析了黏接界面状态对透射特性的影响。此外, 通过实验测量了不同胶层固化时间下声波的透射时域信号, 分析了不同黏接界面状态时的透射系数变化规律, 并与理论求解结果和仿真结果进行对比。

1　理论分析

1.1　理论建模

对于各向同性-各向异性复合黏接结构的声波传播模型, 将全局坐标系的 x 轴置于黏接结构的下界面 (I1 界面), 固体层厚度沿 z 方向, 如图 1 所示。其中, O 为坐标原点, d_1 和 d_3 分别为各向异性层和各向同性层的厚度; I1 和 I3 分别为两楔块与各向异性层和各向同性层的黏接界面, 假设这 2 个界面为理想的完好黏接形式; I2 假设为各向同性层和各向异性层之间的黏接薄层, 厚度 d_2 远小于波长; "+" 和 "–" 分别为黏接界面的上侧和下侧; L 表示纵波, T 表示横波, θ_{i4}、θ_{L4}、θ_{T4} 分别为发射楔块中的纵波入射、反射角、横波反射角, θ_{L0} 和 θ_{T0} 分别为接收楔块中的纵波透射角和横波透射角。

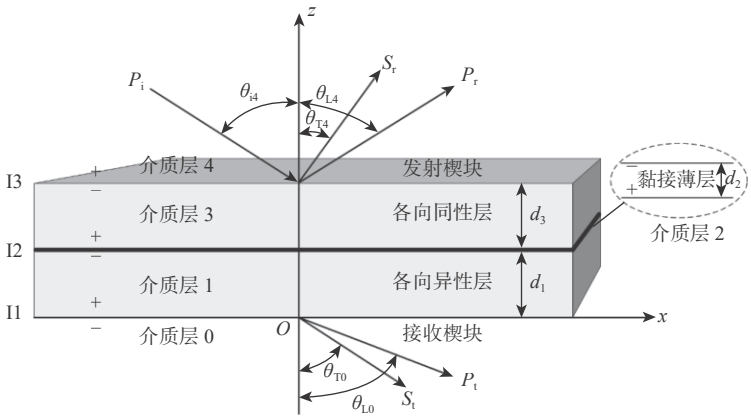


图 1　各向同性-各向异性黏接结构的声波传播模型

Fig. 1　Acoustic wave propagation model in isotropic-anisotropic bonded structures

以角频率为 ω 的简谐平面波 (P_i 波) 由发射楔块入射到黏接结构中, 根据 Snell 定律, 所有反射波与折射波的波矢量沿着 x 方向的分量都相等且为 δ。需说明的是, 本文暂不考虑声波在黏接结构传播过程中的衰减。

假设声波的入射平面为 x-z 平面, 黏接结构中, 各向同性介质的纵波 (P 波) 和横波 (S 波) 的位移势函数可分别表述为[15]

$$\begin{cases} \Phi_{(n)} = \left(\phi_{i(n)}\mathrm{e}^{-\mathrm{i}\alpha_z^{(n)}z} + \phi_{r(n)}\mathrm{e}^{\mathrm{i}\alpha_z^{(n)}z}\right)\mathrm{e}^{\mathrm{i}(\omega t-\delta x)} \\ \Psi_{(n)} = \left(\psi_{i(n)}\mathrm{e}^{-\mathrm{i}\beta_z^{(n)}z} + \psi_{r(n)}\mathrm{e}^{\mathrm{i}\beta_z^{(n)}z}\right)\mathrm{e}^{\mathrm{i}(\omega t-\delta x)} \end{cases} \tag{1}$$

式中: n 为各向同性介质的层数, n=0,4; $\phi_{i(n)}$和$\phi_{r(n)}$分别为入射和反射纵波的位移势幅值; $\psi_{i(n)}$和$\psi_{r(n)}$分别为入射和反射横波的位移势幅值; $\alpha_z^{(n)}$ 和 $\beta_z^{(n)}$ 分别为纵波和横波矢量的 z 轴分量, $\alpha_z^{(n)}=\omega\cos\theta_{Ln}/C_{Ln}$, $\beta_z^{(n)}=\omega\cos\theta_{Tn}/C_{Tn}$, C_{Tn}, C_{Ln} 和 C_{Tn} 分别为介质中纵波和横波的速度。

对于各向同性介质, 其内部空间声场所产生的位移分量 $u_{x(n)}$ 和 $u_{z(n)}$ 及应力分量 $\sigma_{zx(n)}$ 和 $\sigma_{zz(n)}$ 可分别表述为[24]

$$\begin{cases} u_{x(n)} = \dfrac{\partial\Phi_{(n)}}{\partial x} - \dfrac{\partial\Psi_{(n)}}{\partial z} \\ u_{z(n)} = \dfrac{\partial\Phi_{(n)}}{\partial z} + \dfrac{\partial\Psi_{(n)}}{\partial x} \\ \sigma_{zx(n)} = \mu_n\left(\dfrac{\partial u_{x(n)}}{\partial z} + \dfrac{\partial u_{z(n)}}{\partial x}\right) \\ \sigma_{zz(n)} = \lambda_n\left(\dfrac{\partial u_{x(n)}}{\partial x} + \dfrac{\partial u_{z(n)}}{\partial z}\right) + 2\mu_n\left(\dfrac{\partial u_{z(n)}}{\partial z}\right) \end{cases} \tag{2}$$

式中: $u_{x(n)}$ 和 $\sigma_{zx(n)}$ 分别为切向位移和应力分量; $u_{z(n)}$ 和 $\sigma_{zz(n)}$ 分别为法向位移和应力分量; λ_n 和 μ_n 为各向同性介质的 Lame 常数。

在发射楔块中, 将式 (1) 中表示的纵波、横波位移势函数 $\Phi_{(4)}$ 和 $\Psi_{(4)}$ 代入式 (2), 可得介质层 4 中声场与界面 I3 上力学参量 (质点位移和应力) 的关系, 矩阵形式如下:

$$\begin{bmatrix} \phi_{i(4)} \\ \phi_{r(4)} \\ \psi_{i(4)} \\ \psi_{r(4)} \end{bmatrix} = \frac{1}{\omega^2}\begin{bmatrix} C_{T4}\sin\theta_{T4} & -\dfrac{C_{L4}\cos(2\theta_{T4})}{2\cos\theta_{L4}} & -\dfrac{1}{2\rho_4} & \dfrac{1}{2\rho_4}\tan\theta_{L4} \\ C_{T4}\sin\theta_{T4} & \dfrac{C_{L4}\cos(2\theta_{T4})}{2\cos\theta_{L4}} & -\dfrac{1}{2\rho_4} & -\dfrac{1}{2\rho_4}\tan\theta_{L4} \\ \dfrac{C_{T4}\cos(2\theta_{T4})}{2\cos\theta_{T4}} & C_{T4}\sin\theta_{T4} & \dfrac{1}{2\rho_4}\tan\theta_{T4} & \dfrac{1}{2\rho_4} \\ -\dfrac{C_{T4}\cos(2\theta_{T4})}{2\cos\theta_{T4}} & C_{T4}\sin\theta_{T4} & -\dfrac{1}{2\rho_4}\tan\theta_{T4} & \dfrac{1}{2\rho_4} \end{bmatrix}\begin{bmatrix} u_{x(3)}^+ \\ u_{z(3)}^+ \\ \sigma_{zz(3)}^+ \\ \sigma_{zx(3)}^+ \end{bmatrix} \tag{3}$$

式中：$u^{+}_{x(3)}$、$u^{+}_{z(3)}$和$\sigma^{+}_{zz(3)}$、$\sigma^{+}_{zx(3)}$分别为黏接界面I3上侧质点位移分量和应力分量；ρ_4、$C_{\mathrm{L}4}$和$C_{\mathrm{T}4}$分别为楔块介质的密度、纵波速度和横波速度。用矩阵$\boldsymbol{A}_4$表示上述4×4阶矩阵。

假设I3和I1界面为完好黏接状态，即黏接界面上侧和下侧之间的质点位移和应力连续，I3和I1界面处的边界条件可表示为

$$\begin{cases} u^{+}_{x(3)}=u^{-}_{x(3)},u^{+}_{z(3)}=u^{-}_{z(3)} \\ \sigma^{+}_{zx(3)}=\sigma^{-}_{zx(3)},\sigma^{+}_{zz(3)}=\sigma^{-}_{zz(3)} \end{cases} \tag{4}$$

$$\begin{cases} u^{+}_{x(1)}=u^{-}_{x(1)},u^{+}_{z(1)}=u^{-}_{z(1)} \\ \sigma^{+}_{zx(1)}=\sigma^{-}_{zx(1)},\sigma^{+}_{zz(1)}=\sigma^{-}_{zz(1)} \end{cases} \tag{5}$$

在各向同性层中，其固体层上下界面处质点位移和应力分量的传递矩阵如下[25]：

$$\begin{bmatrix} u^{-}_{x(3)} \\ u^{-}_{z(3)} \\ \sigma^{-}_{zz(3)} \\ \sigma^{-}_{zx(3)} \end{bmatrix}=\boldsymbol{B}_3\begin{bmatrix} u^{+}_{x(2)} \\ u^{+}_{z(2)} \\ \sigma^{+}_{zz(2)} \\ \sigma^{+}_{zx(2)} \end{bmatrix} \tag{6}$$

式中：矩阵$\boldsymbol{B}_3$为4×4阶矩阵，包含各向同性层介质的厚度、密度、纵波和横波速度及两波在介质层中的传播角等参数。具体相关参数见附录A。

在黏接薄层中，考虑其厚度可忽略且远小于波长，用来描述I2界面处的黏接状态，将薄层上下界面处质点位移和应力分量用矩阵的形式联系起来，并写成[26]

$$\begin{bmatrix} u^{+}_{x(2)} \\ u^{+}_{z(2)} \\ \sigma^{+}_{zz(2)} \\ \sigma^{+}_{zx(2)} \end{bmatrix}=\begin{bmatrix} 1 & -\mathrm{i}kd_2 & 0 & -\mathrm{i}\omega d_2/\mu_2 \\ -\mathrm{i}\omega\rho_2 d_2 M & 1 & -\mathrm{i}\omega d_2/N & 0 \\ 0 & -\mathrm{i}\omega\rho_2 d_2 & 1 & -\mathrm{i}kd_2 \\ -\mathrm{i}kd_2 Q & 0 & -\mathrm{i}\omega\rho_2 d_2 M & 1 \end{bmatrix}\begin{bmatrix} u^{-}_{x(2)} \\ u^{-}_{z(2)} \\ \sigma^{-}_{zz(2)} \\ \sigma^{-}_{zx(2)} \end{bmatrix} \tag{7}$$

式中：k为波数在界面上的投影；$M=1-4(1-\varepsilon^2)(k/k_{\mathrm{T}2})^2$，$N=\lambda_2+2\mu_2$，$Q=1-2\varepsilon^2$，$\varepsilon=C_{\mathrm{T}2}/C_{\mathrm{L}2}$，$k_{\mathrm{T}2}$为薄层中横波的波数，$\rho_2$和$\lambda_2$、$\mu_2$分别为薄层的密度和2个Lame常数。用矩阵$\boldsymbol{C}_2$表示上述4×4阶的传递矩阵。

为了更精确地描述I2界面处的黏接状态，可将薄层定义为具有松弛时间τ的黏弹性体[27-28]。根据其由液态向固态的变化过程来描述I2界面从弱黏接向完好黏接的转变。这种黏弹性体的剪切模量和体积弹性模量可表示为

$$\begin{cases} \mu_2=\mu_{2\infty}\left[\dfrac{(\omega\tau)^2}{1+(\omega\tau)^2}-\mathrm{i}\dfrac{\omega\tau}{1+(\omega\tau)^2}\right] \\ K_2=K_0+(K_{2\infty}-K_0)\left[\dfrac{(\omega\tau)^2}{1+(\omega\tau)^2}-\mathrm{i}\dfrac{\omega\tau}{1+(\omega\tau)^2}\right] \end{cases} \tag{8}$$

式中：$\omega\tau$为无量纲参数；$\mu_{2\infty}$和$K_{2\infty}$分别为薄层固态时的剪切模量和体积弹性模量；K_0为薄层液态时的体积弹性模量。通过定义$\omega\tau$的不同值来模拟黏接薄层由液态转变成固态的过程。根据$\lambda_2=K_2-2\mu_2/3$计算出黏接薄层的第一Lame常数λ_2，并代入矩阵$\boldsymbol{C}_2$中。

在各向异性层中，假设其为材料弹性主轴与所选取的全局坐标系(笛卡儿坐标系)坐标轴重合的正交各向异性材料，同样可将上下界面处质点位移和应力分量用矩阵的形式联系起来，并写成对应的传递矩阵形式：

$$\begin{bmatrix} u^{-}_{x(2)} \\ u^{-}_{z(2)} \\ \sigma^{-}_{zz(2)} \\ \sigma^{-}_{zx(2)} \end{bmatrix}=\boldsymbol{D}_1\begin{bmatrix} u^{+}_{x(1)} \\ u^{+}_{z(1)} \\ \sigma^{+}_{zz(1)} \\ \sigma^{+}_{zx(1)} \end{bmatrix} \tag{9}$$

式中：矩阵$\boldsymbol{D}_1$为4×4阶的传递矩阵，包含各向异性层的厚度、密度、弹性常数(如C_{ij}，$i,j=1,2,3$)、准纵波和准横波速度及2种波在各向异性层中的传播角等参数[29]。

在接收楔块中，采用发射楔块中相似的分析，将纵波、横波位移势函数$\Phi_{(0)}$和$\Psi_{(0)}$代入式(2)，可得介质层0中声场与界面I1上力学参量(质点位移和应力)的关系，并写成矩阵形式：

$$\begin{bmatrix} u^{-}_{x(1)} \\ u^{-}_{z(1)} \\ \sigma^{-}_{zz(1)} \\ \sigma^{-}_{zx(1)} \end{bmatrix}=\boldsymbol{E}_0\begin{bmatrix} \phi_{\mathrm{r}(0)} \\ \phi_{\mathrm{i}(0)} \\ \psi_{\mathrm{r}(0)} \\ \psi_{\mathrm{i}(0)} \end{bmatrix} \tag{10}$$

式中：矩阵$\boldsymbol{E}_0$与$\boldsymbol{A}_4$互为逆矩阵形式，且矩阵$\boldsymbol{A}_4$中的$\theta_{\mathrm{L}4}$、$\theta_{\mathrm{T}4}$、ρ_4、$C_{\mathrm{L}4}$和$C_{\mathrm{T}4}$分别被$\theta_{\mathrm{L}0}$、$\theta_{\mathrm{T}0}$、ρ_0、$C_{\mathrm{L}0}$和$C_{\mathrm{T}0}$所代替。

联立式(3)～式(10)，可得到联系上下楔块基体层中声场的矩阵表达式：

$$\begin{bmatrix} \phi_{\mathrm{i}(4)} \\ \phi_{\mathrm{r}(4)} \\ \psi_{\mathrm{i}(4)} \\ \psi_{\mathrm{r}(4)} \end{bmatrix}=\boldsymbol{F}\begin{bmatrix} \phi_{\mathrm{r}(0)} \\ \phi_{\mathrm{i}(0)} \\ \psi_{\mathrm{r}(0)} \\ \psi_{\mathrm{i}(0)} \end{bmatrix} \tag{11}$$

式中：矩阵$\boldsymbol{F}=\boldsymbol{A}_4\boldsymbol{B}_3\boldsymbol{C}_2\boldsymbol{D}_1\boldsymbol{E}_0$。

假设仅考虑纵波从I3界面处入射，令$\psi_{\mathrm{i}(4)}=\phi_{\mathrm{i}(0)}=\psi_{\mathrm{i}(0)}=0$，并代入式(11)中，可得纵波反射系数$R_{\mathrm{LL}}$与透射系数$T_{\mathrm{LL}}$为

$$\begin{cases} R_{\mathrm{LL}}=\dfrac{\phi_{\mathrm{r}(4)}}{\phi_{\mathrm{i}(4)}}=\dfrac{F_{33}F_{21}-F_{31}F_{23}}{F_{11}F_{33}-F_{13}F_{31}} \\ T_{\mathrm{LL}}=\dfrac{\phi_{\mathrm{r}(0)}}{\phi_{\mathrm{i}(4)}}=\dfrac{F_{33}}{F_{11}F_{33}-F_{13}F_{31}} \end{cases} \tag{12}$$

1.2 数值求解及结果分析

利用式(1)～式(12)可求解纵波入射条件下的声波透射系数。本文以有机玻璃(polymethyl methacrylate, PMMA)为上下楔块材料，铝板(Al)为各向同性层，环氧树脂为黏接薄层，碳纤维增强复

合材料 (carbon fiber reinforced polymer, CFRP) 板为各向异性层。其中, CFRP 板选用 T300/914 材料, 为单向纤维增强复合材料。环氧树脂在液态和固态时的体积模量分别为 K_0=1.9 GPa 和 $K_{2\infty}$=3.6 GPa, 固态时的剪切模量为 $\mu_{2\infty}$=1.2 GPa。相关材料的具体参数如表 1 所示[18,29]。

图 2 为不同入射角度与 $\omega\tau$ 下纵波透射系数与频率的关系, 其中, 入射角度分别为 0°、20°、40°(随机选取), $\omega\tau$ 分别为 10^{-1}、10^{0}、10^{1} 和 10^{2}。铝板和 CFRP 板的厚度均为 2 mm。环氧树脂薄层的厚度为 0.02 mm, 厚度远小于声波波长, 可忽略厚度对超声透射特性的影响。

表 1　材料参数[18,29]

Table 1　Material parameters[18,29]

材料	密度/(kg·m^{-3})	C_{11}/GPa	C_{12}/GPa	C_{22}/GPa	C_{23}/GPa	C_{44}/GPa	C_{55}/GPa	纵波声速/(m·s^{-1})	横波声速/(m·s^{-1})
铝板	2 700	111.00	61.00	111.00	61.00	25.00	25.00	6 320	3 080
环氧树脂	1 300	6.72	3.98	6.72	3.98	1.37	1.37	2 800	1 100
CFRP板	1 560	143.80	6.20	13.30	6.50	3.60	5.70		
PMMA	1 180	3.47	1.28	3.47	1.28	1.20	1.20	2 730	1 460

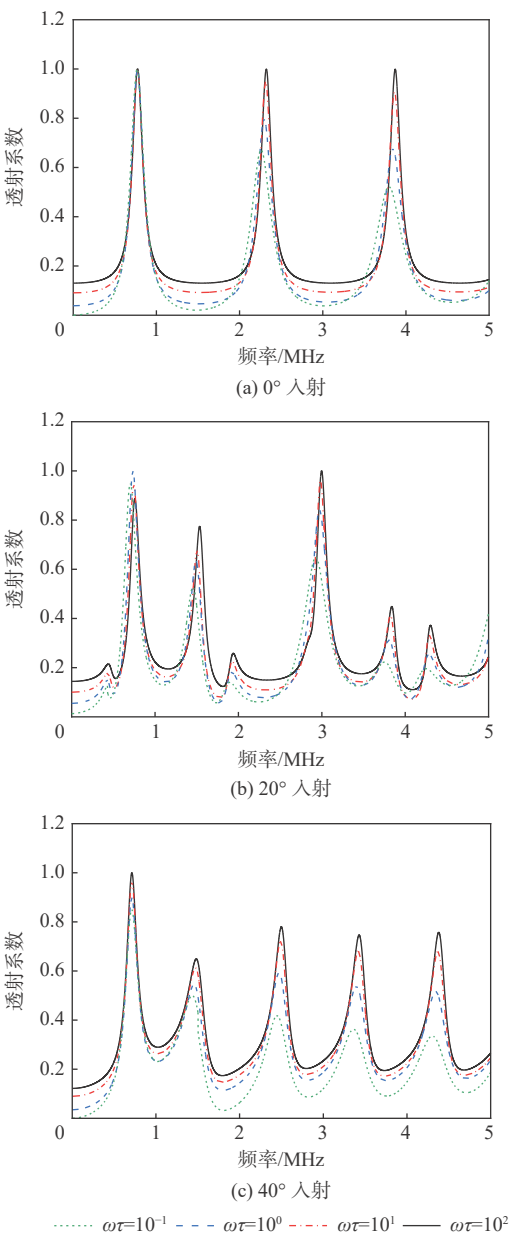


图 2　透射系数与频率之间的关系

Fig. 2　Relationship between transmission coefficients and frequencies

由图 2(a) 可知, 当入射角为 0°时, 由于界面处不存在波形转换, 纵波的传播过程不受各向异性材料特性的影响, 透射系数曲线出现共振现象; 当入射角为 20°和 40°时, 周期性共振现象消失, 曲线变得不规则, 且透射系数峰值的数量增加, 如图 2(b) 与图 2(c) 所示。此外, 在同一入射角度中, 当 $\omega\tau$ 增大时, 透射系数峰值逐渐增大, 并且峰值频率逐渐向高频移动; 当 $\omega\tau$=10^2 时, 不同入射角度时的透射系数峰值均达到最大值, 说明此时黏接界面为完好黏接状态。

2　Al-CFRP 黏接结构透射时域仿真分析

2.1　黏接结构透射时域仿真模型的建立

基于上述理论, 利用有限元仿真软件 COMSOL 建立了 Al-CFRP 黏接结构的透射时域仿真模型, 如图 3 所示, 其为简化的二维平面结构, 并设置接触式的超声发射/接收楔块。其中, CFRP 板的长度与厚度分别为 100 mm 和 2 mm, 与铝板的长度和厚度一致。仿真模型中, 具体的材料参数与表 1 中的参数一致。此外, 上下楔块的黏接界面处设置为完好黏接状态。整个有限元仿真模型不考虑声波在黏接结构内部的衰减特性。

在仿真模型中, 利用弹性波 (时域显示)、固体力学 (弹性波) 物理场来模拟声-结构的时域相互作用。通过线激励和线接收的方式分别模拟超声激励探头和接收探头, 激励端和接收端的长度都设置为 13 mm, 两端面相互平行且端面中心点连线垂直于端面。对于声波传播的模拟, 通过弹性波物理场中的指定速度作为超声激励方式, 激励函数表达式为

$$V(t)=0.5(1-\cos(\pi f_0 t))\sin(2\pi f_0 t) \tag{13}$$

式中: $V(t)$ 为施加的指定速度; f_0 为超声的入射激励

频率；t 为时间，$0\leqslant t\leqslant 2T$，T 为正弦波的周期。当激励中心频率 f_0=2.5 MHz 时，激励信号的时域波形如图 4(a) 所示，通过快速傅里叶变换（fast Fourier transform, FFT）变换可得频率谱，如图 4(b) 所示。可知，当 f_0=2.5 MHz 时，有效带宽（−6 dB）为 1.27～3.76 MHz。

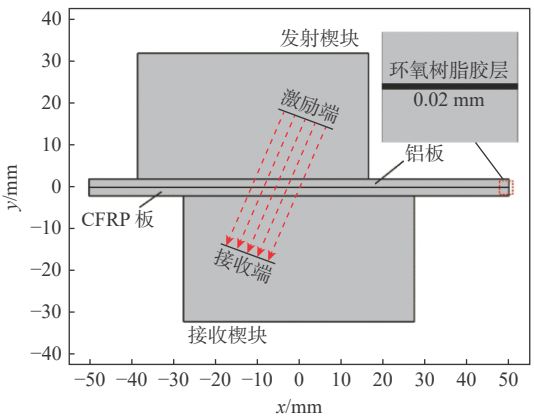


图 3 Al-CFRP 黏接结构透射时域仿真模型

Fig. 3 Time-domain simulation model of transmission for Al-CFRP bonding structure

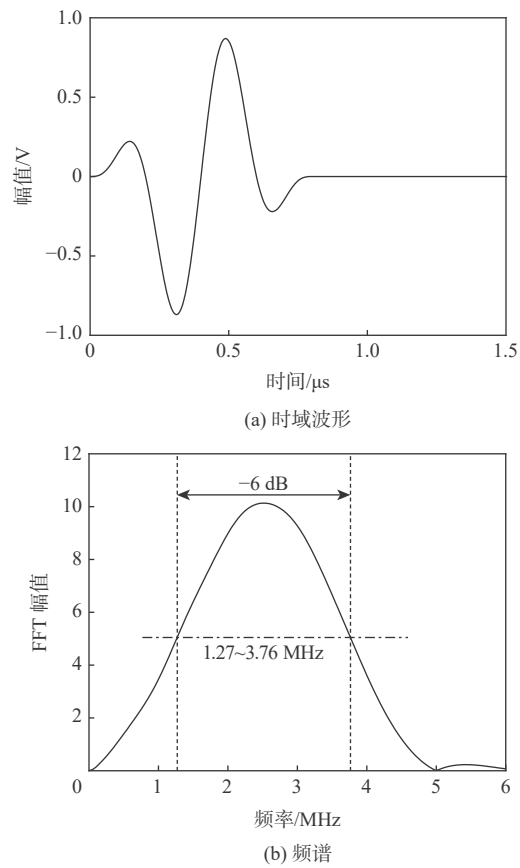


图 4 2.5 MHz 激励中心频率的时域与频谱图

Fig. 4 Time-domain and frequency spectrum plots with 2.5 MHz excitation central frequency

环氧树脂薄层的厚度设置为 0.02 mm，厚度远小于声波波长，可忽略厚度对超声透射特性的影响。因此，环氧树脂薄层可看作 Al-CFRP 黏接结构的黏接界面，通过薄层物理特性的变化来模拟黏接界面的状态。利用式 (14)[30]，将体积弹性模量 K_2 和剪切模量 μ_2 的变化转换成弹性模量 E_2 的变化，从而模拟对应 $\omega\tau$ 取值下的黏接界面状态。图 5 给出了弹性模量 E_2 与 $\omega\tau$ 的关系曲线。当 $\omega\tau$ 增大时，E_2 先逐渐增大，后趋于稳定，在 $\omega\tau=10^2$ 时达到最大值 3.24 GPa。

$$E_2=\frac{9K_2\mu_2}{3K_2+\mu_2} \tag{14}$$

在有限元求解过程中，网格大小的选择至关重要，决定了整个数值模拟结果的准确性。网格选取的表达式为

$$L_e\leqslant c_m/(10f_0) \tag{15}$$

式中：L_e 为有限元网格的大小；c_m 为各层材料中的声速。此外，将模型中的上下楔块两侧边界均设置为低反射边界，可减小边界对声波传播过程中的影响。

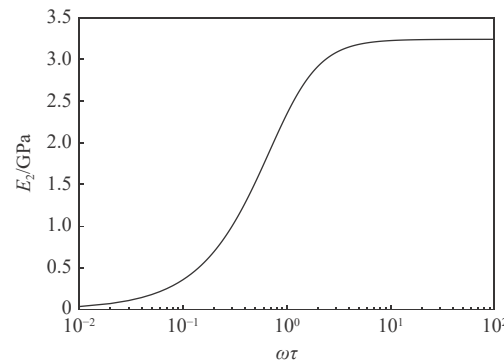


图 5 弹性模量 E_2 与 $\omega\tau$ 之间的关系

Fig. 5 Relationship between elastic modulus E_2 and $\omega\tau$

2.2 黏接结构超声仿真分析

首先，为验证 $\omega\tau$ 与入射角对透射特性的影响，两楔块之间不设置黏接结构，可分别求解得到 0°、20°、40°入射角时的透射信号（见图 6）作为参考信号，V_{ref} 为信号的最大正数幅值。其次，通过求解图 3

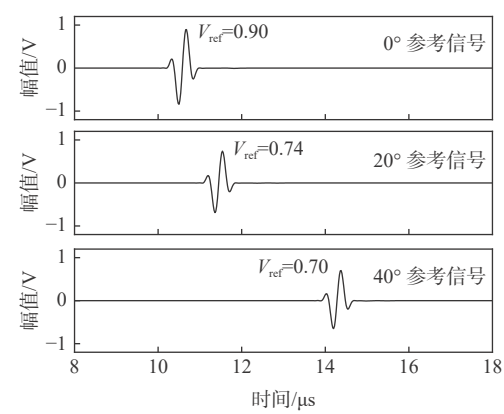


图 6 不同入射角度时的参考信号

Fig. 6 Reference signals at different incident angles

中的仿真模型, 得到不同入射角与 $\omega\tau$ 时的超声透射信号, 如图 7 所示, 图中给出 $\omega\tau$=10^{-1}, 10^{0}, 10^{1}, 10^{2} 时的仿真结果。图 7 中, 由线框标记的信号为首次在接收端所获得的时域信号, 即黏接结构中的透射信号。在相同入射角下, 当 $\omega\tau$ 增大时, 透射幅值对应的时间减少, 而幅值逐渐增大。主要原因是: $\omega\tau$ 增大导致薄层弹性模量 E_2 增大, 从而使声波在黏接结构中的传播速度增大, 黏接界面趋于完好黏接状态, 最终接收端得到的声能增加。

通过对图 7 中的透射时域信号进行 FFT 变换, 可得相应的透射频率谱, 如图 8 所示。其中, 将 $\omega\tau$=10^{2} 时的透射峰值设为 1, 并对频域进行归一化处理。可知, 不同入射角和 $\omega\tau$ 时的频域峰值频率都在有效带宽内。在同种入射角度下, 当 $\omega\tau$ 增大时, FFT 幅值增大, 并且峰值频率逐渐向高频移动; 不同入射角度时的峰值频率移动的距离不同。这与理论分析中的“峰值漂移”现象相似。

已知透射幅值与透射系数成正比, 仿真模型中的透射系数可通过 V_t 与 V_{ref} 的比值计算得到, V_t 为图 7 中透射信号的最大正数幅值。通过计算及归

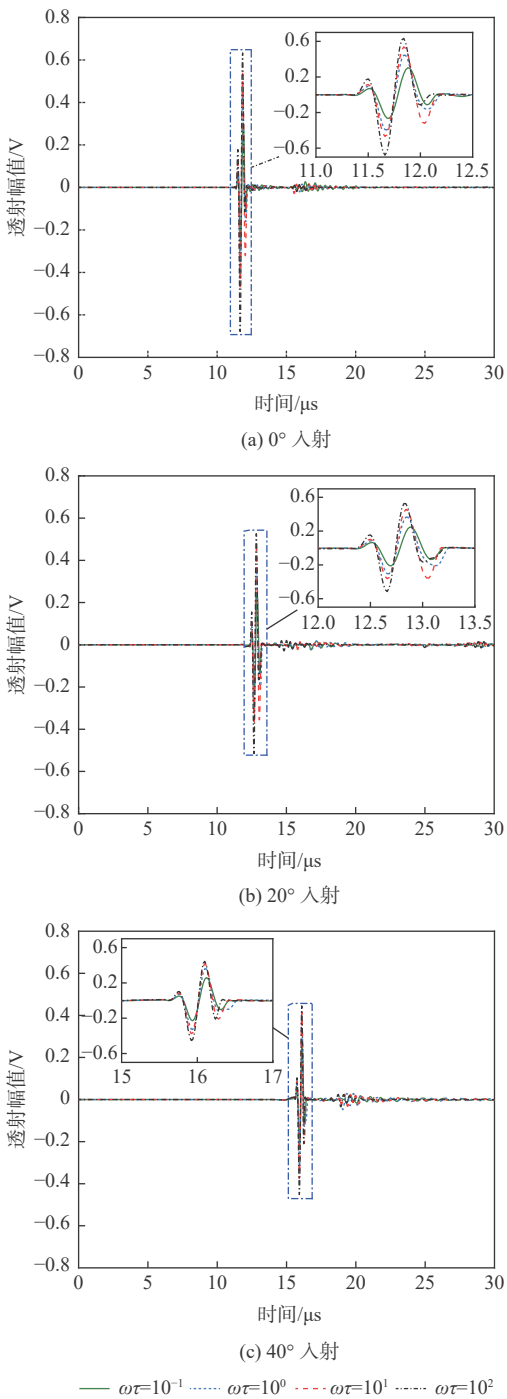


图 7　不同入射角度及 $\omega\tau$ 时的透射信号

Fig. 7　Transmission signals at different incident angles and $\omega\tau$

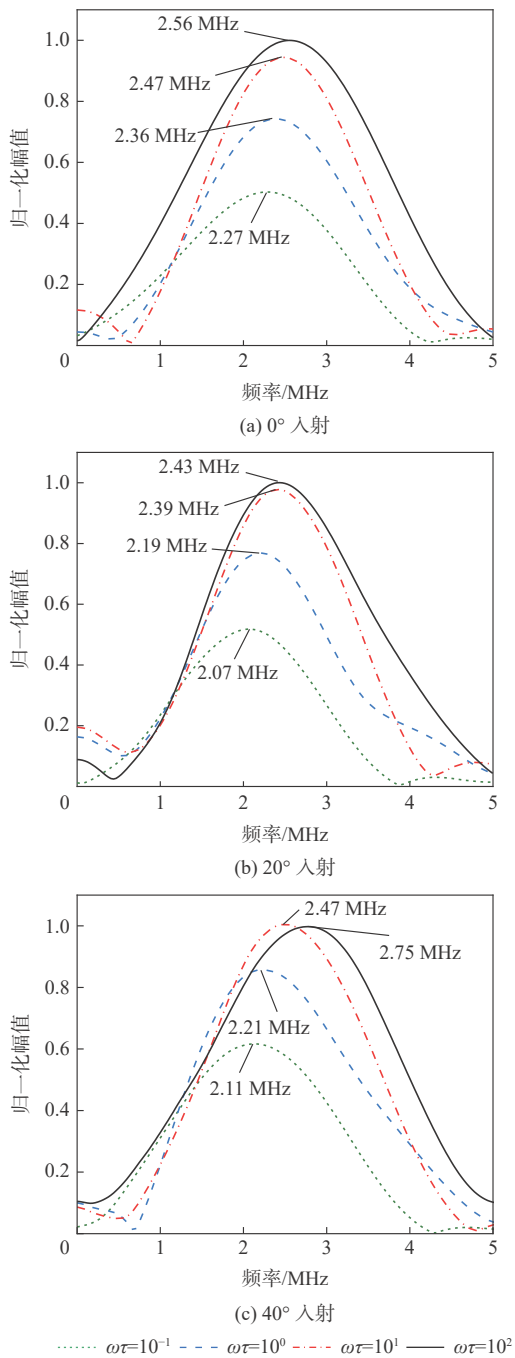
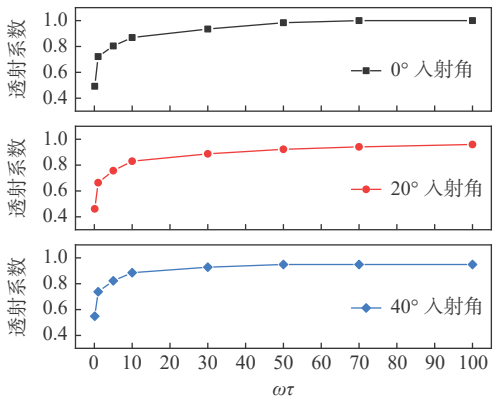


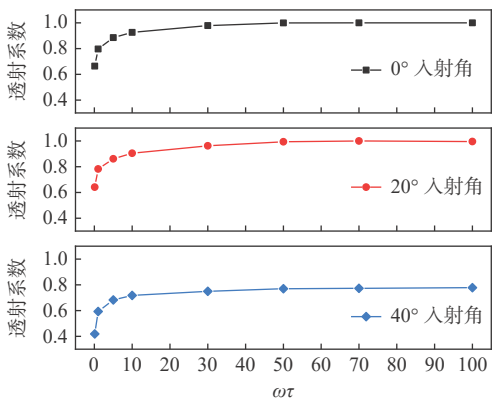
图 8　不同入射角度及 $\omega\tau$ 时的透射频谱图

Fig. 8　Transmission frequency spectrum plots at different incident angles and $\omega\tau$

一化处理后得到透射系数，并与前文理论分析中图 2 的结果进行对比，如图 9 所示。其中，选取图 2 中靠近 2.5 MHz 附近的最大透射系数峰值作为对比。由图 9 可知，当 $\omega\tau$<10 时，黏接界面从弱黏接状态向完好黏接状态演变时，透射系数随着 $\omega\tau$ 的增加而迅速增加；当 $\omega\tau$>10 时，透射系数增加的幅度较小，逐渐趋于稳定，这种现象说明黏接界面接近完好黏接状态；当 $\omega\tau$=100 时，透射系数达到最大值，说明此时黏接界面为完好黏接状态。此外，可以看出，仿真结果与理论计算结果的趋势一致，这也进一步说明，利用无量纲参数 $\omega\tau$ 来描述界面黏接状态是可行的。



(a) 有限元仿真结果



(b) 理论计算结果

图 9 不同入射角度及 $\omega\tau$ 时的透射系数

Fig. 9 Transmission coefficients at different incident angles and $\omega\tau$

3 超声检测实验

3.1 实验试件制备

制备一种各向同性-各向异性黏接结构，基体材料分别为铝板和 CFRP 板 (T300/914)，尺寸均为 100 mm×80 mm×2 mm，CFRP 板为碳纤维取向平行于长度方向的单向层合板，黏接结构示意图如图 10 所示。

为得到不同黏接界面状态的 Al-CFRP 黏接结构，内部环氧树脂胶层的固化时间和厚度控制极其重要。根据环氧树脂胶的使用要求，在基体材料涂上黏接胶后先用恒定重物压在其上方，确保胶层内部空气排出，在需要测试时移开重物。在制作黏接结构试件时，使用游标卡尺测量试件厚度，确保环氧树脂胶层厚度小于 0.02 mm。当基体材料通过环氧树脂胶黏接完成后，分别每 2 h 测量一次，来模拟不同黏接界面状态时的 Al-CFRP 复合材料黏接结构，所制备的试件如图 11 所示。

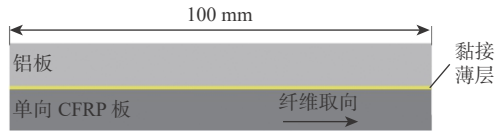


图 10 Al-CFRP 黏接结构示意图

Fig. 10 Schematic diagram of Al-CFRP bonded structure

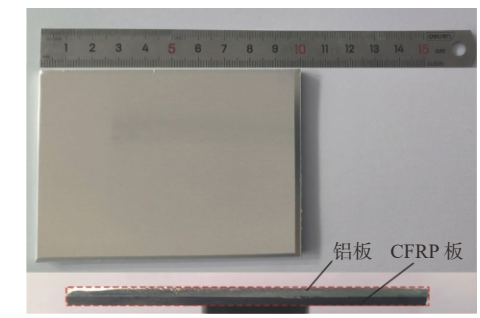


图 11 制备的 Al-CFRP 黏接试件

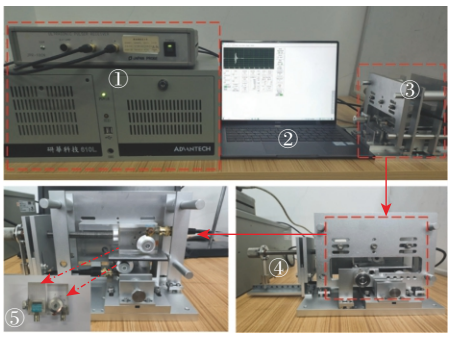
Fig. 11 Prepared Al-CFRP bonded specimen

3.2 超声透射实验及分析

为获得 Al-CFRP 黏接试件的超声透射信号，搭建了可移动接触式的超声透射检测系统，如图 12 所示，主要包含脉冲发射/接收装置 (日本探头公司生产，型号 JPR-10)、一对可调角度超声传感器 (中心频率为 2.5 MHz，传感器端面尺寸为 13 mm×13 mm，入射/接收角度范围为 0°～90°)、计算机、可移动接触式超声检测装置等。超声实验均在常温、常压下进行。

首先，上下楔块之间不放置黏接试件，得到不同入射角时的参考信号，如图 13 所示。其次，环氧树脂薄层受固化时间的影响，导致黏接试件的黏接界面状态发生变化。借助可移动接触式超声透射检测系统对图 11 中不同固化时间下的试件进行检测。图 14 给出了不同固化时间 (2,6,10,14 h) 与入射角 (0°,20°,40°) 时的超声透射信号。

由图 14 可知，当环氧树脂薄层固化时间增加时，透射时域幅值逐渐增大，幅值对应的时间减少，与前文仿真结果中的现象相似。环氧树脂薄层固化时间增大，薄层弹性模量增大，基体之间的界面黏接强度也增加。当固化时间为 14 h 时，幅值达到



① 脉冲发射/接收装置; ② 计算机;
③ 可移动接触式超声检测装置; ④ 移动推杆;
⑤ 可调角度楔块 (超声发射/接收换能器)。

图 12　可移动接触式超声透射检测系统

Fig. 12　Movable contact ultrasonic transmission testing system

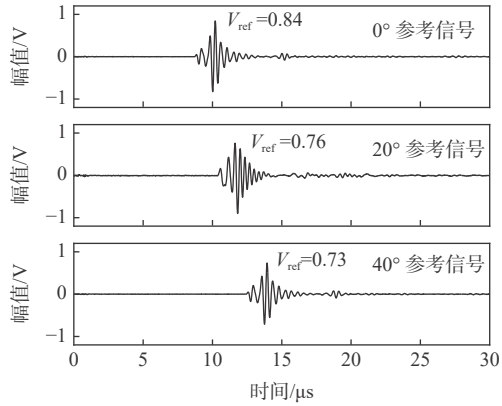


图 13　无试件下不同入射角度时的参考信号

Fig. 13　Reference signals at different incident angles without specimen

最大值, 不同入射角度下幅值对应时间如表 2 所示, 同时, 与有限元仿真中幅值对应时间比较可知, 两者在时间上的误差均小于 5%。通过对图 14 中的透射信号进行 FFT 变换, 得到归一化的频域幅值, 如图 15 所示。由图 15 中红色实线箭头可知, 在同种入射角度下, 当固化时间增大时, FFT 幅值逐渐增大, 峰值频率逐渐向高频移动, 这与有限元仿真和理论分析中峰值频率偏移的特征一致。

类似地, 通过 V_t 与 V_{ref} 的比值及归一化处理后得到相应的透射系数, 并与仿真结果进行对比, 如图 16 所示。可知, 当胶层固化时间小于 10 h 时, 透射系数随固化时间增大而迅速增大, 即初始固化时间对透射系数的影响较大, 这与有限元仿真结果中 $\omega\tau$<10 时的透射系数变化一致; 当固化时间大于 10 h 时, 透射系数随固化时间增大而缓慢增大; 当固化时间大于 12 h 时, 透射系数基本保持不变, 说明此时黏接界面接近于完好黏接状态, 对应仿真结

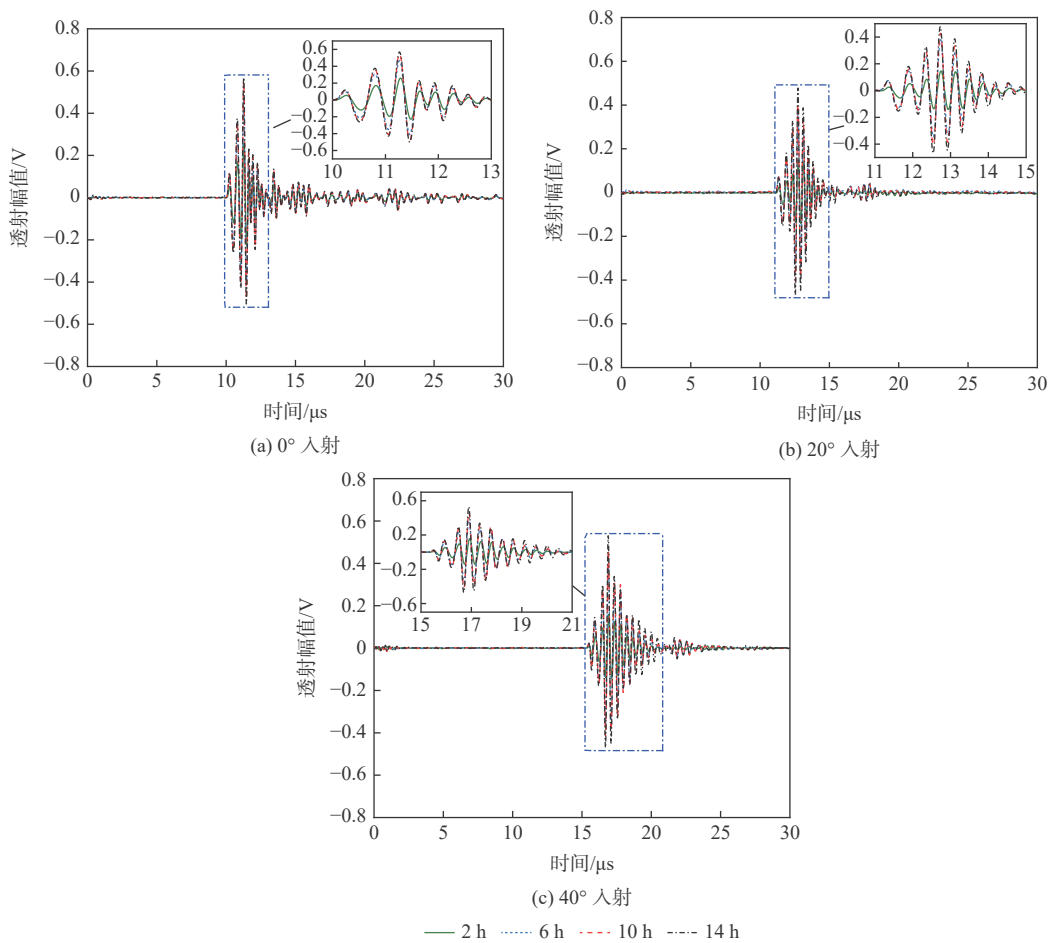


图 14　不同入射角度及固化时间的透射信号

Fig. 14　Transmission signals at different incident angles and curing times

表 2 时间误差分析

Table 2 Analysis of time errors

入射角度/(°)	时间/μs		误差/%
	有限元仿真结果	实验检测结果	
0	11.84	11.27	4.8
20	12.82	12.74	0.6
40	16.11	16.89	4.8

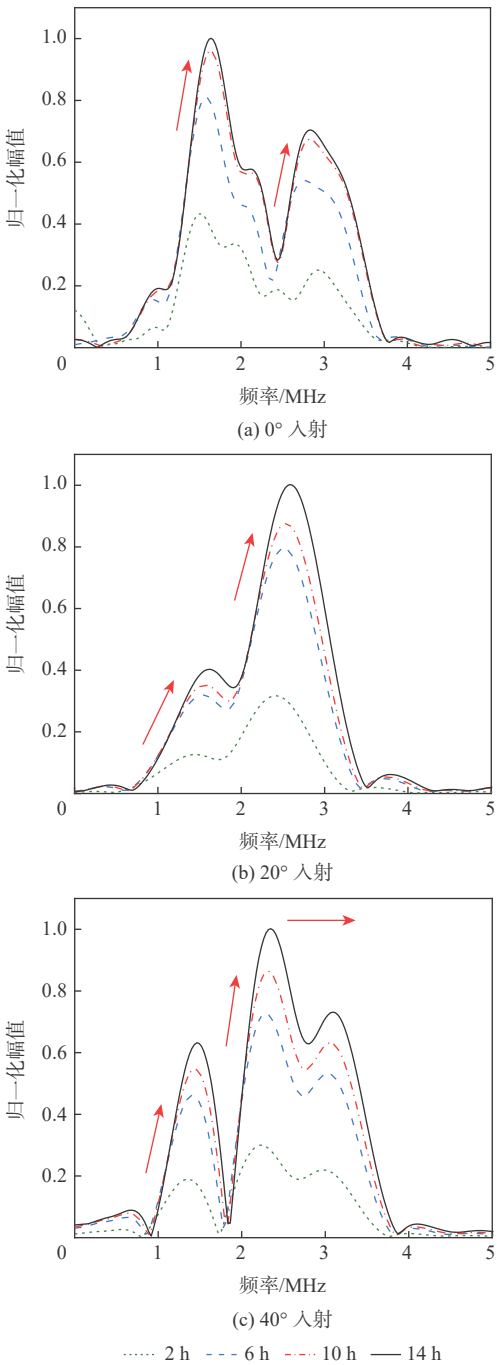


图 15 不同入射角度及固化时间的透射频谱图

Fig. 15 Transmission frequency spectrum plots at different incident angles and curing times

果中 $\omega\tau$=100 时界面的黏接状态。因此，实验结果与仿真结果对比发现，透射系数曲线的变化趋势整体相似。

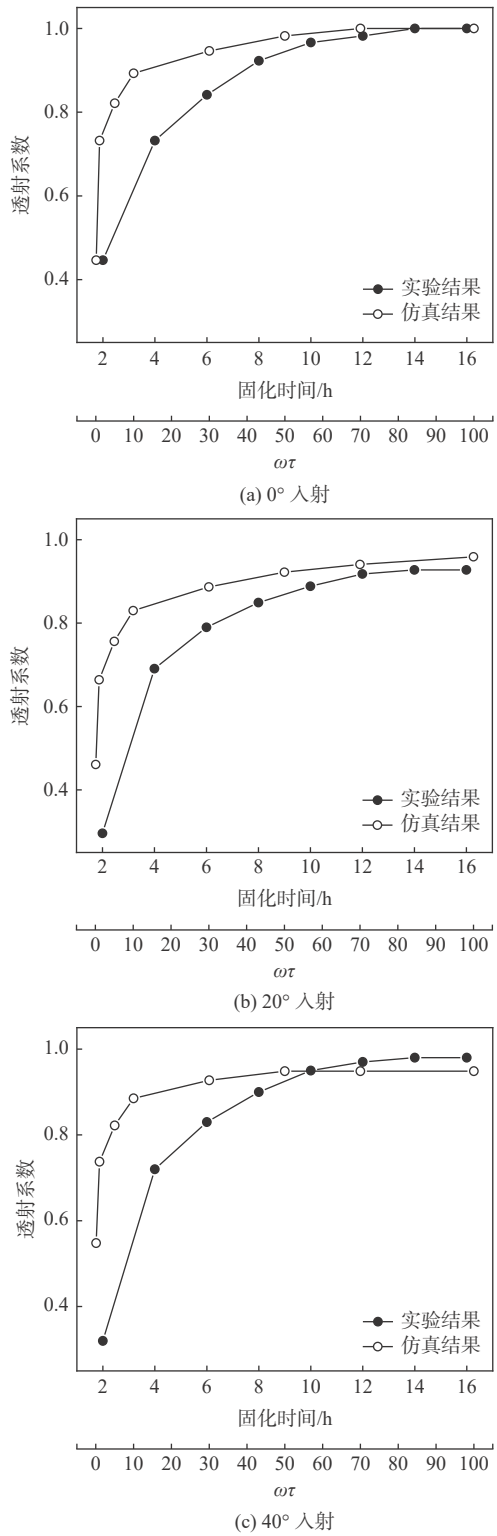


图 16 不同入射角度时的透射系数对比

Fig. 16 Comparison of transmission coefficients at different incident angles

4 结 论

针对 Al-CFRP 黏接结构中的超声传播特性，利用理论分析、有限元仿真及实验测试的方法，研究了黏接界面状态及入射角度对超声透射特性的影响。

1）利用传递矩阵法，建立了基于无量纲参数 $\omega\tau$

的黏接结构超声传播理论模型。当入射角为 0°时, 透射系数曲线出现共振现象; 当入射角为 20°和 40°时, 周期性共振现象消失, 透射系数峰值数量增多。在同一入射角度中, 随着 $\omega\tau$ 的增大, 透射系数峰值增大, 峰值频率逐渐向高频移动。

2) 建立了 Al-CFRP 黏接结构的超声透射时域仿真模型, 研究了接触式条件下 Al-CFRP 黏接结构中的声波透射特性。随着 $\omega\tau$ 的增大, FFT 幅值逐渐增大, 峰值频率逐渐向高频移动, 与理论分析中的“峰值漂移”现象相似。透射系数随着 $\omega\tau$ 的增加先迅速增大后缓慢增大。有限元仿真结果与数值理论结果的趋势一致。

3) 利用超声透射检测系统, 获得了胶层不同固化时间下的透射频率谱, FFT 峰值频率随 $\omega\tau$ 的变化而发生偏移现象。当固化时间小于 10 h, 透射系数随固化时间增大而迅速增大; 当固化时间大于 10 h 时, 透射系数随固化时间增大而缓慢增大; 当固化时间大于 12 h 时, 透射系数基本保持不变。实验结果与仿真结果变化趋势相似。

参考文献（References）

[1] Talebitooti R, Gohari H D, Zarastvand M R. Multi objective optimization of sound transmission across laminated composite cylindrical shell lined with porous core investigating non-dominated sorting genetic algorithm[J]. Aerospace Science and Technology, 2017, 69: 269-280.

[2] 张震, 曾亮, 张永华, 等. 粘接结构质量超声检测和信号处理方法[J]. 失效分析与预防, 2014, 9(2): 126-130.
Zhang Z, Zeng L, Zhang Y H, et al. Review on ultrasonic testing technology and processing method for bonding structure quality[J]. Failure Analysis and Prevention, 2014, 9(2): 126-130(in Chinese).

[3] 周正干, 滕利臣, 李洋. 复杂结构焊缝缺陷双线阵全聚焦超声成像方法[J]. 北京航空航天大学学报, 2021, 47(12): 2407-2413.
Zhou Z G, Teng L C, Li Y. Dual-linear-array TFM ultrasonic imaging method for weld defects of complex structure[J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 47(12): 2407-2413(in Chinese).

[4] Wang X G, Yao L F, Huang Z C, et al. Evaluating interfacial bonding characteristics of the composite material thin layer by ultrasound delay time spectrum[J]. Composite Structures, 2019, 222: 110913.

[5] Zhou W, Lv Z H, Wang Y R, et al. Acoustic response and microdamage mechanism of fiber composite materials under mode-II delamination[J]. Chinese Physics Letters, 2015, 32(4): 046201.

[6] Valente L L, Sarkis-Onofre R, Gonçalves A P, et al. Repair bond strength of dental composites: systematic review and meta-analysis[J]. International Journal of Adhesion and Adhesives, 2016, 69: 15-26.

[7] Wang X G, Wang J X, Shen G L, et al. Research on interface bonding characteristics of layered medium using ultrasonic oblique incidence[J]. Composite Structures, 2022, 295: 115733.

[8] 周正干, 王俊, 李洋, 等. 多层黏接结构的阵列超声检测评价方法[J]. 北京航空航天大学学报, 2023, 49(12): 3207-3214.
Zhou Z G, Wang J, Li Y, et al. Ultrasonic array testing and evaluation method of multilayer bonded structures[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(12): 3207-3214 (in Chinese).

[9] Thomson W T. Transmission of elastic waves through a stratified solid medium[J]. Journal of Applied Physics, 1950, 21(2): 89-93.

[10] Pilarski A, Rose J L. A transverse-wave ultrasonic oblique-incidence technique for interfacial weakness detection in adhesive bonds[J]. Journal of Applied Physics, 1988, 63(2): 300-307.

[11] 丁俊才, 吴斌, 何存富. 板状粘接结构中对称和反对称纵波与界面的相互作用[J]. 振动与冲击, 2017, 36(6): 27-37.
Ding J C, Wu B, He C F. Interaction of the symmetric and anti-symmetric longitudinal waves with the interfaces in plate-like adhesive structure[J]. Journal of Vibration and Shock, 2017, 36(6): 27-37(in Chinese).

[12] 孙凯华, 李建文, 孙朝明, 等. 钢-铅粘接结构的粘接强度对超声体波反射与透射特性的影响[J]. 应用声学, 2019, 38(1): 93-104.
Sun K H, Li J W, Sun C M, et al. Influences of bonding strength on reflection and transmission characteristics of ultrasonic bulk waves in steel-lead bonded structure[J]. Applied Acoustics, 2019, 38(1): 93-104(in Chinese).

[13] 吴斌, 张婧, 邱兆国, 等. 斜入射下粘接界面的反射特性[J]. 北京工业大学学报, 2013, 39(6): 801-805.
Wu B, Zhang J, Qiu Z G, et al. The reflective properties of bonding interface in oblique incidence[J]. Journal of Beijing University of Technology, 2013, 39(6): 801-805(in Chinese).

[14] 邱兆国, 吴斌, 何存富. 弱粘接结构中谐振频率与刚度比的数值研究[J]. 工程力学, 2012, 29(6): 32-37.
Qiu Z G, Wu B, He C F. Numerical analysis of resonance frequency and stiffness ratio in weak bonded structures[J]. Engineering Mechanics, 2012, 29(6): 32-37(in Chinese).

[15] 王耀俊. 多层固体媒质对声波的反射和透射[J]. 南京大学学报(自然科学版), 1993, 29(1): 49-62.
Wang Y J. Acoustic wave reflectionand transmission on multilayered media[J]. Journal of Nanjing University (Natural Sciences), 1993, 29(1): 49-62(in Chinese).

[16] Nayfeh A H, Chimenti D E. Ultrasonic wave reflection from liquid-coupled orthotropic plates with application to fibrous composites[J]. Journal of Applied Mechanics, 1988, 55(4): 863-870.

[17] Nguyen V H, Abdoulatuf A, Desceliers C, et al. A probabilistic study of reflection and transmission coefficients of random anisotropic elastic plates[J]. Wave Motion, 2016, 64: 103-118.

[18] 宋国荣, 刘明坤, 吕炎, 等. 正交各向异性板液/固界面的声反射与声透射[J]. 声学学报, 2020, 45(1): 77-86.
Song G R, Liu M K, Lv Y, et al. Acoustic reflection and transmission at the interface between orthotropic plate and liquid media[J]. Acta Acustica, 2020, 45(1): 77-86(in Chinese).

[19] Maghsoodi A, Ohadi A, Sadighi M. Calculation of wave dispersion curves in multilayered composite-metal plates[J]. Shock and Vibration, 2014, 2014: 410514.

[20] 宋国荣, 宋协宏, 吕炎, 等. 基于超声透射特性的复合材料粘接结构粘接质量预测[J]. 机械工程学报, 2024, 60(4): 230-238.
Song G R, Song X H, Lü Y, et al. Prediction of bonding quality of composite bonded structures based on ultrasonic transmission cha-

racteristics[J]. Journal of Mechanical Engineering, 2024, 60(4): 230-238(in Chinese).

[21] Son M S, Kang Y J. Propagation of shear waves in a poroelastic layer constrained between two elastic layers[J]. Applied Mathematical Modelling, 2012, 36(8): 3685-3695.

[22] Wang L, Rokhlin S I. Ultrasonic wave interaction with multidirectional composites: modeling and experiment[J]. The Journal of the Acoustical Society of America, 2003, 114(5): 2582-2595.

[23] He C F, Li Y K, Lyu Y, et al. Ultrasonic reflection characteristics of FRP-to-FRP bonded joints with thick adhesive layers for bonding evaluation: theoretical analysis[J]. Composite Structures, 2020, 246: 112402.

[24] Rose J L, Nagy P B. Ultrasonic waves in solid media[J]. The Journal of the Acoustical Society of America, 2000, 107(4): 1807-1808.

[25] Brekhovskikh L. Waves in layered media[M]. New York: Academic Press, 2012.

[26] Rokhlin S I, Wang Y J. Analysis of boundary conditions for elastic wave interaction with an interface between two solids[J]. The Journal of the Acoustical Society of America, 1991, 89(2): 503-515.

[27] Lavrentyev A I, Rokhlin S I. Models for ultrasonic characterization of environmental degradation of interfaces in adhesive joints[J]. Journal of Applied Physics, 1994, 76(8): 4643-4650.

[28] Loukkal A, Lematre M, Bavencoffe M, et al. Modeling and numerical study of the influence of imperfect interface properties on the reflection coefficient for isotropic multilayered structures[J]. Ultrasonics, 2020, 103: 106099.

[29] 丁俊才, 吴斌, 何存富, 等. 含各向异性层的多层结构中的横波传播[J]. 应用基础与工程科学学报, 2017, 25(1): 171-186.
Ding J C, Wu B, He C F, et al. Transverse wave propagation in multilayered structure with an anisotropic layer[J]. Journal of Basic Science and Engineering, 2017, 25(1): 171-186(in Chinese).

[30] 柴华友, 吴慧明, 张电吉, 等. 弹性介质中的表面波理论及其在岩土工程中应用[M]. 北京: 科学出版社, 2008: 18-19.
Chai H Y, Wu H M, Zhang D J, et al. Surface wave theory in elastic medium and its application in geotechnical engineering[M]. Beijing: Science Press, 2008: 18-19(in Chinese).

附录 A

$$
\begin{cases}
C_{11}=C_{44}=2\sin^2\theta_{T3}\cos P_3+\cos(2\theta_{T3})\cos Q_3\\
C_{12}=C_{34}=\mathrm{i}(\tan\theta_{L3}\cos(2\theta_{T3})\sin P_3-\sin(2\theta_{T3})\sin Q_3)\\
C_{13}=C_{24}=\sin\theta_{L3}(\cos Q_3-\cos P_3)/(\rho_3 C_{L3})\\
C_{14}=-\mathrm{i}(\tan\theta_{L3}\sin\theta_{T3}\sin P_3+\cos\theta_{T3}\sin Q_3)/(\rho_3 C_{T3})\\
C_{21}=C_{43}=\mathrm{i}(2\cot\theta_{L3}\sin^2\theta_{T3}\sin P_3-\\
\qquad\tan\theta_{T3}\cos(2\theta_{T3})\sin Q_3)\\
C_{22}=C_{33}=\cos(2\theta_{T3})\cos P_3+2\sin^2\theta_{T3}\cos Q_3\\
C_{23}=-\mathrm{i}(\cos\theta_{T3}\sin P_3+\tan\theta_{T3}\sin\theta_{L3}\sin Q_3)/(\rho_3 C_{L3})\\
C_{31}=C_{42}=2\rho_3 C_{T3}\sin\theta_{T3}\cos(2\theta_{T3})(\cos Q_3-\cos P_3)\\
C_{32}=-\mathrm{i}\rho_3(C_{L3}\cos^2(2\theta_{T3})\sin P_3/\cos\theta_{L3}+\\
\qquad 4C_{T3}\cos\theta_{T3}\sin^2\theta_{T3}\sin Q_3)\\
C_{41}=-2\mathrm{i}\rho_3 C_{T3}^2[2\cos\theta_{L3}\sin^2\theta_{T3}\sin P_3/C_{L3}+\\
\qquad\cos^2(2\theta_{T3})\sin Q_3/(2C_{T3}\cos\theta_{T3})]
\end{cases}
\tag{A1}
$$

式中：$P_3=\omega d_3\cos\theta_{L3}/C_{L3}$，$Q_3=\omega d_3\cos\theta_{T3}/C_{T3}$，$\theta_{L3}$ 和 θ_{T3} 分别为介质中纵波和横波的入射角，C_{L3} 和 C_{T3} 分别为纵波和横波的传播速度；ρ_3 和 d_3 分别为介质层的密度和厚度。

Ultrasonic transmission testing of bonding interface curing process in Al-CFRP composite structures

BU Fanqiang[1]，LIU Yong[1]，WANG Xingguo[1,*]，LI Xiaogao[1]，SHEN Guolang[1]，MA Chengwen[2]

(1. School of Mechanical and Electronic Engineering，Jingdezhen Ceramic Institute，Jingdezhen 333403，China；
2. Jiangxi Changxing Aviation Equipment Co.，Ltd.，Jingdezhen 333032，China)

Abstract：An ultrasonic transmission testing method was created in response to the difficulties in assessing the bonding states of isotropic-anisotropic composite structures. Based on the transfer matrix method, a dimensionless parameter $\omega\tau$ was introduced to describe bonding interface states. A theoretical model of ultrasonic propagation was established for the composite structure obtained by resin bonding Al and carbon fiber reinforced polymer (CFRP) to analyze the influence of the bonding state on the ultrasonic transmission characteristics. The results of theoretical analyses show that the transmission coefficient under the same incident angle gradually increases when $\omega\tau$ increases, and the transmission coefficient peak frequency shifts to higher frequency. Theoretical analyses reveal that the transmission coefficient at a fixed incident angle gradually increases as $\omega\tau$ increases, and the peak frequency shifts to a higher frequency. An ultrasonic transmission time-domain simulation model for the Al-CFRP composite structure was developed, and the simulation results show that the fast Fourier transform (FFT) amplitude gradually increases with $\omega\tau$ increasing, and the peak frequency shifts to a higher frequency. The transmission coefficient increases rapidly with $\omega\tau$ at first, then it increases slowly and eventually stabilizes. The trends in FFT amplitude and transmission coefficient with curing time are compatible with the simulation results, according to ultrasonic transmission testing measurements conducted on Al-CFRP bonded specimens under various bonding interfaces.

Keywords：isotropic; anisotropic; composite structures; bonding interface; ultrasonic transmission

Received：2025-01-06；**Accepted**：2025-02-07；**Published Online**：2025-02-27 14：23

URL：link.cnki.net/urlid/11.2625.V.20250227.1349.002

Foundation items：National Natural Science Foundation of China (52265020); Jingdezhen Municipal Basic Research and Frontier Technology Project (2025JCYJ001)

* **Corresponding author**. E-mail：wangxingguo@jcu.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0444

面向垂直轴风力发电机的柔性叶片结构优化

王晓喆[1]，王钰博[2,3]，吴坤[3]，万志强[4,*]

(1. 北京航空航天大学 无人系统研究院，北京 100191；2. 北京航空航天大学 国家卓越工程师学院，北京 100191；
3. 北京航空航天大学 飞行学院，北京 100191；4. 北京航空航天大学 航空科学与工程学院，北京 100191)

摘 要：垂直轴风力发电机的风轮旋转轴垂直于地面或气流方向，其在风向改变时无需对风，能够始终保持稳定的发电功率。应用柔性叶片可进一步提高发电功率，但缺乏相关理论及方法。基于此，提出一种基于二维气动力及简支梁理论的柔性叶片流固耦合分析及优化方法。基于现有叶片的基本信息开展柔性叶片设计与结构简化，提出分布载荷作用下的高效简支梁静力学解析方法；将二维黏性/无黏气动力与结构变形通过曲线插值拟合，建立柔性叶片的流固耦合响应分析框架；研究柔性叶片的刚度特性对发电机周期发电功率的影响规律，采用遗传算法和Kriging方法，以最大发电功率为目标进行柔性叶片的刚度优化。结果表明：柔性叶片结构有助于提升发电功率，可为垂直轴风力发电机的研究、设计和进一步应用提供参考。

关 键 词：垂直轴风力发电机；柔性叶片；流固耦合；结构设计；刚度优化
中图分类号：V211.47
文献标志码：A **文章编号**：1001-5965(2026)11-3770-09

垂直轴风力发电机(vertical axis wind turbine, VAWT)[1]是指风轮的旋转轴垂直于地面或气流方向的风力发电机。垂直轴风力发电机不仅简化了风力发电机的结构设定，也减小了风轮对风时的陀螺力。

按照发电机受力发电的方式进行分类，垂直轴风力发电机主要分为阻力型和升力型。阻力型垂直轴风力发电机主要利用空气流过叶片产生的阻力作为驱动力，而升力型垂直轴风力发电机则利用空气流过叶片产生的升力作为驱动力。目前，大功率多兆瓦级大型垂直轴风力发电机是未来的主要发展方向[2]，国内外均已提出10 MW级的垂直轴风力发电概念机[3]。

柔性叶片的设计灵感来源于鸟类翅膀，主要是通过羽毛高效地捕捉风能，羽毛虽轻，却具有很好的捕风性能，并且能够根据风力条件的不同进行灵活地调整。基于仿生学的启示，通过对羽毛的独特构造进行深入分析，从中提取相应的结构特性，进而研发出柔性羽形叶片。柔性叶片的设计充分考虑了空气动力学原理，可以完全克服刚性叶片的缺点，具有良好的空气动力学特性[4-5]。

飞机在流场中运动时，由于空气动力的作用，机翼结构会发生变形，进而影响到机翼的初始气动特性。流固耦合分析是指对流体与固体结构的相互作用进行计算的一种方法，空气动力和结构变形的相互作用和影响会被考虑在内，在工程领域十分重要。

流固耦合分析方法是当前的热点，国内外均开展了相关研究。武岳等[6-7]采用分区迭代算法求解流固耦合的作用，对大跨结构的等效风荷载、风振响应分析及风致气弹耦合效应等相关问题进行了深入研究。国外开展相关研究相对较早，Bathe等[8-10]

收稿日期：2024-06-18；**录用日期**：2024-08-09；**网络出版时间**：2024-08-27 10:19
网络出版地址：link.cnki.net/urlid/11.2625.V.20240826.1636.001
基金项目：中国科协青年人才托举工程项目(2022QNRC001)；航空科学基金(2022Z012051001)
* **通信作者**. E-mail：wzq@buaa.edu.cn

引用格式：王晓喆，王钰博，吴坤，等. 面向垂直轴风力发电机的柔性叶片结构优化[J]. 北京航空航天大学学报，2026，52(11)：3770-3778. Wang X Z，Wang Y B，Wu K，et al. Structural optimization of flexible blades for vertical axis wind turbines[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3770-3778 (in Chinese).

每年都会在美国主持一次关于流固耦合问题的学术交流会, 并领导开发了 ADINA 软件系统, 其流固耦合模块(fluid-structure interaction, FSI)包含了强耦合和弱耦合等功能, 可根据实际问题选择不同方法进行分析。以 Nastran 为代表的大型商用有限元软件集成了静气动弹性、飞行载荷、颤振等典型模块, 是流固耦合分析方法在飞行器设计中的进一步应用。

目前, 流固耦合分析方法广泛应用于不同领域。刘为佳等采用双向流固耦合计算方法对激波/边界层干扰下壁板的气动弹性响应过程进行数值模拟[11]; 罗剑桥等通过建立跨介质飞行器近水面滑跳流固耦合模型, 研究了复杂跨介质飞行器的近水面滑跳运动特性[12]; 李秋琳等则通过开展不同出口宽高比下的双 S 弯喷管双向流固耦合数值研究, 分析出口宽高比这一关键几何参数对双 S 弯喷管耦合特性影响及其流动特征影响[13]; 许云涛等发展了一种结合模态叠加法的高效率高精度计算流体力学/计算结构动力学(computational fluid dynamics/computational structural dynamics, CFD/CSD)双向耦合计算方法, 完成了典型超空泡射弹尾拍过程的流固耦合仿真计算[14]; 吴越等在进行柔性扑翼翼面形状和运动参数的优化设计中, 通过搭建流固耦合计算框架, 增加了适应涡格法自由尾涡迭代时间步长的框架结构, 提高了计算效率[15]; 李岳等在进行飞机滑水安全问题研究时, 通过构建飞机轮胎滑水流固耦合仿真分析模型, 基于单因素云模型数字特征及变权向量求解综合隶属度, 建立多元决策下的飞机滑水风险等级及划分标准[16]; 郭跃阳等在研究扑翼共振机理时, 采用流固耦合模拟, 研究了从传统结构模态和声学结构相互作用模态分析得出的模态频率下扑翼的空气动力学性能[17]; 聂顺辰等则在研究高速性能降落伞充气过程中顶篷损伤时采用了流固耦合方法进行分析[18]。

以上流固耦合分析方法在不同学科中的广泛应用展示了其较强的适应性。但基于 CFD/CSD 耦合的计算方法涉及流体力学与结构力学的反复迭代, 这一过程极其繁琐, 计算量大, 同时也存在着网格畸变、易发散等问题。如果分析场景较为复杂, 则收敛过程会十分困难。耦合过程的数据传递效率和映射精度同样影响着计算结果, 网格前处理工作较为依赖科研人员的经验。

垂直轴风力发电机叶片具有大展弦比平直机翼的特征, 其流固耦合问题具有典型二维特性, 可在合理假设的前提下进一步简化, 在提高效率的同时保证计算精度和鲁棒性。针对上述特点, 本文提出一种适用于垂直轴风力发电机的柔性叶片, 结合二维气动力和简支梁理论, 发展了相应的流固耦合分析方法和刚度优化方法。首先, 搭建柔性叶片的气动/结构耦合分析框架; 然后, 研究柔性叶片的刚度特性对风力发电机周期发电功率的影响规律; 最后, 结合遗传算法和 Kriging 方法, 以最大发电功率为目标, 完成垂直轴风力发电机柔性叶片的刚度优化。

1　流固耦合分析方法

1.1　气动力计算方法

H 型垂直轴风力发电机的基本结构和发电原理如图 1 所示。

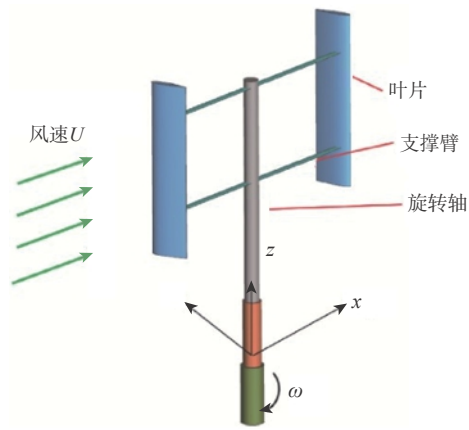


图 1　H 型垂直轴风力发电机基本结构和发电原理[19]

Fig. 1　Basic structure and power generation principle of the H-type vertical axis wind turbine[19]

其叶片具有大展弦比机翼特征, 可忽略展向流动, 仅考虑翼型的作用和影响。二维气动力的基本 Navier-Stokes 方程如下:

$$\begin{cases} \dfrac{\partial u}{\partial t}+u\dfrac{\partial u}{\partial x}+v\dfrac{\partial u}{\partial y}+\dfrac{1}{\rho}\cdot\dfrac{\partial p}{\partial x}=\upsilon\left(\dfrac{\partial^2 u}{\partial x^2}+\dfrac{\partial^2 u}{\partial y^2}\right) \\ \dfrac{\partial v}{\partial t}+u\dfrac{\partial v}{\partial x}+v\dfrac{\partial v}{\partial y}+\dfrac{1}{\rho}\cdot\dfrac{\partial p}{\partial y}=\upsilon\left(\dfrac{\partial^2 v}{\partial x^2}+\dfrac{\partial^2 v}{\partial y^2}\right) \end{cases} \tag{1}$$

式中: u、v分别为沿着 x、y方向上的速度分量; t为时间; p为压强; ρ为密度; υ为运动黏性系数。

当前成熟的商用空气动力学分析软件较多, 可满足不同的分析场景和计算需求。其中, XFOIL 是一种针对亚声速翼型的开源气动力分析程序, 由 Drela 开发, 采用黏性/无黏迭代方法, 具有较高的精度和效率, 本文选用 XFOIL 进行二维叶片的气动力分析[20]。

1.2　柔性叶片结构设计

对柔性叶片的结构进行展开设计, 具体包括: 中心梁、垂直梁、结构梁和蒙皮, 如图 2 所示。中心梁是叶片的主承力构件, 中心梁的结构刚度是主要优化对象。垂直梁和结构梁作刚性假设处理, 作

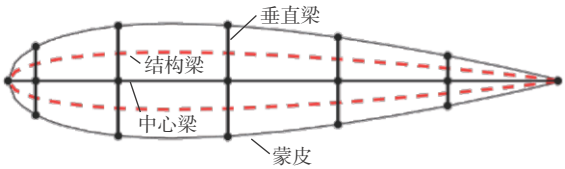


图2 柔性叶片结构示意图

Fig. 2 Schematic diagram of flexible blade structure

用于蒙皮的气动力可通过垂直梁直接传递至中心梁。结构梁可限制中心梁扭转，只产生垂向位移。

叶片上表面蒙皮为柔性膜，可以在气动力作用下变形，内部压强保持不变。作用于蒙皮的气动力可转化为分布的静载荷（本文分布静载荷数量取40，可根据实际情况调整），将叶片中心梁和蒙皮分为40段，前5段和后5段在计算中假设为刚性梁，其余30段为柔性梁，两端分别采用固支铰和活动铰约束，其刚度描述如下：

$$\begin{cases} K_{1,2}=\max(v_1,v_{\min}) \\ K_{2i-1,2i}=\max\left(v_1-\sum_{j=2}^{i}v_j,v_{\min}\right) \qquad 2\leqslant i\leqslant 7 \\ K_{\min}=\max\left(v_1-\sum_{j=2}^{7}v_j,v_{\min}\right) \\ K_{2i-1,2i}=K_{\min}+\sum_{j=8}^{i}X_j \qquad 8\leqslant i\leqslant 15 \end{cases} \tag{2}$$

式中：K_i为梁的刚度；$v_{\min}$为梁刚度的设计下限；v_1为第1段梁的刚度；v_i为该段梁刚度的减少量；$K_{\min}$为梁中心最小刚度；X_i为该段梁刚度的增加量。梁的刚度先减小后增大，其分布趋势与材料厚度分布一致。

1.3 结构静力学解析方法

在发电过程中，叶片的长度与弦长几乎不变，且与厚度相比，长度足够长。根据叶片受力、边界约束及无扭转假设，可将中心梁简化为具有不同刚度分布特性的简支梁[21]，如图3所示。简支梁受到固支铰约束及活动铰约束，沿梁施加从F_2～F_n的$n-1$个静载荷来模拟分布的气动力，F_1为边界约束反作用力。根据分布载荷，中心梁被划分为n段，与式(2)对应，则$K_n=E_nI_n$，其中，E_n和I_n分别表示中心梁第n段的弹性模量和截面惯性矩。F_n的施加点与固支铰约束点之间的距离为c_n，梁总长度为l。

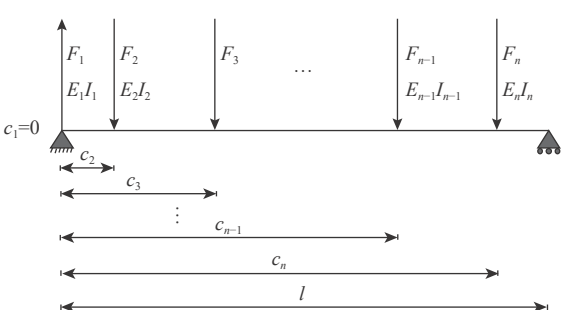


图3 叶片中心梁模型

Fig. 3 Central beam model of blades

采用单位载荷法求解中心梁的垂直位移。如图4所示，假设一个虚拟的单位载荷δF作用于中心梁上，其中，$\overline{F}_1$和$\overline{F}_3$为简支梁的约束力。

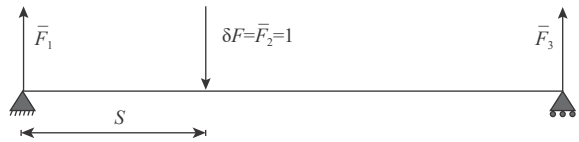


图4 虚功原理及单位载荷示意图

Fig. 4 Schematic diagram of virtual work principle and unit load

基于单位载荷法和虚功原理[22]，结合载荷分布情况，与约束点距离为S的点的垂直位移为

$$\begin{aligned} w(S)=&\int_{c_1}^{c_2}\frac{M_1(x)\overline{M}_1(x)}{E_1I_1}\mathrm{d}x+\int_{c_2}^{c_3}\frac{M_2(x)\overline{M}_1(x)}{E_2I_2}\mathrm{d}x+\cdots+\\ &\int_{c_k}^{S}\frac{M_k(x)\overline{M}_1(x)}{E_kI_k}\mathrm{d}x+\int_{S}^{c_{k+1}}\frac{M_k(x)\overline{M}_2(x)}{E_kI_k}\mathrm{d}x+\cdots+\\ &\int_{c_{n-1}}^{c_n}\frac{M_{n-1}(x)\overline{M}_2(x)}{E_{n-1}I_{n-1}}\mathrm{d}x+\int_{c_n}^{c_{n+1}}\frac{M_n(x)\overline{M}_2(x)}{E_nI_n}\mathrm{d}x \end{aligned} \tag{3}$$

式中：$M_n(x)$表示气动载荷作用在中心梁第n段的弯矩分布；$\overline{M}_1(x)$和$\overline{M}_2(x)$分别表示虚拟单位载荷分别在作用点前后所引起的弯矩分布。

1.4 建模及方法校验

通过商用有限元软件MSC.Nastran验证上述解析方法，简支梁的弦向截面参数如图5所示。

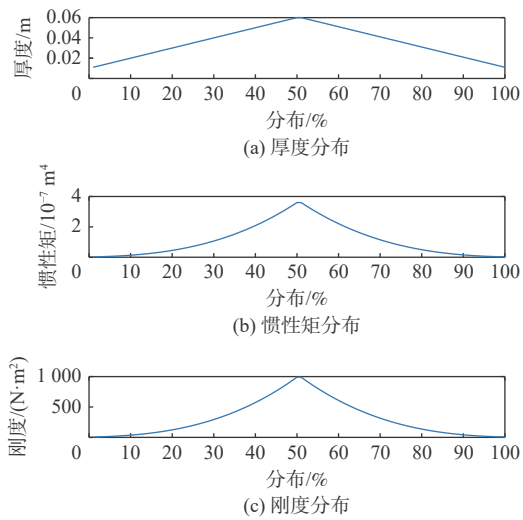


图5 简支梁结构特性

Fig. 5 Structural characteristics of simply supported beams

通过XFOIL计算叶片上/下表面的压强，并积分得到分布载荷，计算式如下：

$$\begin{cases} \Delta C_p=\int_0^l C_{p_\mathrm{low}}\hat{\boldsymbol{n}}\cdot\boldsymbol{n}_{\mathrm{normal}}\mathrm{d}x+\int_0^l C_{p_\mathrm{up}}\hat{\boldsymbol{n}}\cdot\boldsymbol{n}_{\mathrm{normal}}\mathrm{d}x \\ \Delta p=\dfrac{1}{2}\rho V^2\Delta C_p \end{cases} \tag{4}$$

式中: ΔC_p为上下翼面压力差系数; Δp表示上下翼面压力差; V 表示来流速度; ρ为空气密度; $\hat{\boldsymbol{n}}$为翼型外方向单位向量; $\boldsymbol{n}_{\text{normal}}$为梁法向单位矢量; 下标 up、low 分别表示翼型上、下表面。

迎角为 0°时, 有限元方法和解析法的结果对比如图 6 所示。可以看出, 2 种方法分别计算得到的垂直位移吻合较好, 本文分布载荷作用下的简支梁结构静力学解析方法具有较高的计算精度和效率。

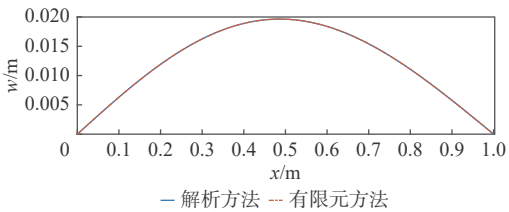


图 6　有限元方法和解析方法的结果比较

Fig. 6　Comparison of results between finite element method and analytical method

1.5　流固耦合分析

叶片流固耦合分析的基本流程如下:

1) 叶片的初始结构参数及风力发电机工作环境设定。

2) 采用 XFOIL 计算叶片的二维气动力, 通过压强积分和曲线插值拟合, 得到作用于中心梁的分布静载荷。

3) 应用简支梁静力学解析方法计算中心梁的垂直位移, 通过曲线插值拟合更新叶片的上表面气动外形, 并开始新一轮的气动力计算。

4) 重复上述流程, 当结构位移小于设定值时, 流固耦合计算收敛。

根据上述流程, 进行柔性叶片初始结构的流固耦合分析, 4 轮迭代后, 垂直位移收敛, 如图 7 所示。可以看出, 柔性叶片的上表面相对于刚性叶片的上表面有所改变, 叶片厚度稍有增加, 受风面积增大, 会影响垂直轴风力发电机的发电功率。

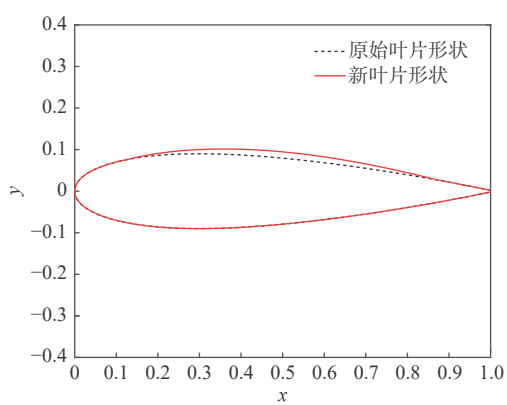


图 7　迭代前后叶片简化图对比

Fig. 7　Comparison of simplified diagrams of blades before and after iteration

2　发电功率分析方法

垂直轴风力发电机的叶片转子赤道面各个角、力、速度向量的示意图如图 8 所示。

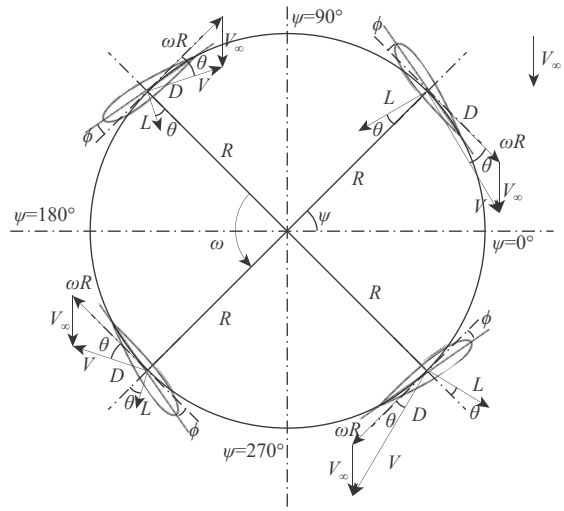


图 8　转子赤道面示意图

Fig. 8　Schematic diagram of the equatorial plane of the rotor

垂直轴风力发电机的旋转角速度与叶片气动力之间的关系如图 9 所示。

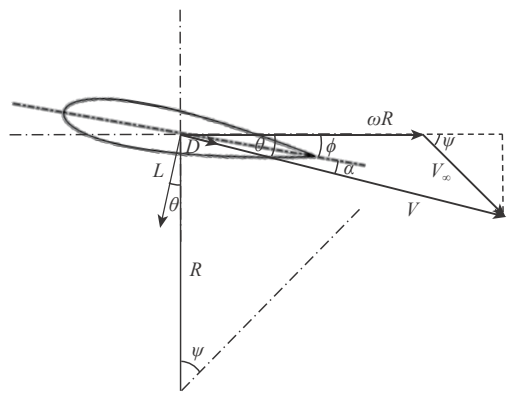


图 9　角速度与力的向量关系

Fig. 9　Vector relationship between angular velocity and force

根据图 9 中的几何关系, 当风速、角速度、俯仰角保持为常数时, 输出功率 P 为方位角的积分函数, 表达式如下:

$$P=\frac{\omega}{2\pi}\int_0^{2\pi}Q(\psi)\mathrm{d}\psi \tag{5}$$

式中: ω为角速度; ψ为叶片的方位角。

根据文献 [23], 叶片翼型选用 NACA0018 翼型, 其基本数据及风力发电机的工作环境如表 1 所示。

H 型垂直轴风力发电机旋转时的角度关系可表示为

$$\theta=\arctan\left(\frac{\sin\psi}{\cos\psi+\lambda}\right) \tag{6}$$

式中: $\lambda=\omega R/V_\infty$为转速比。

表1 基础环境设置

Table 1 Basic environment setting

风速 V_∞/(m·s^{-1})	额定转速ω/(rad·s^{-1})	叶片长度 l/m	叶片弦长 c/m	旋转半径 R/m	叶片数量n_b	俯仰角 ϕ/(°)	空气密度 ρ/(kg·m^{-3})
5.5	4.05	1	0.61	8.4	2	0	1.225

迎角α和入流角θ的关系如下：

$$\alpha=\theta-\phi \tag{7}$$

式中：ϕ为俯仰角。

叶片的俯仰角设定为0°，迎角α与入流角度θ相等，在旋转一周的过程中，其迎角α随方位角ψ的具体变化如图10所示。

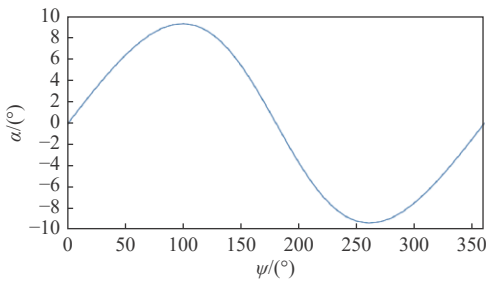


图10 迎角随方位角的变化

Fig. 10 Diagram of angle of attack changing with azimuth

根据发电机叶片的角度关系及合成速度V情况，得到计算式如下：

$$V=V_\infty\sqrt{(\lambda+\cos\psi)^2+\sin^2\psi} \tag{8}$$

根据式(8)，可得出叶片的合成速度与方位角之间的联系，如图11所示。

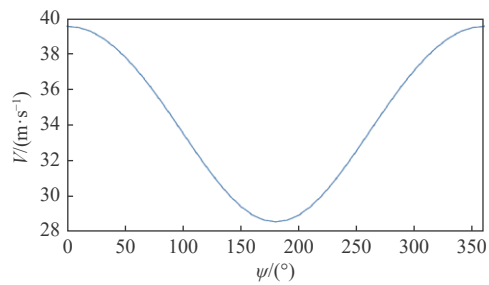


图11 合成速度曲线

Fig. 11 Resultant velocity curve

在叶片旋转一周的过程中，叶片的升力系数C_l、阻力系数C_d和切向力系数C_t随方位角的变化情况如图12～图14所示。

根据式(5)，结合表1中叶片参数及发电机工作参数，假设叶片在气动力的作用下无任何形变，可计算得出刚性叶片旋转一周的周期发电功率为2.100 kW。

按照式(2)所设定的柔性叶片结构的中心梁初始刚度分布，结合1.5节中的流固耦合计算方法，开展柔性叶片垂直轴风力发电机的发电功率计算，得

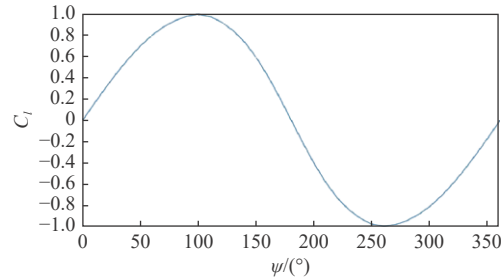


图12 升力系数随方位角变化

Fig. 12 Variation of lift coefficient with azimuth angle

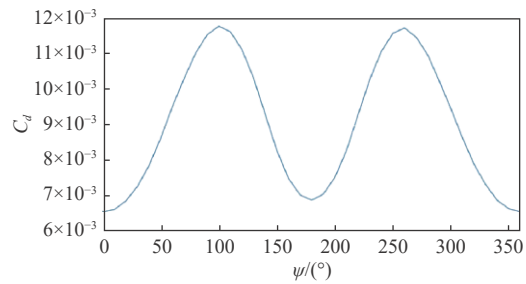


图13 阻力系数随方位角变化

Fig. 13 Variation of drag coefficient with azimuth angle

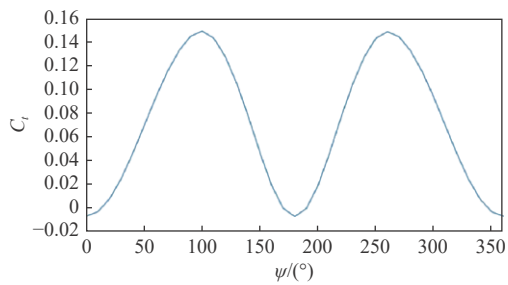


图14 切向力系数随方位角变化

Fig. 14 Variation of tangential force coefficient with azimuth angle

到柔性叶片旋转一周的发电功率为2.099 kW。

根据计算结果，将刚性叶片变为柔性叶片后，垂直轴风力发电机的发电功率有所减小，需要研究柔性叶片中心梁刚度对发电功率的影响规律，并开展刚度分布优化，以提升整体发电功率。

3 柔性叶片垂直轴风力发电机优化设计

3.1 基于代理模型的优化方法

遗传算法是一种现代启发式算法，其不依赖敏度信息，不易陷入局部最优解且具有较好的稳定性。遗传算法的核心是将问题的解决策略抽象为类似于生物遗传和进化中染色体的特性，并通过模拟生物进化过程中的杂交、基因突变等生物学过程来不断优化解决方案[24-25]。

为解决遗传算法样本数量多、计算耗费大等问

题, 引入 Kriging 代理模型以提高优化效率。Kriging 方法是依据协方差函数对随机过程或随机场进行空间建模和预测(插值)的回归算法。在特定的随机过程中, Kriging 方法能够给出最优线性无偏估计, 因此, 在地理统计学中也被称为空间最优无偏估计器[26]。

Kriging 模型表示如下:

$$y_k = f_k(\boldsymbol{x}) + z_k(\boldsymbol{x}) \qquad k = 1,2,\cdots,q \tag{9}$$

式中: y_k为未知函数; $\boldsymbol{x}$为n维向量; $f_k(\boldsymbol{x})$为回归模型, 可选用 0、1、2 次多项式; $z_k(\boldsymbol{x})$为随机函数。本文选用 2 次多项式和高斯函数构建 Kriging 模型[27]。有关 Kriging 模型及其改进形式的更多内容可参考文献 [28]。

相对误差是实际响应值和预测值之间的差异, 常用来校验代理模型的精度, 可表示为

$$e = \left| r_{\mathrm{a}} - r_{\mathrm{p}} \right| / r_{\mathrm{a}} \tag{10}$$

式中: r_{a}为实际响应值; r_{p}为模型的预测值。

Kriging 模型的建立流程如图 15 所示。

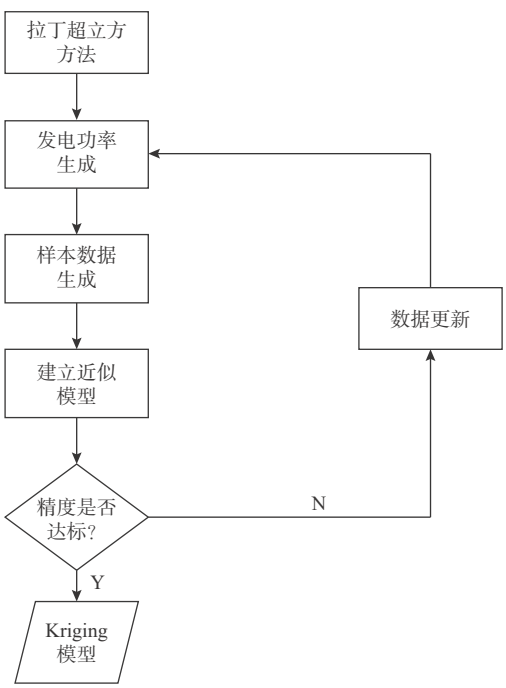


图 15　Kriging 模型建立流程

Fig. 15　Process of establishing Kriging model

首先, 设定中心梁刚度参数值的取值范围, 在设计变量的取值范围内采用拉丁超立方抽样选取足够数量的样本点。然后, 计算各柔性叶片样本的周期发电功率, 以样本的刚度分布为输入、周期发电功率为输出, 建立柔性叶片的发电功率 Kriging 模型。最后, 应用遗传算法, 以最大发电功率为目标函数, 开展基于 Kriging 代理模型的柔性叶片刚度优化, 将代理优化得到的最优刚度分布代入第 2 节建立的垂直轴柔性叶片风机发电功率计算方法得到真实的发电功率, 代理优化流程如图 16 所示。

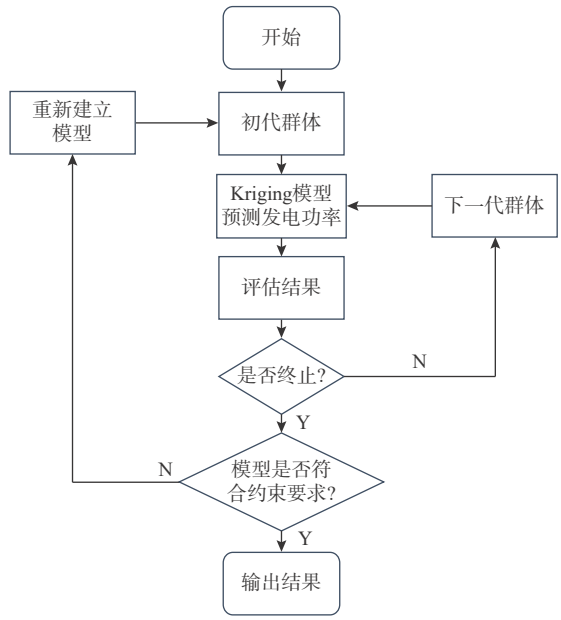


图 16　代理优化流程

Fig. 16　Flowchart of surrogate-based optimization

3.2　优化结果及分析

3.2.1　代理模型精度验证

以刚度分布为设计变量, 在变量空间内选取 200 个样本点计算对应的柔性叶片发电功率, 建立 Kriging 模型。在相同的样本空间内选取 50 个校验样本点并计算真实发电功率, 同时使用 Kriging 模型预测上述校验样本点的发电功率。对比 Kriging 模型的预测值和真实值, 并计算校验样本的相对误差, 如图 17 和图 18 所示。

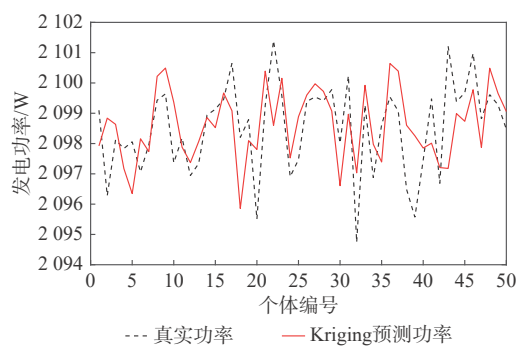


图 17　Kriging 方法得到的功率与真实功率的对比

Fig. 17　Comparison between power obtained by Kriging method and actual power

发电功率的代理预测值和真实仿真值的相对误差平均值为 $5.334\,6\times10^{-4}$, 误差值很小, 2 种方法得到的结果可以视为一致的, Kriging 模型具有较高的预测精度。

3.2.2　优化流程及结果

应用 MATLAB 优化工具箱中的遗传算法, Kriging

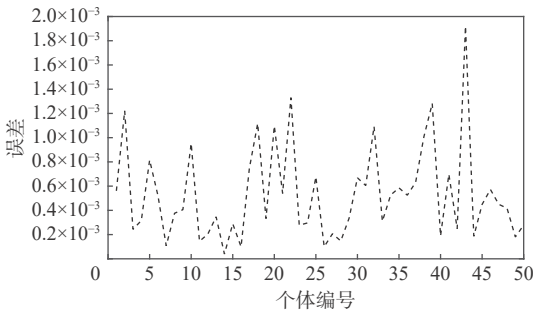


图 18 相对误差绝对值

Fig. 18 Absolute value of relative error

模型选用 DACE 工具箱。遗传代数设定为 20，每代样本数量设定为 100。在进化到第 8 代时，发电功率趋于收敛，经过叶片刚度优化后的最优发电功率为 2 107.59 W。

将 Kriging 代理优化得到的最优刚度分布信息进行真实柔性叶片发电功率仿真计算，得到发电功率为 2 107.54 W。通过结果的比较，可以看到，Kriging 方法优化得出的发电功率基本准确，优化结果可信且有效。

在第 2 节已开展了刚性叶片的发电功率计算，发电功率为 2 100.06 W，而未经优化的柔性叶片发电功率为 2 099.05 W。可以看出，通过优化设计，柔性叶片刚度分布更为合理，可有效提升发电功率，并取得 8 W 的功率收益，本文的柔性结构和优化方法有效可行。

由于叶片内部梁的设计较为简单，仅由弹性中心梁和刚性垂直梁组成，且表面蒙皮变形程度较小，未能充分发挥柔性叶片的提升潜力，使得功率收益较小。

4 结 论

垂直轴风力发电机风能利用率高、起动风速低，相比水平轴风力发电机具有效率高等优点。本文针对垂直轴风力发电机，提出一种柔性叶片结构，建立了高效的流固耦合分析框架及刚度优化方法。主要结论和创新点如下：

1）基于现有叶片的基本信息开展柔性叶片设计与结构简化，提出了分布载荷作用下的高效简支梁静力学解析方法。

2）将二维黏性/无黏气动力与结构变形通过曲线插值拟合，建立了柔性叶片的流固耦合响应分析框架。

3）研究了柔性叶片的刚度特性对发电机周期发电功率的影响规律，采用遗传算法和 Kriging 方法，以最大发电功率为目标进行了柔性叶片的刚度优化，可有效提升发电功率。

通过对垂直轴风力发电机的叶片进行柔性设计和刚度分布优化，可有效提升发电功率，可为垂直轴风力发电机的研究、设计和进一步应用提供参考。当前柔性叶片内部的梁结构较为简单，在未来工作中，将继续深入开展柔性叶片的变形结构、机构设计研究，以进一步提高发电功率。

参考文献（References）

[1] 何志宁, 刘座铭, 张宗珍. 垂直轴风力发电机的发展历史及现状[J]. 机械工程师, 2014(2): 39-40.
He Z N, Liu Z M, Zhang Z Z. Status quo and development of vertical-axis wind turbine[J]. Mechanical Engineer, 2014(2): 39-40(in Chinese).

[2] 张涵, 唐清春, 黄健友. 垂直轴风力发电机力学性能研究综述[J]. 机械工程与技术, 2024, 13(2): 144-153.
Zhang H, Tang Q C, Huang J Y. A review of research on the mechanical performance of vertical axis wind turbines[J]. Mechanical Engineering and Technology, 2024, 13(2): 144-153(in Chinese).

[3] Tjiu W, Marnoto T, Mat S, et al. Darrieus vertical axis wind turbine for power generation II: challenges in HAWT and the opportunity of multi-megawatt Darrieus VAWT development[J]. Renewable Energy, 2015, 75: 560-571.

[4] 张雷. 柔性叶片结构气弹稳定性分析研究[D]. 呼和浩特: 内蒙古工业大学, 2013.
Zhang L. Analysis of the flexible blade structure aeroelastic stability[D]. Hohhot: Inner Mongolia University of Technology, 2013 (in Chinese).

[5] 高荣臻. 柔性风力机叶片气弹响应试验研究[D]. 扬州: 扬州大学, 2023.
Gao R Z. Experimental study on aeroelastic response of flexible wind turbine blades[D]. Yangzhou: Yangzhou University, 2023(in Chinese).

[6] 沈世钊, 武岳. 膜结构风振响应中的流固耦合效应研究进展[J]. 建筑科学与工程学报, 2006, 23(1): 1-9.
Shen S Z, Wu Y. Research progress on fluid-solid interaction effect of wind-induced vibration response of membrane structure[J]. Journal of Architecture and Civil Engineering, 2006, 23(1): 1-9(in Chinese).

[7] 武岳, 沈世钊. 索膜结构风振响应中的气弹耦合效应研究[J]. 建筑钢结构进展, 2006, 8(2): 30-36.
Wu Y, Shen S Z. Study on wind-induced vibration of membrane-cable structures with the consideration of aeroelastic effect[J]. Progress in Steel Building Structures, 2006, 8(2): 30-36(in Chinese).

[8] Bathe K J, Zhang H, Ji S H. Finite element analysis of fluid flows fully coupled with structural interactions[J]. Computers & Structures, 1999, 72(1-3): 1-16.

[9] Bathe K J, Zhang H. A flow-condition-based interpolation finite element procedure for incompressible fluid flows[J]. Computers & Structures, 2002, 80(14-15): 1267-1277.

[10] Kohno H, Bathe K J. A nine-node quadrilateral FCBI element for incompressible fluid flows[J]. Communications in Numerical Methods in Engineering, 2006, 22: 917-931.

[11] 刘为佳, 李映坤, 陈雄, 等. 基于流固耦合的激波/边界层干扰作用下壁板颤振特性[J]. 航空学报, 2023, 44(6): 108-121.

Liu W J, Li Y K, Chen X, et al. Panel flutter characteristics on shock wave/boundary layer interaction based on fluid-structure coupling[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(6): 108-121(in Chinese).

[12] 罗剑桥, 解春雷, 金泽华, 等. 跨介质飞行器近水面滑跳流固耦合仿真及可滑跳区域研究[J]. 航空学报, 2023, 44(21): 377-394.
Luo J Q, Xie C L, Jin Z H, et al. Water-skipping fluid-structure interaction simulation and slippable area study of trans-medium vehicle[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(21): 377-394(in Chinese).

[13] 李秋琳, 周莉, 孙鹏, 等. 出口宽高比对 S 弯喷管流固耦合特性影响[J]. 航空学报, 2023, 44(14): 149-163.
Li Q L, Zhou L, Sun P, et al. Influence mechanism of aspect ratio on fluid-structure interaction characteristics of serpentine nozzle[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(14): 149-163(in Chinese).

[14] 许云涛, 檀大林, 杨超. 基于 CFD/CSD 耦合的高速射弹尾拍载荷特性研究[J]. 北京航空航天大学学报, 2023, 49(9): 2539-2546.
Xu Y T, Tan D L, Yang C. Study on tail-slap load characteristics of high-speed projectile based on CFD/CSD coupling[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(9): 2539-2546(in Chinese).

[15] 吴越, 谢长川, 杨超. 面向柔性扑翼翼面形状和运动参数的优化设计[J]. 北京航空航天大学学报, 2023, 49(12): 3311-3320.
Wu Y, Xie C C, Yang C. Optimal design of shape and motion parameters of a flapping wing[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(12): 3311-3320(in Chinese).

[16] 李岳, 胡宇祺, 蔡靖, 等. 基于变权重-正态云模型的飞机轮胎滑水风险[J]. 北京航空航天大学学报, 2023, 49(9): 2299-2305.
Li Y, Hu Y Q, Cai J, et al. Hydroplaning risk of aircraft tire based on variable weight theory-normal cloud model[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(9): 2299-2305 (in Chinese).

[17] Guo Y Y, Yang W Q, Dong Y B, et al. Resonance mechanism of flapping wing based on fluid structure interaction simulation[J]. Chinese Journal of Aeronautics, 2024, 37(5): 243-262.

[18] Nie S C, Yu L, Li Y J, et al. Fluid structure interaction of supersonic parachute with material failure[J]. Chinese Journal of Aeronautics, 2023, 36(10): 90-100.

[19] Zhang Y F, Li Q A, Zhu X Y, et al. Wind tunnel experiments and numerical study on performance characteristics of an H-type vertical axis wind turbine in the spanwise direction[J]. Journal of Thermal Science, 2021, 30(3): 758-771.

[20] Drela M. XFOIL: subsonic airfoil development system[DB/OL]. (2026-01-01)[2026-07-02]. https://web.mit.edu/drela/Public/web/xfoil/.

[21] 单辉祖. 材料力学Ⅰ[M]. 4 版. 北京: 高等教育出版社, 2016: 37-62.
Shan H Z. Mechanics of materials Ⅰ[M]. 4th ed. Beijing: Higher Education Press, 2016: 37-62(in Chinese).

[22] Hibbeler R C. Mechanics of materials[M]. New York: Pearson Education, Inc., 2014: 718-785.

[23] Kuester J F. Preliminary design of a vertical axis wind turbine with flexible sails[D]. Cranfield: Cranfield University, 2011.

[24] 王铁方. 计算机基因学: 基于家族基因的网格信任模型[M]. 北京: 知识产权出版社, 2016: 93-94.
Wang T F. Computer genetics: a grid trust model based on family genes[M]. Beijing: Intellectual Property Publishing House, 2016: 93-94(in Chinese).

[25] 郑树泉. 工业智能技术与应用[M]. 上海: 上海科学技术出版社, 2019: 250-251.
Zheng S Q. Technology and application of industrial intelligence [M]. Shanghai: Shanghai Scientific & Technical Publishers, 2019: 250-251(in Chinese).

[26] 刘国峰, 孟小红, 岳延波, 等. 克里金法在 GPS 数据内插中的应用[J]. 物探与化探, 2006, 30(2): 175-178.
Liu G F, Meng X H, Yue Y B, et al. The application of Kriging to GPS data interpolation[J]. Geophysical and Geochemical Exploration, 2006, 30(2): 175-178(in Chinese).

[27] Wang X Z, Wan Z Q, Liu Z, et al. Integrated optimization on aerodynamics-structure coupling and flight stability of a large airplane in preliminary design[J]. Chinese Journal of Aeronautics, 2018, 31(6): 1258-1272.

[28] 韩忠华. Kriging 模型及代理优化算法研究进展[J]. 航空学报, 2016, 37(11): 3197-3225.
Han Z H. Kriging surrogate model and its application to design optimization: a review of recent progress[J]. Acta Aeronautica et Astronautica Sinica, 2016, 37(11): 3197-3225(in Chinese).

Structural optimization of flexible blades for vertical axis wind turbines

WANG Xiaozhe[1]，WANG Yubo[2, 3]，WU Kun[3]，WAN Zhiqiang[4, *]

(1. Institute of Unmanned System，Beihang University，Beijing 100191，China；
2. National Superior College for Engineers，Beihang University，Beijing 100191，China；
3. School of Aviation，Beihang University，Beijing 100191，China；
4. School of Aeronautic Science and Engineering，Beihang University，Beijing 100191，China)

Abstract：A vertical-axis wind turbine has a rotation axis that is perpendicular to the ground or the direction of the airflow, allowing it to generate stable power without having to orient it as the wind direction changes. Applying flexible blades can further improve power generation, but there is currently a lack of relevant theories and methods. This article proposes a fluid-structure coupling analysis and optimization design method for the flexible blade based on two-dimensional aerodynamics and simply supported beam theory. First, an effective static analysis approach for simply supported beams under distributed loads is proposed, and flexible blade design and structural simplification are carried out based on the fundamental data of current blades. Then, the two-dimensional viscous/inviscid aerodynamic forces and structural deformation are fitted through curve interpolation to establish a fluid-structure coupling response analysis framework for flexible blades. Finally, the influence of the stiffness characteristics of flexible blades on the periodic power generation of generators is studied. The genetic algorithm and Kriging method are employed to maximize power generation by searching for the optimum stiffness of the flexible blades. The results indicate that the flexible blade structure helps to improve power generation, and this study can provide a reference for the research, design, and further application of vertical axis wind turbines.

Keywords：vertical axis wind turbine；flexible blades；fluid-structure coupling；structural design；stiffness optimization

Received：2024-06-18；**Accepted**：2024-08-09；**Published Online**：2024-08-27 10：19

URL：link.cnki.net/urlid/11.2625.V.20240826.1636.001

Foundation items：Young Elite Scientists Sponsorship Program by CAST (2022QNRC001); Aeronautical Science Foundation of China (2022Z012051001)

*** Corresponding author**. E-mail：wzq@buaa.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0531

基于低光实例的无人机航拍低光照图像增强算法

王殿伟[1,*]，赵五林[1]，房杰[1]，李苑青[1]，许志杰[2]
(1. 西安邮电大学 通信与信息工程学院，西安 710121；2. 哈德斯菲尔德大学 计算机与工程学院，哈德斯菲尔德 HD1 3DH)

摘 要：低光照图像增强是许多计算机视觉应用的重要预处理环节，针对低光照图像存在的亮度低、细节模糊、噪声干扰及成对低光/正常光训练数据获取困难等问题，提出一种新的两阶段无人机(UAV)航拍低光照图像增强算法。基于Retinex理论中内容相同的图像共享一致的反射分量，使用2张内容相同的低光照图像进行训练学习先验信息，不依赖于成对低光/正常光数据对。在第1阶段中提出细节增强模块(DEM)，通过捕获不同尺度的特征信息，增强反射分量的细节及边缘信息；在第2阶段中设计照明增强模块(IEM)，并引入照明注意图，增强照明分量的同时避免高对比度区域出现过曝光现象；构建去噪模块(DM)抑制反射分量中的噪声干扰。实验结果表明：所提算法在多个数据集上的视觉质量和客观评价指标优于当前先进算法，增强后的图像有助于目标检测算法在低光照图像处理上取得良好效果。

关 键 词：低光照图像增强；无人机航拍图像；细节增强；照明增强；图像去噪
中图分类号：TP391.41
文献标志码：A **文章编号**：1001-5965(2026)11-3779-11

无人机(unmanned aerial vehicle, UAV)航拍图像因其视角独特、包含信息量大的特点，在军事、森林防火、电力巡检、抗震救灾等领域有着广泛的应用。但无人机在光线较差条件下拍摄的图像普遍存在亮度不足、噪声干扰、细节模糊等问题，导致图像视觉效果降低并影响后续的计算机视觉任务，如目标检测、识别等[1]。因此，无人机航拍低光照图像增强(low-light image enhancement, LIME)已经成为研究热点[2]。

在低光照图像增强这一领域，目前已经提出了许多可行的算法。现有算法主要包含传统算法和深度学习算法2类。传统算法可以分为直方图增强类和Retinex类。其中，自适应直方图均衡化[3]、对比度限制自适应直方图均衡化[4]等算法通过调整图像的像素分布，增强亮度，改善图像视觉质量。Retinex类算法模拟人眼视觉感知将图像分解为照明、反射分量2部分，在低光照图像增强中有着广泛的应用[5]。在Retinex类算法中，Jobson等[6]提出多尺度Retinex算法将多个尺度的增强图像加权融合，作为最终结果。Guo等[7]提出低光照图像增强算法，使用结构先验来初始细化照明图，将反射分量作为最终结果。然而，传统算法依赖于手工设计约束，对单张图像调整成本大且难以应对复杂场景，泛化能力差，难以广泛应用。

近年来，深度学习算法取得了良好效果。现有算法可分为有监督的学习策略、无监督的学习策略及零样本的学习策略。其中，有监督的学习策略依赖于成对低光/正常光图像训练网络。Wei等[8]构建了RetinexNet网络，提出用深度学习的算法表征物理模型。Zhang等[9]提出的KinD网络，在反射分量恢复网络中使用照明分量作为引导，更好地恢复了反射分量。Wu等[10]提出URetinex-Net网络，该

收稿日期：2024-07-12；**录用日期**：2024-09-13；**网络出版时间**：2024-10-11 10:42
网络出版地址：link.cnki.net/urlid/11.2625.V.20241010.1955.004
基金项目：国家自然科学基金(62201454,62306235)；陕西省国际科技合作项目(2023-GHYB-04)；陕西省教育厅科学研究项目(23JK0670)；西安市科学技术局社会发展创新示范项目(23SFSF0004)；西安邮电大学研究生创新基金(CXJJYL2023018)
* **通信作者**. E-mail：wangdianwei@xupt.edu.cn

引用格式：王殿伟，赵五林，房杰，等. 基于低光实例的无人机航拍低光照图像增强算法[J]. 北京航空航天大学学报，2026，52(11)：3779-3789. Wang D W，Zhao W L，Fang J，et al. Low-light image enhancement algorithm for UAV aerial photography base on low-light instances[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3779-3789 (in Chinese).

网络分为初始化、展开优化及照明调整3个部分，可以根据用户需要调整亮度，取得了良好的效果。Yi等[11]构建了Diff-Retinex网络，在分解网络中引入Transformer对低光照图像进行分解，在反射分量恢复网中利用Diffusion恢复反射分量，取得了不错的效果。Cai等[12]构建了Retinexformer网络，利用照明引导的注意力模块实现图像增强。上述有监督学习的算法虽然增强效果良好，但大多需要成对低光/正常光数据集训练网络，在真实情况下，成对训练数据的获取存在很大困难。

相比于有监督学习的算法，基于无监督学习和零样本学习的算法不依赖于低光/正常光图像对，受到了越来越多的关注。Guo等[13]设计了零参考深度曲线估计(zero-reference deep curve estimation, Zero-DCE)网络，通过曲线迭代实现亮度增强。Jiang等[14]提出EnlightenGAN网络，使用生成对抗网络(generative adversarial network, GAN)在非配对图像之间建立映射。Ma等[15]构建了自校准照明(self-calibrated illumination, SCI)网络，通过引入权重共享的自校准模块，提高增强结果稳定性并大幅降低计算负担。Wen等[16]受相机物理模型的启发，提出一种深度估计曲线，通过迭代方式增强低光照图像，并设计去噪模块(denoise module, DM)减少噪声干扰。在上述无监督学习的算法中，(GAN)存在训练过程比较困难、损失函数收敛不稳定等问题[11]。零样本学习的算法在网络优化过程中仅使用单张低光照图像，泛化能力强，但存在单张图像包含信息不足、依赖手工制定的先验信息等问题，在定量性能上不如其他算法[17]。

为解决单张低光照图像中信息有限和手工先验适应性差的问题，Fu等[18]基于Retinex理论提出了一种从2张场景相同的低光照图像学习自适应先验的无监督增强算法PairLIE，获得更多信息的同时，不依赖于成对低光/正常光数据，取得了非常不错的效果。PairLIE从LOL[8]、SICE[19]数据集中收集内容相同的低光照图像对，由于2张低光照图像共享相同的内容，分解得到的反射分量一致。2张内容相同的低光照图像的Retinex分解可表示为：$\boldsymbol{I}_1=\boldsymbol{R}_1\boldsymbol{L}_1$，$\boldsymbol{I}_2=\boldsymbol{R}_2\boldsymbol{L}_2$。其中，$\boldsymbol{I}_1$、$\boldsymbol{I}_2$为低光照图像，$\boldsymbol{R}_1$、$\boldsymbol{R}_2$为反射分量，$\boldsymbol{L}_1$、$\boldsymbol{L}_2$为照明分量。但相比于普通低光照图像，无人机航拍图像的视角范围更广、包含的信息量更大，无人机夜间拍摄时更容易受点光源影响。PairLIE未对反射分量进行处理，增强后的低光照图像细节及边缘不清晰；其使用的全局Gamma校正方式增强照明分量会造成高对比度及点光源区域出现过曝光现象。

为解决上述问题，本文提出一种新的两阶段增强算法。第1阶段，首先，输入成对的低光照图像，由照明分量估计网络(illumination estimation net, IENet)与反射分量估计网络(reflection estimation net, RENet)分别估计照明分量与反射分量。通过引入照明先验信息帮助IENet更好地估计照明分量。其次，为更好地保留图像细节，本文设计了细节增强模块(detail enhancement module, DEM)，通过多尺度特征提取模块(multi-scale feature extract module, MFEM)捕获多个尺度的特征信息，提高网络的细节感知能力。利用特征融合模块(feature fusion module, FFM)将局部特征与全局特征相结合，增强反射分量的细节及边缘信息。第2阶段，仅需要将单张低光照图像输入训练好的IENet、RENet中得到照明分量、反射分量，通过引入照明注意图指导照明增强网络调整照明分量，避免高对比度区域出现过曝光问题。由于低光照图像存在噪声干扰问题，本文构建了DM来抑制反射分量中的噪声。将调整后的照明分量、反射分量重新组合，得到增强结果。创新点总结如下：

1) 构建了DEM，提高网络的细节感知能力，使增强后的图像细节更加清晰，边缘更加明显。

2) 设计了DM，抑制低光照图像中存在的噪声干扰问题。

3) 提出了照明增强模块(illumination enhancement module, IEM)，引入照明注意图，在增强亮度的同时防止对比度高的区域出现过曝光现象。

1 本文算法

低光照图像普遍存在亮度不足、噪声干扰、纹理及边缘信息模糊等问题。相比于普通低光照图像，无人机拍摄的图像信息量更大，夜间拍摄时更容易受点光源影响。为此，本文提出一种新的两阶段低光照图像增强算法。第1阶段为分解及细节增强。首先，图像通过分解模块分解为照明分量、反射分量；其次，设计了DEM，增强反射分量的细节及边缘信息。第2阶段构建了IEM增强照明分量。此外，设计了DM来抑制反射分量中的噪声干扰。将增强后的照明分量、反射分量结合，得到增强结果。图1展示了本文算法的整体网络结构。

1.1 分解模块

在基于Retinex理论的低光照图像增强算法中，如何估计照明信息是关键[20]，得到准确的照明分量后，反射分量可以通过后续网络进行处理。因此，本文构建了IENet和RENet，将输入图像分解为照明分量与反射分量2部分，在此基础上加入照明

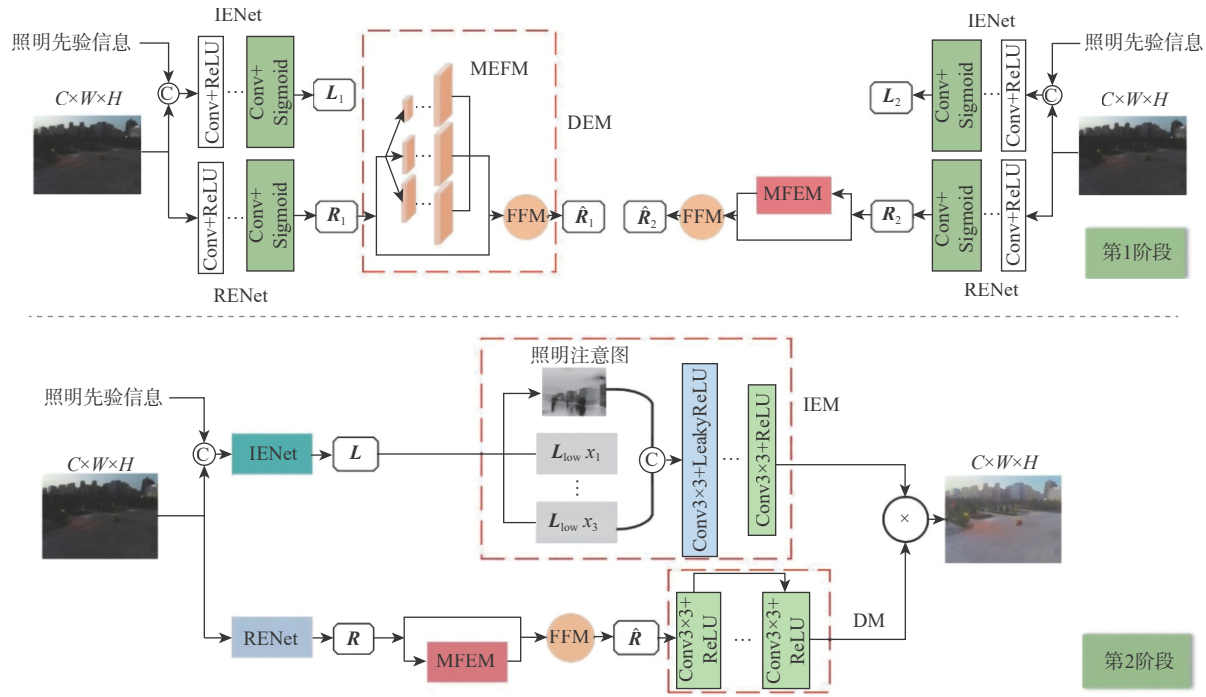


图 1　本文算法的网络结构

Fig. 1　Network structure of the proposed algorithm

先验信息帮助网络更好地估计照明分量。IENet 与 RENet 的损失函数设计如下:

$$L_{\mathrm{dc}}=\lambda_{\mathrm{re}}\|\boldsymbol{I}-\boldsymbol{RL}\|_2^2+\lambda_{\mathrm{ii}}\left\|\boldsymbol{L}-\max_{c\in\{R,G,B\}}\boldsymbol{I}^{(c)}\right\|_2^2+\lambda_{\mathrm{tv}}\nabla\boldsymbol{L}+\lambda_{\mathrm{rc}}\|\boldsymbol{R}_1-\boldsymbol{R}_2\|_2^2 \tag{1}$$

式中: $\boldsymbol{I}$为输入的低光照图像; $\boldsymbol{R}$和$\boldsymbol{L}$分别为分解网络得到的反射分量和照明分量; $c\in\{R,G,B\}$表示 RGB 通道; ∇表示垂直与水平梯度。经过实验, 本文将超参数的取值设置为 $\lambda_{\mathrm{re}}=1$, $\lambda_{\mathrm{ii}}=0.1$, $\lambda_{\mathrm{tv}}=1$, $\lambda_{\mathrm{rc}}=1$。式(1)等号右侧第 1 项为重建损失, 约束分解得到的 2 个分量重建后与输入图像一致, 第 2 项为照明初始化损失, 第 3 项为总变分损失, 用于平滑照明分量, 第 4 项为反射分量一致损失, 约束 2 张场景相同的低光照图像反射分量保持一致。

1.2　细节增强模块

为消除反射分量的退化并增强细节, 本文设计了 DEM 对反射分量进行处理, 保留更多的细节信息。DEM 由 MFEM 和 FFM 构成。

为保留反射分量中的细节信息, 本文构建了 MFEM, 提高网络的细节感知能力, 如图 2 所示。

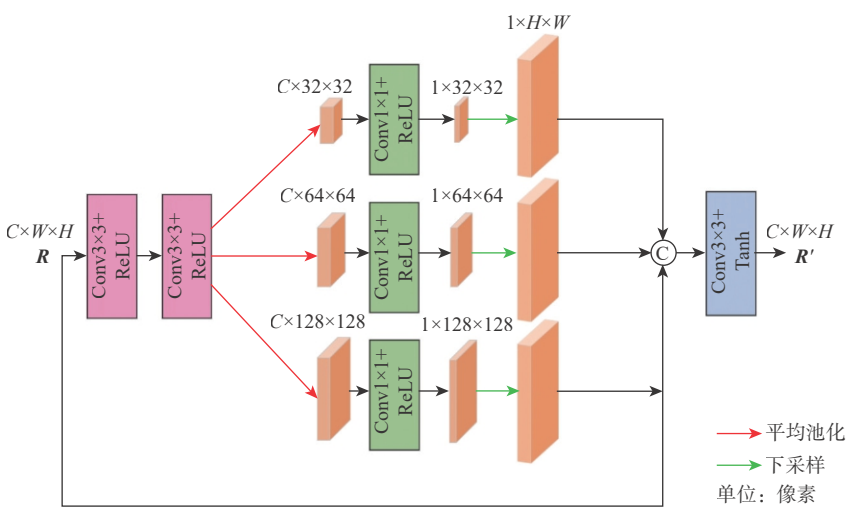


图 2　多尺度特征提取模块结构

Fig. 2　Multi-scale feature extract module structure

先将反射分量下采样到不同尺度, 捕获多个尺度的特征信息; 再将它们进行融合, 获得更丰富的特征信息来还原图像的颜色和细节, 使无人机低光照图像的细节更加清晰。MFEM 分为 3 条支路, 其

中，下采样的尺寸分别为32像素×32像素，64像素×64像素，128像素×128像素，最大池化层帮助网络收集更多的边缘细节信息。

虽然MFEM可以提供更丰富的局部细节特征，但在低光照图像增强任务中，全局特征和局部特征都是必不可少的[21]。全局特征提供图像的背景信息，局部特征提供图像的边缘细节信息。因此，受SENet[22]的启发，本文构建了FFM，对包含不同空间信息的特征图进行融合，捕获它们在空间上的相关性，图3展示了FFM的结构。FFM将初始低光照图像与MFEM得到的特征图合并作为输入，在获得全局特征的同时，避免了MFEM模块因下采样造成的细节丢失。FFM采用全局平均池化层降低特征图的维度，聚合特征通道的空间信息。FFM有2个全连接层(FC)，第1个用于降维，减少网络的参数量，第2个用于估计不同通道的权重系数，对重要特征赋予较大权重。将权重系数与原始特征通道相乘，再通过卷积层进一步提高网络特征表达能力。DEM的损失函数定义为

$$L_{\text{detail}}=\lambda_{\text{re}}\left\|\boldsymbol{I}-\hat{\boldsymbol{R}}\boldsymbol{L}\right\|_2^2+\lambda_{\text{c}}\left\|\hat{\boldsymbol{R}}_1-\hat{\boldsymbol{R}}_2\right\|_2^2+\lambda_{\text{ss}}\left(1-\text{SSIM}\left(\hat{\boldsymbol{R}}_{1,2},\boldsymbol{R}_{1,2}\right)\right) \tag{2}$$

式中：$\hat{\boldsymbol{R}}$为细节增强后的反射分量。经过实验，本文将超参数的取值设置为$\lambda_{\text{re}}=1$，$\lambda_{\text{c}}=1$，$\lambda_{\text{ss}}=0.1$。式(2)等号右侧第1项为重建损失，约束细节增强后的反射分量符合重建输入图像的要求，第2项为一致性损失，约束2张低光照图像的反射分量在细节增强后仍保持一致，第3项为结构相似性(structure similarity, SSIM)损失，约束细节增强后的反射分量与分解模块得到的反射分量在整体结构上保持一致。

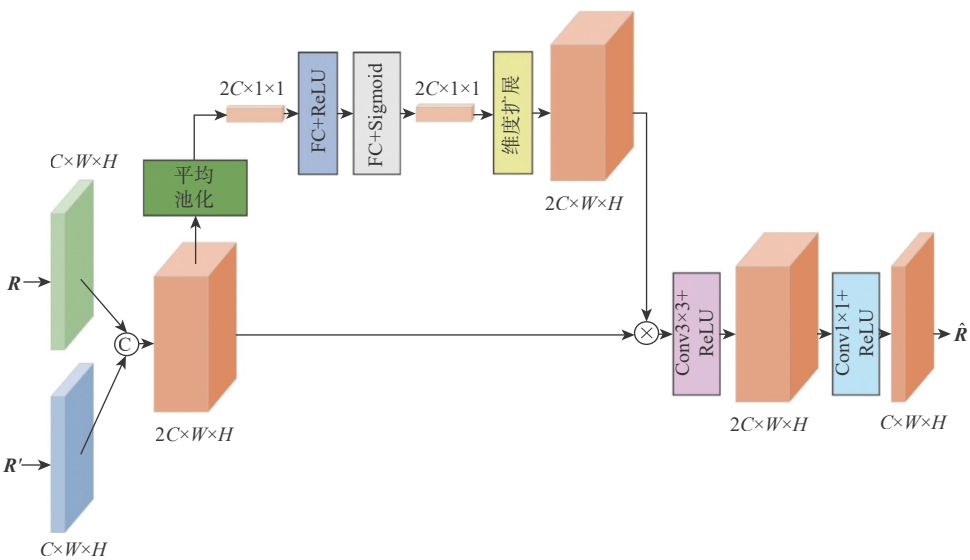


图3 特征融合模块结构

Fig. 3 Feature fusion module structure

本文算法的第1阶段由分解模块和DEM这2部分构成，对2个模块分别进行训练，第1阶段的总体损失函数包含2个部分，可以表示为

$$L_{\text{stage1}}=L_{\text{dc}}+L_{\text{detail}} \tag{3}$$

式中：L_{dc}为分解网络的损失函数；L_{detail}为DEM的损失函数。

图4展示了DEM的对比可视化结果，反射分量经过DEM后，细节更加清晰，边缘信息保留更加明显。



(a) 低光照图像 (b) 无细节增强 (c) 添加细节增强

图4 细节增强模块消融实验对比

Fig. 4 Comparison of detail enhancement module ablation experiments

1.3 去噪模块

低光照图像增强需要考虑去噪，因为噪声通常存在于黑暗区域[1]，为此本文构建了DM来抑制反射分量中的噪声干扰。低光照图像中的噪声主要是高斯噪声[23]，第1阶段的细节增强网络可以解决图像细节模糊的问题，但在细节增强的同时会带来噪声放大的问题。因此，本文将分解网络得到的反射分量看作无噪声图像，将细节增强后的反射分量人工添加高斯噪声后看作噪声图像。图5展示了DM的结构，采用9层具有对称跳跃连接的卷积层，避免出现信息丢失。DM的损失函数可表示为

$$L_{de}=\lambda_c\left\|\hat{\boldsymbol{R}}'-\boldsymbol{R}\right\|_1+\lambda_{ss}(1-\mathrm{SSIM}(\hat{\boldsymbol{R}}',\boldsymbol{R})) \tag{4}$$

式中: $\hat{\boldsymbol{R}}'$为加噪声反射分量去噪后的结果。式(4)等号右侧第 1 项为一致性损失, 第 2 项为结构相似性损失。经过实验, 本文将超参数的值设为$\lambda_c=5$, $\lambda_{ss}=1$。

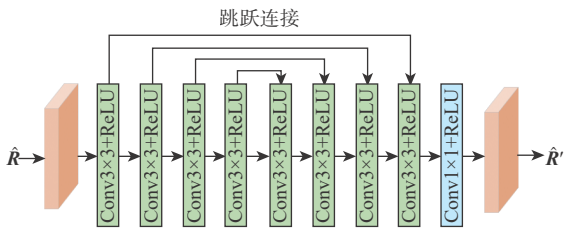


图 5　去噪模块结构

Fig. 5　Denoise module structure

1.4　照明增强模块

由于本文算法使用成对低光照图像进行训练, 不存在正常光照明分量作为参考, PairLIE 使用全局 Gamma 校正的方式增强照明分量, 但这种算法对整幅图像进行亮度调整, 容易造成高对比度区域出现增强过度的情况。为此, 本文构建了 IEM。首先, 采用多曝光融合的思想, 通过对低光照图像照明分量设置不同的曝光比例生成多曝光图像[24], 再将多曝光图像融合作为正常光照明分量, 可表示为

$$\boldsymbol{L}=\boldsymbol{L}_{\mathrm{low}}x_i \tag{5}$$

式中: $\boldsymbol{L}_{\mathrm{low}}$为低光照明分量; x_i为曝光比例。

其次, 引入 EnlightenGAN[14] 中的照明注意图, 对黑暗区域进行更多的增强, 相对明亮的区域增强较少。具体来说, 先将照明分量$\boldsymbol{L}$归一化到 [0,1] 之间, 再将$\beta-\boldsymbol{L}$作为注意图指导 IEM, β表示注意力图像素归一化后, 大小为 1, 解决高对比度区域出现过度增强的问题。图 6 展示了 IEM 的结构, 前 4 层由带 LeakyReLU 的 3×3 卷积层组成, 最后 1 层由 3×3 卷积加 ReLU 组成, 本文将低光照明分量和照明注意图融合作为输入, 经过照明注意图指导模块得到最终的增强结果。IEM 的损失函数表示如下:

$$L_{en}=\left\|\hat{\boldsymbol{L}}-\boldsymbol{L}_{\mathrm{high}}\right\|_2^2 \tag{6}$$

式中: $\hat{\boldsymbol{L}}$为调整后的照明分量; $\boldsymbol{L}_{\mathrm{high}}$为多曝光融合得到的正常光照明分量。

本文算法的第 2 阶段由 DM 和 IEM 这 2 部分构成, 对 2 个模块分别进行训练, 第 2 阶段的总体损失函数包含 2 个部分, 可以表示为

$$L_{\mathrm{stageII}}=L_{de}+L_{en} \tag{7}$$

式中: L_{de}为 DM 的损失函数; L_{en}为 IEM 的损失函数。

图 7 展示了 IEM 的对比可视化结果, 图 7(b)为照明注意图, 可以看出, IEM 在增强亮度的同时有效解决了高对比度区域及点光源出现过曝光的问题。

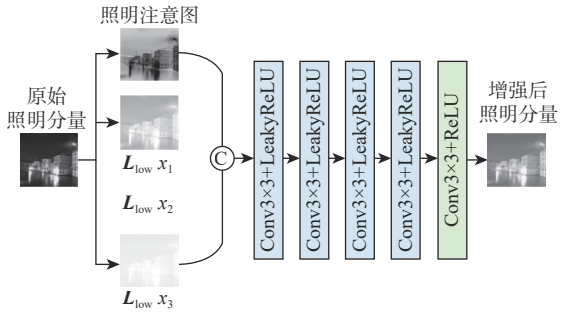


图 6　照明增强模块结构

Fig. 6　Illumination enhancement module structure



图 7　照明增强模块消融实验对比

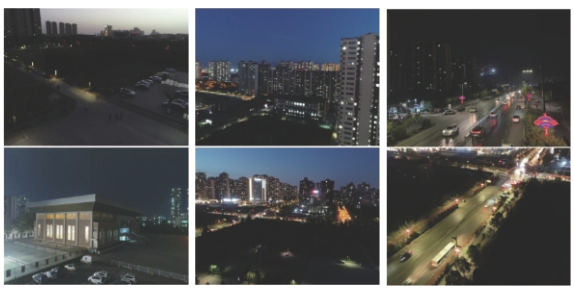
Fig. 7　Comparison of illumination enhancement module ablation experiments

2　实验结果与分析

2.1　实验细节

本文使用 PairLIE 从 LOL 数据集、SICE 数据集中收集的 324 组曝光不足且场景对齐良好的图像 (共 1 000 张低光照图像) 进行训练。SICE 数据集包含 589 个序列, 共 4 413 张多重曝光图像, 只从中选择曝光不足的图像。每组图像包含 2～6 张图像, 训练时从每组图像中随机抽取 2 张构成低光照图像对。对各模块分别进行训练, 分解模块及 DEM 选择 Adam 作为优化器, 批量大小设置为 1, 初始学习率设为 1×10^{-4}, 网络训练次数为 400。DM 及 IEM 选择 Adam 作为优化器, 初始学习率设为 1×10^{-4}, 网络训练次数为 200。本文实验的硬件平台配置为 Intel

Core i9-13900HX处理器，NVIDIA RTX 4060显卡，内存16 GB，使用Windows11操作系统和PyTorch1.13.0框架。为在无人机航拍图像上验证本文算法的有效性，使用大疆精灵4拍摄的200张多类真实环境下的低光照图像和网络查找获得100张无人机低光照图像组合作为测试集。测试集中使用无人机实际拍摄的场景（包含校园、建筑、城市街道），无人机拍摄的图像样例如图8所示。为与当前主流增强算法进行比较，本文还使用了公开数据集进行测试。



(a) 校园场景 (b) 建筑场景 (c) 街道场景

图8 无人机图像样例

Fig. 8 UAV sample image

2.2 客观评价

1）自建测试集。为验证本文算法的有效性，在自建测试集上与当前先进的16种基于深度学习的算法进行比较，包括RetinexNet[8]、MBLLEN[25]、KinD[9]、DRBN[26]、TBEFN[27]、Zero-DCE[13]、DSLR[28]、KinD++[20]、RUAS[29]、Zero-DCE++[30]、EnlightenGAN[14]、R2RNet[31]、URetinex-Net[10]、SCI[15]、PairLIE[18]、Self-DACE[16]。为验证算法的泛化能力，本文选取多类真实环境下的图像进行可视化比较。采用3种主流的无参考评价指标进行定量比较，包括LOE[32]、BRISQUE[33]、NIQE[34]。LOE反映图像增强后的自然程度，值越低，表示增强图像与原图像亮度顺序越接近，自然度更高。BRISQUE通过分析特征反映图像质量，值越低，表示图像越真实。NIQE用于评价无参考图像质量，值越小，表示感知质量越好。处理一幅图像所需要的时间越小，表示算法的速度越快。表1展示了客观评价结果，加黑数字为各指标的最优值。可以看出，在自建测试集上，本文算法在NIQE这项指标上取得了最好的结果，LOE的值达到第2，BRISQUE的指标靠前。处理图像时间为0.013 s，表示算法能够1 s处理约79张图像，能够满足实时性要求。参数量为7.73×10^5，大于部分轻量化的低光照图像增强算法，但整体而言本文算法在提升增强图像质量的同时参数量相对较小。与当前的先进算法相比，本文算法也有相当强的竞争力。

2）公开数据集。为进一步验证本文算法的泛化性能，在4个公开的低光照图像数据集（LIME、MEF、NPE、DICM）上进行测试。因为这些数据集不包含参考图像，所以本文选择NIQE作为评价指标。表2展示了定量结果，加黑数字为各数据集上的最优值。可以看出，本文算法在LIME数据集、NPE数据集上效果最好，DICM数据集上位于第2，进一步说明本文算法可以获得高质量视觉结果。

表1 不同算法的客观评价指标

Table 1 Objective evaluation indicators for different algorithms

算法	LOE	BRISQUE	NIQE	时间/s	参数量
RetinexNet[8]	702.80	31.47	3.663	0.120	0.555×10^6
MBLLEN[25]	361.15	32.92	3.849	13.991	0.450×10^6
KinD[9]	723.10	25.22	3.904	0.148	8.160×10^6
DRBN[26]	462.32	28.69	3.450	0.878	0.577×10^6
TBEFN[27]	406.56	19.00	3.419	0.050	0.486×10^6
Zero-DCE[13]	263.77	29.66	3.550	0.003	0.079×10^6
DSLR[28]	200.29	18.41	3.438	0.074	14.931×10^6
KinD++[20]	609.83	23.05	3.813	1.068	8.275×10^6
RUAS[29]	614.95	51.41	6.071	0.006	**0.003×10^6**
Zero-DCE++[30]	287.97	24.91	3.423	**0.001**	0.011×10^6
EnlightenGAN[14]	408.01	**17.64**	3.297	0.008	8.637×10^6
R2RNet[31]	227.57	28.55	3.896	0.667	35.740×10^6
URetinex-Net[10]	**153.29**	19.83	3.434	0.037	0.917×10^6
SCI[15]	222.67	20.14	3.568	0.002	0.011×10^6
PairLIE[18]	322.69	20.59	3.892	0.003	0.342×10^6
Self-DACE[16]	288.52	30.19	3.990	0.007	0.699×10^6
本文算法	169.87	18.86	**3.276**	0.013	0.773×10^6

表 2　不同算法在公开数据集上的 NIQE

Table 2　NIQE of different algorithms on public datasets

算法	NIQE			
	LIME	MEF	NPE	DICM
RetinexNet[8]	4.887	4.923	4.447	4.695
MBLLEN[25]	4.458	4.949	4.385	4.868
KinD[9]	4.323	3.716	4.379	3.824
DRBN[26]	4.143	3.775	4.096	3.787
TBEFN[27]	3.954	3.560	4.028	3.670
Zero-DCE[13]	3.769	3.754	3.976	3.446
DSLR[28]	4.231	4.025	4.313	4.519
KinD++[20]	4.197	3.567	4.223	3.687
RUAS[29]	4.358	4.746	4.483	4.471
Zero-DCE++[30]	3.967	3.629	4.022	**3.337**
EnlightenGAN[14]	3.719	**3.317**	4.113	3.567
R2RNet[31]	4.272	4.460	4.213	4.358
URetinex-Net[10]	4.241	3.987	4.041	3.707
SCI[15]	4.180	3.723	4.370	4.005
PairLIE[18]	4.294	3.975	4.107	3.796
Self-DACE[16]	4.143	4.562	4.367	3.949
本文算法	**3.617**	3.491	**3.964**	3.512

2.3　主观评价

1）自建测试集。为更直观地验证本文算法的有效性，在自建数据集上与当前主流算法进行比较，图 9 展示了测试结果。Zero-DCE++、Self-DCE 的增强结果都存在亮度增强不够和颜色偏差；KinD++的增强结果倾向于黄色且部分图像边缘细节不清晰；PairLIE 增强后的图像边缘细节模糊，点光源区域存在过曝光现象；本文算法设计了 DEM，能够提高网络的细节感知能力，使增强后的图像细节更加清晰，边缘更加明显；URetinex-Net 的增强结果在高对比度及点光源区域出现了明显的过曝光现象；SCI 对图像亮度增强过度，将原始图像中的亮色天空区域变为白色；本文构建的 IEM，引入照明注意图指导 DEM，增强结果减缓了过曝光和增强过度的现象。ElightenGAN 的增强结果边缘细节清晰，高对比度区域未产生过曝光现象，但在图像平滑区域出现了明显的噪声。本文算法设计的 DM，抑制了图像中存在的噪声干扰。可以看出，本文算法不仅增强了亮度，且使图像的细节更加清晰，减缓了高对比度区域及点光源出现过曝光现象，减少了噪声对图像的干扰，增强结果符合人眼视觉感知。

2）公开数据集。本文在 4 个公开的低光照数据集 (LIME、ME-F、NPE、DICM) 上与当前主流算法进行比较，结果如图 10 所示。第 1 幅、第 2 幅图中，URetinex-Net、SCI 等算法在点光源和高对比

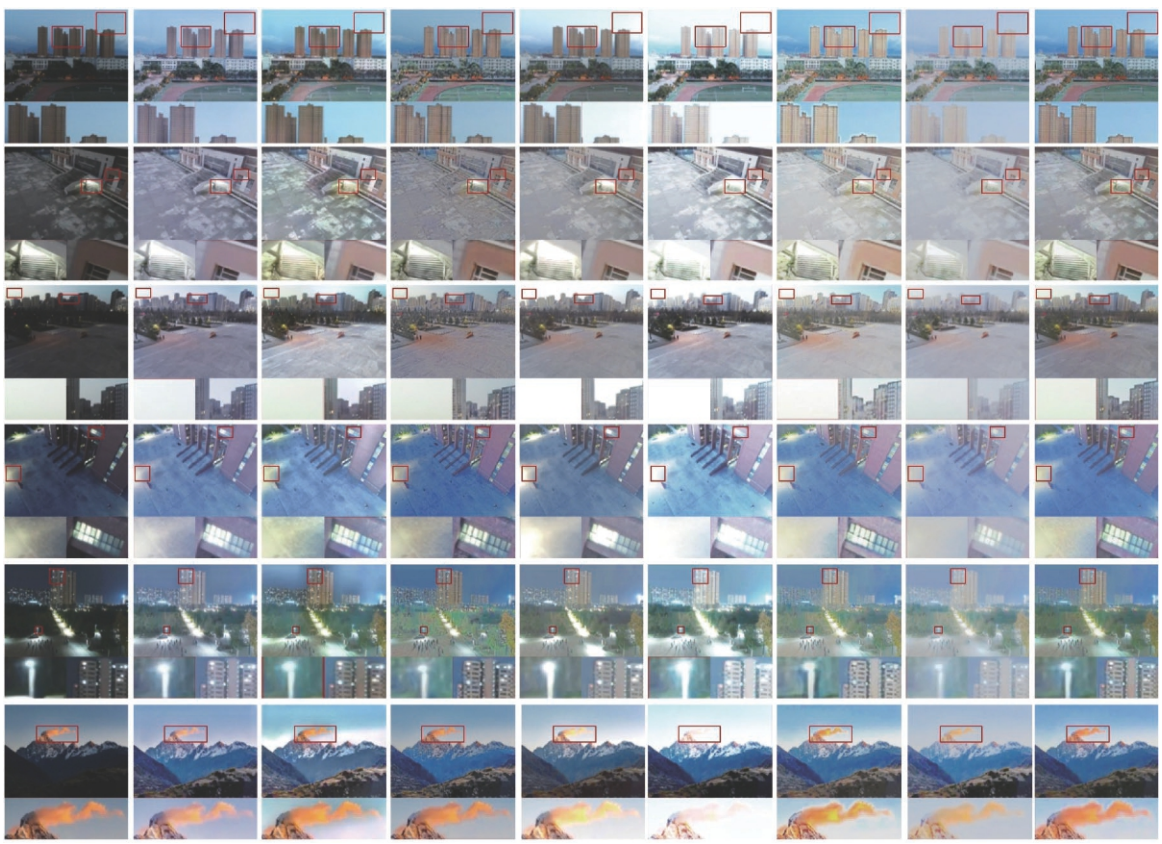


图 9　不同算法在自建数据集上的增强结果

Fig. 9　Enhancement results of different algorithms on the self-built dataset



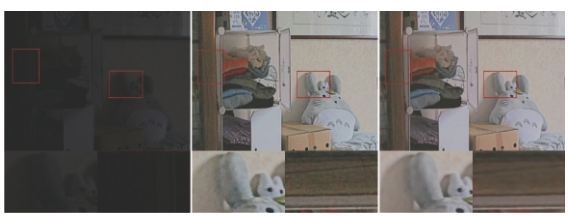
图 10 不同算法在公开数据集上的增强结果

Fig. 10 Enhancement results of different algorithms on public datasets

度区域出现了明显的过曝光现象。第 3 幅图中，ElightenGAN、Kin-D++增强后的图像存在明显的噪声干扰。第 5 幅、第 6 幅图中，PairLIE、Self-DCE 等算法边缘及细节不够清晰。本文算法设计了 DEM，能够提高网络的细节感知能力，楼房、树木等物体细节清晰；构建了照明注意图引导的 IEM，增强结果在点光源区域没有出现局部过曝光的情况；提出的 DM 对黑暗区域的噪声起到了抑制效果，改善了低光照图像的视觉质量。

2.4 消融实验

本文进行了 3 组消融实验，验证各模块（DEM、DM、IEM）的有效性。图 4 展示了 DEM 的消融对比结果；图 7 展示了 IEM 的消融对比结果；图 11 展示了 DM 的消融对比结果，图 11(b) 为未添加 DM 得到的结果，图像中的部分区域出现了明显的噪声，图 11(c) 为添加 DM 后得到的结果，图像中的噪声得到了明显的抑制。



(a) 低光照图像 (b) 无去噪模块 (c) 本文算法

图 11 去噪模块对比

Fig. 11 Comparison of denoise module

为评估各模块对网络性能的影响，本文采用峰值信噪比（peak signal-to-noise ratio, PSNR）、SSIM 这 2 个客观评价指标在 LOL 数据集上进行测试，数值越大，代表效果越好，表 3 展示了本文的测试结果。由表 3 可知，本文 DEM、DM 有效提升了图像质量。虽然 DEM 放大了噪声，但在加入 DM 后，图像噪声得到了明显的抑制。

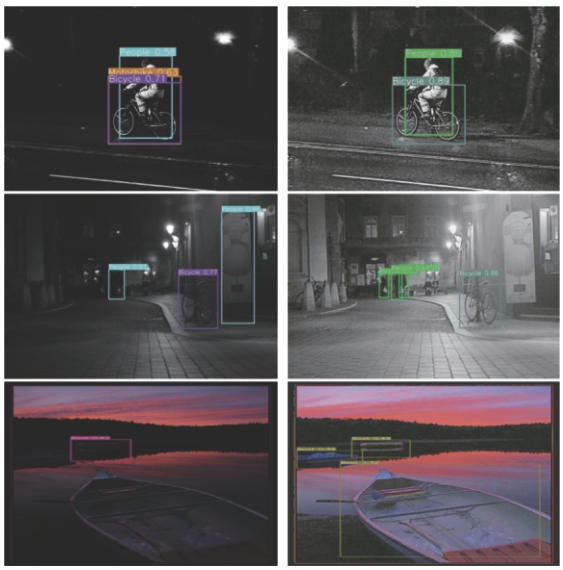
表 3 消融实验客观评价指标

Table 3 Objective evaluation indicators for ablation experiments

DEM	DM	PSNR/dB	SSIM
		19.53	0.729
	√	20.23	0.779
√		19.16	0.735
√	√	19.92	0.761

2.5 目标检测应用

为验证本文算法对目标检测任务在低光照图像处理上的帮助，在 ExDark[35] 数据 line-height-add:0.3pt 集上，使用 YOLOv7[36]、YOLOv8[37] 2 种主流目标检测算法分别对增强前后的图像进行测试。由图 12 和图 13 可知，在这 2 种检测算法上，增强后的图像对自行车、人、船这 3 种类别上的检测性能都有明显的提升，同时避免了增强前图像出现的误检和图像亮度低造成的漏检现象。为更加客观地验证本文算法的效果，采用精度、召回率作为客观评价指标，对这 2 种检测算法的性能进行定量分析，表 4 和表 5 展示了定量分析结果。可知，在对增强后的图像进行检测时，这 2 种算法在精度和召回率上都有明显提升。说明本文算法可以帮助目标检测算法在低光照图像的检测上取得更好的效果。



(a) 增强前目标检测结果　(b) 增强后目标检测结果

图 12　YOLOv7 目标检测算法结果

Fig. 12　YOLOv7 object detection algorithm results



(a) 增强前目标检测结果　(b) 增强后目标检测结果

图 13　YOLOv8 目标检测算法结果

Fig. 13　YOLOv8 object detection algorithm results

表 4　增强前后目标检测算法的精度对比

Table 4　Comparison of accuracy of object detection algorithms before and after enhancement

算法	自行车(增强前)	自行车(增强后)	人(增强前)	人(增强后)	船(增强前)	船(增强后)	小汽车(增强前)	小汽车(增强后)
YOLOv7[36]	0.630	0.715	0.603	0.684	0.571	0.685	0.426	0.509
YOLOv8[37]	0.794	0.810	0.793	0.819	0.724	0.764	0.807	0.812

表 5　增强前后目标检测算法的召回率对比

Table 5　Recall comparison of object detection algorithms before and after enhancement

算法	自行车(增强前)	自行车(增强后)	人(增强前)	人(增强后)	船(增强前)	船(增强后)	小汽车(增强前)	小汽车(增强后)
YOLOv7[36]	0.605	0.711	0.616	0.671	0.501	0.652	0.661	0.746
YOLOv8[37]	0.684	0.708	0.571	0.618	0.579	0.690	0.682	0.718

3　结　论

1) 本文提出一种新的两阶段图像增强算法, 有效解决了无人机低光照图像通常存在的亮度低、细节模糊、噪声干扰等问题。

2) 本文算法设计了细节增强模块保留图像的细节及边缘信息; 通过去噪模块抑制噪声干扰; 构建了照明注意图引导的照明增强模块, 在增强亮度的同时减缓了高对比度区域出现过曝光现象。

3) 实验结果表明, 本文算法不仅能有效提升亮度, 还能保持图像细节边缘清晰, 抑制了噪声干扰, 缓解了高对比度及点光源区域出现的过曝光现象, 得到的增强图像取得了不错的视觉效果。

为使本文算法能够应用于无人机平台上, 仍需对算法进行轻量级优化。

参考文献 (References)

[1] Yang K F, Cheng C, Zhao S X, et al. Learning to adapt to light[J]. International Journal of Computer Vision, 2023, 131(4): 1022-1041.

[2] 王殿伟, 刘旺, 房杰, 等. 颜色一致性的无人机航拍低光照图像增强算法[J]. 北京航空航天大学学报, 2025, 51(4): 1096-1106.
Wang D W, Liu W, Fang J, et al. Low illumination image enhancement algorithm for UAV aerial photography with color consistency[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(4): 1096-1106(in Chinese).

[3] Pizer S M, Amburn E P, Austin J D, et al. Adaptive histogram equalization and its variations[J]. Computer Vision, Graphics, and Image Processing, 1987, 39(3): 355-368.

[4] Pisano E D, Zong S Q, Hemminger B M, et al. Contrast limited adaptive histogram equalization image processing to improve the detection of simulated spiculations in dense mammograms[J]. Journal of Digital Imaging, 1998, 11(4): 193.

[5] Land E H. The retinex theory of color vision[J]. Scientific American, 1977, 237(6): 108-129.

[6] Jobson D J, Rahman Z, Woodell G A. A multiscale retinex for bridging the gap between color images and the human observation of scenes[J]. IEEE Transactions on Image Processing, 1997, 6(7): 965-976.

[7] Guo X, Li Y, Ling H. LIME: low-light image enhancement via illu-

mination map estimation[J]. IEEE Transactions on Image Processing, 2017, 26(2): 982-993.

[8] Wei C, Wang W J, Yang W H, et al. Deep retinex decomposition for low-light enhancement[EB/OL]. (2018-08-14)[2024-05-15]. https://arxiv.org/abs/1808.04560.

[9] Zhang Y H, Zhang J W, Guo X J. Kindling the darkness: a practical low-light image enhancer[C]//Proceedings of the 27th ACM International Conference on Multimedia. New York: ACM, 2019: 1632-1640.

[10] Wu W H, Weng J, Zhang P P, et al. URetinex-Net: retinex-based deep unfolding network for low-light image enhancement[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2022: 5891-5900.

[11] Yi X P, Xu H, Zhang H, et al. Diff-Retinex: rethinking low-light image enhancement with a generative diffusion model[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2024: 12268-12277.

[12] Cai Y H, Bian H, Lin J, et al. Retinexformer: one-stage retinex-based transformer for low-light image enhancement[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2024: 12470-12479.

[13] Guo C L, Li C Y, Guo J C, et al. Zero-reference deep curve estimation for low-light image enhancement[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 1777-1786.

[14] Jiang Y F, Gong X Y, Liu D, et al. EnlightenGAN: deep light enhancement without paired supervision[J]. IEEE Transactions on Image Processing, 2021, 30: 2340-2349.

[15] Ma L, Ma T Y, Liu R S, et al. Toward fast, flexible, and robust low-light image enhancement[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2022: 5627-5636.

[16] Wen J Y, Wu C H, Zhang T, et al. Self-reference deep adaptive curve estimation for low-light image enhancement[EB/OL]. (2023-09-10)[2024-05-15]. https://arxiv.org/abs/2308.08197.

[17] Li C Y, Guo C L, Han L H, et al. Low-light image and video enhancement using deep learning: a survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(12): 9396-9416.

[18] Fu Z Q, Yang Y, Tu X T, et al. Learning a simple low-light image enhancer from paired low-light instances[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2023: 22252-22261.

[19] Cai J R, Gu S H, Zhang L. Learning a deep single image contrast enhancer from multi-exposure images[J]. IEEE Transactions on Image Processing, 2018, 27(4): 2049-2062.

[20] Zhang Y H, Guo X J, Ma J Y, et al. Beyond brightening low-light images[J]. International Journal of Computer Vision, 2021, 129(4): 1013-1037.

[21] Wang L W, Liu Z S, Siu W C, et al. Lightening network for low-light image enhancement[J]. IEEE Transactions on Image Processing, 2020, 29: 7984-7996.

[22] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 7132-7141.

[23] Wei K X, Fu Y, Zheng Y Q, et al. Physics-based noise modeling for extreme low-light photography[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(11): 8520-8537.

[24] Zhu M F, Pan P B, Chen W, et al. EEMEFN: low-light image enhancement via edge-enhanced multi-exposure fusion network[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 13106-13113.

[25] Lv F F, Lu F, Wu J H, et al. MBLLEN: low-light image/video enhancement using CNNs[C]//Proceedings of the British Machine Vision Conference. Durham: BMVA Press, 2018.

[26] Yang W H, Wang S Q, Fang Y M, et al. From fidelity to perceptual quality: a semi-supervised approach for low-light image enhancement[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 3060-3069.

[27] Lu K, Zhang L H. TBEFN: a two-branch exposure-fusion network for low-light image enhancement[J]. IEEE Transactions on Multimedia, 2021, 23: 4093-4105.

[28] Lim S, Kim W. DSLR: deep stacked Laplacian restorer for low-light image enhancement[J]. IEEE Transactions on Multimedia, 2021, 23: 4272-4284.

[29] Liu R S, Ma L, Zhang J A, et al. Retinex-inspired unrolling with cooperative prior architecture search for low-light image enhancement[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2021: 10556-10565.

[30] Li C Y, Guo C L, Loy C C. Learning to enhance low-light image via zero-reference deep curve estimation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(8): 4225-4238.

[31] Hai J, Xuan Z, Yang R, et al. R2RNet: low-light image enhancement via real-low to real-normal network[J]. Journal of Visual Communication and Image Representation, 2023, 90: 103712.

[32] Ahn H, Keum B, Kim D, et al. Adaptive local tone mapping based on retinex for high dynamic range images[C]//Proceedings of the IEEE International Conference on Consumer Electronics. Piscataway: IEEE Press, 2013: 153-156.

[33] Mittal A, Moorthy A K, Bovik A C. No-reference image quality assessment in the spatial domain[J]. IEEE Transactions on Image Processing, 2012, 21(12): 4695-4708.

[34] Mittal A, Soundararajan R, Bovik A C. Making a “completely blind” image quality analyzer[J]. IEEE Signal Processing Letters, 2013, 20(3): 209-212.

[35] Loh Y P, Chan C S. Getting to know low-light images with the Exclusively Dark dataset[J]. Computer Vision and Image Understanding, 2019, 178: 30-42.

[36] Wang C Y, Bochkovskiy A, Liao H M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2023: 7464-7475.

[37] Varghese R, Sambath M. YOLOv8: a novel object detection algorithm with enhanced performance and robustness[C]//Proceedings of the International Conference on Advances in Data Engineering and Intelligent Computing Systems. Piscataway: IEEE Press, 2024: 1-6.

Low-light image enhancement algorithm for UAV aerial photography base on low-light instances

WANG Dianwei[1,*]，ZHAO Wulin[1]，FANG Jie[1]，LI Yuanqing[1]，XU Zhijie[2]

(1. School of Communications and Information Engineering，Xi'an University of Posts and Telecommunications，Xi'an 710121，China；
2. School of Computing and Engineering，University of Huddersfield，Huddersfield HD1 3DH，UK)

Abstract：A two-stage low-light image enhancement algorithm for unmanned aerial vehicle (UAV) aerial photography is proposed to address low-light image issues, including low brightness, fuzzy details, noise interference, and challenges in obtaining paired low/normal light training data. Low-light image enhancement is a crucial preprocessing component of many computer vision applications. Based on the Retinex theory that images with the same content share consistent reflection components, two low-light images with the same content are used for training to learn a priori information, which does not depend on paired low/normal light data pairs. The first stage features a detail enhancement module (DEM) that captures multi-scale feature information to enhance details and edges in the reflection component. To prevent overexposure in high-contrast areas while improving illumination, the second stage incorporates an illumination enhancement module (IEM) and an illumination attention map. Additionally, a denoise module (DM) is incorporated to suppress noise in the reflection component. Experimental results indicate that our method outperforms current state-of-the-art algorithms in visual quality and objective evaluation metrics across multiple datasets. Moreover, the enhanced images significantly improve the performance of target detection algorithms in low-light conditions.

Keywords：low-light image enhancement；unmanned aerial vehicle aerial image；detail enhancement；illumination enhancement；image denoising

Received：2024-07-12；**Accepted**：2024-09-13；**Published Online**：2024-10-11 10：42

URL：link.cnki.net/urlid/11.2625.V.20241010.1955.004

Foundation items：National Natural Science Foundation of China (62201454, 62306235); International Science and Technology Cooperation Program of Shaanxi Province (2023-GHYB-04); Scientific Research Program Funded by Shaanxi Provincial Education Department (23JK0670); Innovative Demonstration Projects for Social Development Funded by Xi'an Municipal Bureau of Science and Technology (23SFSF0004); Postgraduate Innovation Fund of Xi'an University of Posts and Telecommunications (CXJJYL2023018)

*** Corresponding author**. E-mail：wangdianwei@xupt.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0705

面向飞机舱门检测的改进 RT-DETR 模型

张长勇[1,*]，张轩铖[1]，乔亚海[1]，李铮[2]
(1. 中国民航大学 电子信息与自动化学院，天津 300300；2. 中国民航大学 计算机科学与技术学院，天津 300300)

摘 要：飞机舱门检测对于实现机场特种车辆自动靠机至关重要，针对因天气光照变化、机身涂装干扰及设备限制而导致的检测精度低、模型部署困难等问题，提出一种基于改进实时检测 Transformer (RT-DETR) 的飞机舱门检测模型。选用轻量级的残差神经网络 ResNet18 作为主干特征提取基准网络；通过引入上下文引导模块，优化主干网络中的 BasicBlock，增强对上下文信息的利用，降低计算资源的消耗；在颈部编码网络，将高低频 (HiLo) 注意力机制与内尺度特征交互 (AIFI) 模块相结合，形成 AIFI-HiLo 模块，增强特征表达，降低漏检率和误检率；采用二次改进后的高级筛选特征金字塔网络 (HS-FPN) 替换跨尺度特征融合模块 (CCFM)，增强模型对多尺度特征的融合能力。实验结果表明：所提改进模型的平均精度值达到 94.9%，对比基准模型提高了 1.8%，参数量、浮点运算量和模型体积分别降低了 41.3%、40% 和 41.6%；改进模型具有体积小、准确率高的特点，更适用于机场特种车辆搭载设备。

关 键 词：飞机舱门检测；机场特种车辆；实时检测 Transformer；上下文引导模块；高低频注意力；高级筛选特征融合金字塔
中图分类号：TP391.4; V35
文献标志码：A **文章编号**：1001-5965(2026)11-3790-11

在民航业追求高质量发展的时代背景下，“四型机场”——即平安、绿色、智慧、人文机场的建设理念，为未来中国机场的发展绘制了宏伟蓝图，其中，建设智慧机场不仅是技术创新与应用的集中展现，更是提升运营效率、保障安全服务、优化旅客体验的重要途径。在智慧机场的建设框架中，实现各种机场特种车辆的自动靠机是不可或缺的一环，特别是针对需要精准对接飞机舱门的特种车辆，如旅客登机梯、行动不便旅客登机车、集装货物装载机、散装货物装载机、航空食品车、航空垃圾接收车等。对于这些特种车辆来说，准确快速地获取飞机舱门位置是进行靠机作业的前提。因此，迫切需要开发高效、可靠的手段来完成飞机舱门检测任务。

历年来，相关学者和业界专家们积极运用先进的传感器技术与计算机领域的前沿成果，围绕飞机舱门检测开展了一系列研究。邓览[1]在舱门检测领域引入了双目视觉与图像处理技术，通过精确的边缘检测算法，实现了视觉方法在舱门识别中的初步应用；陈鸿顺等[2]采用高精度激光轮廓仪检测舱门的竖直边缘和下边缘，从而确定舱门位置，利用更为可靠的深度信息提高了舱门检测的精度；Casado Merino 等[3]借鉴人脸识别技术的思路，通过识别舱门周围独特的舷窗特征，为舱门检测提供辅助信息，提升了对不同舱门进行检测的普适性和可靠性；Andonovski 等[4]同样聚焦于利用与舱门相关的元素来辅助检测飞机舱门，但不仅仅局限于舷窗，还考虑了把手、文字标识、脚踏板、箭头指示等多种特征，并提出了一种逻辑算法，从而综合多种特征信息，最终确认舱门的准确位置；叶润等[5]则利用单次多框检测器(single shot multibox detector, SSD)

收稿日期：2024-09-26；**录用日期**：2024-10-25；**网络出版时间**：2024-11-20 18:09
网络出版地址：link.cnki.net/urlid/11.2625.V.20241120.1428.001
基金项目：民航首台（套）重点项目 (3122023PY04)
*通信作者. E-mail：cyzhang@cauc.edu.cn

引用格式：张长勇，张轩铖，乔亚海，等. 面向飞机舱门检测的改进 RT-DETR 模型 [J]. 北京航空航天大学学报，2026，52（11）：3790-3800. Zhang C Y，Zhang X C，Qiao Y H，et al. Improved RT-DETR model for aircraft door detection [J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：3790-3800 （in Chinese）.

目标检测算法, 结合轻量级的 MobileNet 特征提取网络, 构造了一种基于 MobileNet-SSD 的舱门检测模型, 能够在保证检测性能的同时, 降低计算复杂度; 谢玉森[6]将相机-激光雷达-惯性测量单元(inertial measurement unit, IMU)传感器组合, 通过提取图像特征、融合深度信息及捕捉动态变化, 运用同时定位与建图(simultaneous localization and mapping, SLAM)技术实现了在复杂和动态环境下的舱门跟踪检测, 为舱门检测技术的发展提供了新的思路与方法。

在机场实际环境下, 采取多传感器融合的方式能够得到较为精确的检测结果, 但其集成度不高, 不易搭载至机场特种车辆上, 且使用激光雷达这类主动式传感器, 可能存在干扰机场其他设备正常运作的风险, 相较之下, 基于深度学习的视觉目标检测方法凭借其简单实用、精准高效、非侵入式的特性, 无疑是更加适合舱门检测的优选方案。然而, 将视觉方法应用于实际场景时, 还需要克服 2 方面的问题: 一方面, 飞机舱门检测系统需要利用边缘端设备作为载体, 但高精度的目标检测模型往往拥有复杂的网络结构和巨大的参数计算量, 导致其难以部署到计算资源和存储空间均有限的智能边缘设备中; 另一方面, 轻量化模型会牺牲部分准确度, 在天气光照变化的影响下, 难以保证模型对不同大小舱门的检测精确性, 可能出现错检、漏检的情况。因此, 只有设计出检测性能较高且模型大小适中的飞机舱门检测模型才能满足机场特种车辆使用需求。

综上, 本文提出一种基于改进实时检测 Transformer(real-time detection Transformer, RT-DETR)的飞机舱门检测模型。该模型主要检测舱门的形状、轮廓及舱门与机身相对位置等特征, 并针对这些特征易受环境干扰、模型不易部署的问题, 引入轻量级的上下文引导模块[7], 对原始主干网络中的 BasicBlock 模块重新设计, 增强模型对上下文信息的利用, 减少模型的参数量和计算量; 在颈部编码网络部分融入高低频(high-low frequency, HiLo)注意力机制, 强化内尺度特征交互(intra-scale feature interaction, AIFI)模块特征捕捉能力; 同时, 采用新的高级筛选特征金字塔网络(high-level screening feature pyramid network, HS-FPN)替换跨尺度特征融合模块(cross-scale feature fusion module, CCFM), 并借鉴坐标注意力(coord attention, CA)针对 HS-FPN 独特的筛选机制进行二次改进(记为 CA-HS-FPN), 提升模型对检测目标特征的表征能力和融合效率。利用实验验证网络改进的有效性, 力求在降低模型参数与计算量的同时, 提高模型的检测精度。

1　RT-DETR 模型结构

RT-DETR[8]是基于 DETR 的实时端到端目标检测器。DETR[9]采用 Transformer 架构, 通过自注意力机制在整个图像中捕捉长程依赖关系, 实现端到端的目标检测。RT-DETR 在此基础上, 通过将多尺度特征交互分解为内尺度交互和跨尺度融合的两步操作, 显著减少了计算资源消耗, 避免了传统卷积神经网络方法中复杂的候选区域生成和非极大值抑制(non-maximum suppression, NMS)等后处理步骤, 相较于主流的更快的基于区域的卷积神经网络(faster region-based convolutional neural network, Faster R-CNN)、YOLO 等方法, 在速度和精度上均有显著提升, 更适用于实时应用场景。在 RT-DETR 目标检测模型中, 官方共给出以 ResNet 为主干的 RT-DETR-R18、RT-DETR-R34、RT-DETR-R50、RT-DETR-R101 和以 HGNet 为主干的 RT-DETR-L、RT-DETR-X 等 12 个版本, 考虑到机场特种车辆对于飞机舱门检测模型的实际需求, 本文选择网络深度与检测精度较为适中的 RT-DETR-R18 作为基础模型, 其具体网络结构主要包含主干网络、高效混合编码器、不确定性-最小查询选择机制、搭载辅助预测头的解码器 4 个部分, 如图 1 所示。

主干网络采用 ResNet-18[10]实现特征提取, 构成部分有卷积层、最大池化层(MaxPool)及具有残差结构的 BasicBlock。卷积层用于初步提取图像特征, 通过卷积、批量标准化和激活函数来增强特征表达能力; 最大池化层则用于下采样, 减少特征图的尺寸; 在深层特征提取阶段, 网络使用多个 BasicBlock 来进一步提取复杂的图像特征, 每个阶段的 BasicBlock 具有不同的输出通道数, 从而能够捕捉多尺度的特征。

高效混合编码器以主干网络最后 3 个阶段的输出特征 $\boldsymbol{S}_3$、$\boldsymbol{S}_4$、$\boldsymbol{S}_5$ 作为输入, 利用 AIFI 和 CCFM 将多尺度特征转换为图像特征序列。其中, AIFI 只在高级特征 $\boldsymbol{S}_5$ 上执行内尺度交互, 大大减少了计算冗余; CCFM 将由卷积层和 RepC3 组成的融合块插入到相邻特征的融合路径中, 对不同路径输出通过逐元素加法融合, 确保融合过程中的特征信息不会丢失。编码器计算过程为

$$\boldsymbol{Q}=\boldsymbol{K}=\boldsymbol{V}=\mathrm{Flatten}(\boldsymbol{S}_5) \tag{1}$$

$$\boldsymbol{F}_5=\mathrm{Reshape}(\mathrm{Aifi}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V})) \tag{2}$$

$$\boldsymbol{O}=\mathrm{Ccfm}(\{\boldsymbol{S}_3,\boldsymbol{S}_4,\boldsymbol{F}_5\}) \tag{3}$$

式中: $\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$ 分别表示不同的数据矩阵或向量,

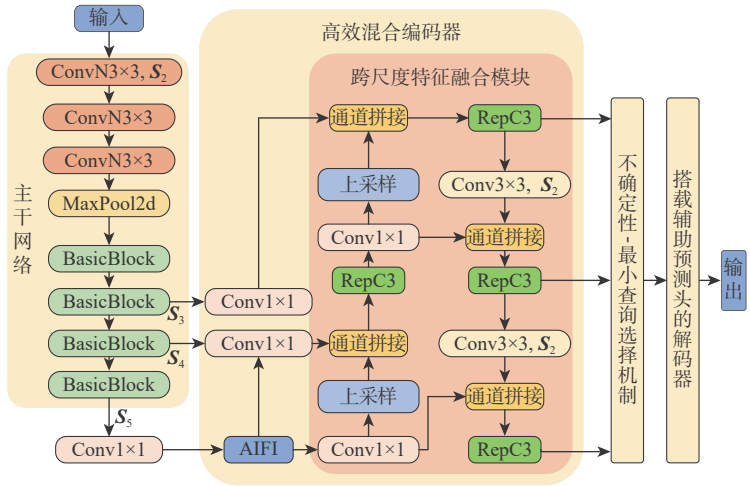


图 1 RT-DETR 模型结构

Fig. 1 RT-DETR model structure

$\boldsymbol{Q}$(查询)包含了当前需要关注或查询的信息，K(键)提供了用于与 $\boldsymbol{Q}$ 进行比较的基准信息，V(值)包含了实际的信息内容；Flatten 表示将 S_5 特征展平并重新排列，以适应 Transformer 的输入格式；Reshape 表示将处理后的特征图恢复为原始的空间维度和通道数；Aifi 表示内尺度特征交互操作；Ccfm 表示跨尺度特征融合操作。

不确定性-最小查询选择机制特别定义了编码器输出特征在分类与定位预测上的联合不确定性，并将该不确定性集成到损失函数中用以指导模型的优化过程，从而为解码器提供具有更高分类得分和更高交并比(intersection over union, IoU)[11]得分的初始查询，搭载辅助预测头的解码器会对初始查询进一步迭代优化，最终输出精确的预测框及与之对应的高置信度评分。联合不确定性 U 和损失函数 L 分别表示为

$$U(\hat{\boldsymbol{x}}) = \|\boldsymbol{P}(\hat{\boldsymbol{x}}) - \boldsymbol{C}(\hat{\boldsymbol{x}})\| \qquad \hat{\boldsymbol{x}} \in \mathbf{R}^D \tag{4}$$

$$L(\hat{x},\hat{y},y) = L_{\text{box}}(\hat{b},b) + L_{\text{cls}}(U(\hat{x}),\hat{c},c) \tag{5}$$

式中：$\hat{\boldsymbol{x}}$ 为编码器特征；$\boldsymbol{P}$ 为位置预测；$\boldsymbol{C}$ 为分类预测；$\hat{y} = \{\hat{c},\hat{b}\}$ 和 y 分别为预测值和真值，$\hat{c}$ 和 $\hat{b}$ 分别表示类别框和边界框，b 表示标注框真实值，c 表示类别真实值。

2 检测模型改进设计

针对因天气光照变化、机身涂装干扰及设备限制而导致的舱门检测精度低、模型部署困难等问题，通过引入上下文引导模块，优化主干网络中的 BasicBlock，增强对上下文信息的利用，降低计算资源的消耗；在颈部编码网络，将 HiLo 注意力机制与 AIFI 相结合，形成 AIFI-HiLo 模块，增强特征表达，降低漏检率和误检率；采用 CA-HS-FPN 替换 CCFM，增强模型对多尺度特征的融合能力。最终得到优化后的飞机舱门检测模型，其整体结构如图 2 所示。

2.1 特征提取网络改进

在 RT-DETR-R18 主干网络中，BasicBlock 作为基础构建模块，旨在高效提取并传递输入特征图的信息，以支持后续复杂任务的处理。为了从来自上一层网络的输入特征图中提取出丰富的局部特征，

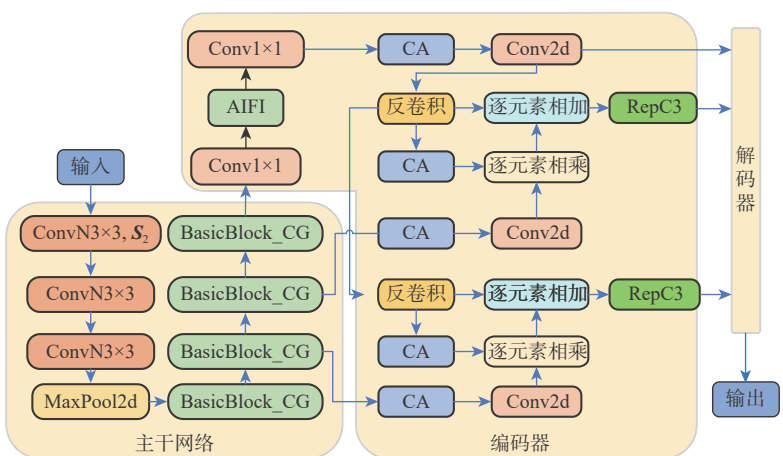


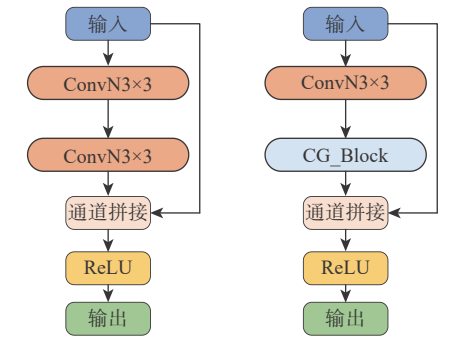
图 2 改进后的飞机舱门检测模型结构

Fig. 2 Improved aircraft door detection model structure

BasicBlock 内部部署了 2 个连续的卷积规范层。每个卷积规范层均集成了卷积层(Conv)、批量归一化(BN)及 ReLU[12] 激活函数, 能够有效地提高模型的性能和训练速度。此外, BasicBlock 采用了残差连接设计, 其将模块的输入直接加至第 2 个卷积规范层的输出上, 形成了一条“捷径”, 使得输入信息能够无损地跨越多个层级, 直接参与到后续特征的构建中, 有效缓解了梯度消失问题, 提高了网络的训练稳定性。

然而, BasicBlock 主要聚焦于局部特征的提取与传递, 而对全局上下文信息的利用相对不足[13]。上下文信息对于理解飞机舱门在图像中的位置关系至关重要, 其能够提供额外的线索来帮助模型更准确地识别和定位舱门。为了提高模型对全局上下文信息的利用率, 如图 3 所示, 引入上下文引导模块 CG_Block 替换 BasicBlock 中的第 2 个卷积规范层, 构成新的 BasicBlock_CG 模块, 可以在提高计算效率的同时, 更好地捕捉长距离依赖关系, 增强模型利用周围信息来推断被遮挡或噪声干扰部分的能力, 以应对图像中如飞机机身涂装鲜艳、恶劣天气影响、光照反射影响、出现遮挡物等复杂场景, 使模型在各种情况下都能够保持稳定的飞机舱门检测性能。

上下文引导模块的基本原理是模拟人类视觉系统依赖上下文信息来辨识物体, 通过捕获局部特征、周围上下文和全局上下文, 并将这些信息融合起来, 以提高特征提取的准确性。模块结构如图 4 所示。其中, 局部特征提取器使用标准 3×3 卷积层, 从 8 个相邻特征向量中学习局部特征, 这些局部特征随后会与周围上下文特征结合, 形成网络对图像各个区域的全面理解。周围上下文特征提取



(a) BasicBlock 基础结构　(b) BasicBlock_CG 基础结构

图 3　改进前后 BasicBlock 对比

Fig. 3　Comparison of BasicBlock before and after improvement

器与局部特征提取器同时进行工作, 通过空洞/膨胀卷积层增加感受野的大小, 从而能够在更大的区域内捕获丰富的上下文信息, 帮助模型更好地理解复杂场景。局部特征提取器与周围上下文特征提取器均采用了通道卷积, 消除了跨通道的计算成本, 能够大大减小模型的参数量及计算量, 以方便其部署至计算资源有限的设备。联合特征提取器通过连接层、BN 及参数化 ReLU(PReLU)操作整合提取出局部特征和周围上下文特征, 使得网络在局部精细度和全局上下文间达到平衡, 从而提高目标检测的准确性; 全局特征提取器使用全局平均池化层(global average pooling, GAP)聚合全局信息, 并通过全连接层(fully connected, FC)进一步细化全局上下文特征, 全局上下文被视为加权向量, 逐通道地重新标定联合特征, 强调有用的特征部分, 抑制不重要的特征部分, 以增强联合特征提取器学习到的特征。CG_Block 内部也采用了全局残差学习, 添加了从输入到全局特征提取器的连接, 有助于学习高度复杂的特征。

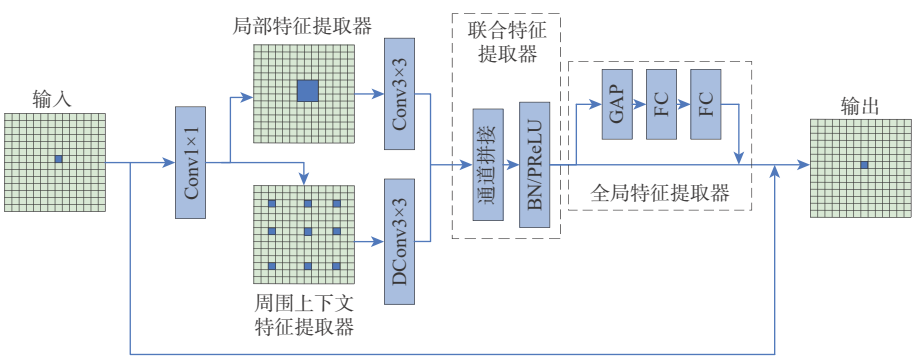


图 4　CG_Block 结构

Fig. 4　CG_Block structure

2.2　AIFI-HiLo 模块设计

AIFI 与传统的 Transformer 编码器设计类似, 都离不开多头自注意力(multi-head self-attention, MSA)机制[14]。MSA 通过并行处理和从不同表示子空间中捕捉信息, 每个头都能独立地进行 Q(查询)、K(键)、V(值)的线性变换和注意力计算, 提高了模型的并行性和表达能力, 从而能够更有效地捕获输入数据中的多种依赖关系。然而, 标准多头自注意

力层往往在所有图像块上强制应用相同的全局注意力，忽略了特征存在不同的基础频率，导致模型在高分辨率图像上需要消耗大量的计算资源。对此，在AIFI中引入HiLo注意力[15]可以有效解决该问题。HiLo注意力的结构如图5所示。图中，N_h为该层中的自我关注头的总数，a为高频或低频磁头的分频比。

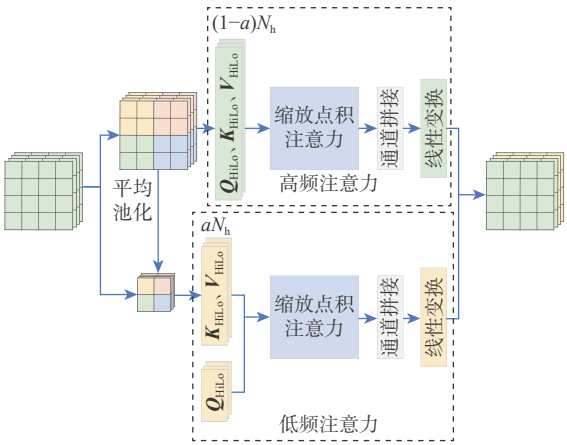


图5 HiLo注意力结构

Fig. 5 HiLo attention structure

HiLo注意力将MSA按照特征高低频划分为2个部分：高频注意力部分(high-frequency attention, Hi-Fi)通过局部自注意力和高分辨率特征图对高频交互进行编码，减少了长距离依赖的处理需求，对于实现快速且高效的视觉变换器至关重要；低频注意力部分(low-frequency attention, Lo-Fi)通过全局注意力和下采样特征对低频交互进行编码，减少了全局自注意力的计算负担，从而大大提高编码效率。具体来说，HiLo注意力将MSA中相同数量的磁头分为2组，分频比为a，其中，$(1-a)N_h$个磁头用于高频注意力，其他N_h个用于低频注意力，这种分配策略确保了不同类型的特征得到适当的关注和处理。高频注意力部分专注于图像中的高频细节，如边缘、纹理等，通过局部窗口自注意力(在2×2的窗口中进行)捕获细粒度高频，并采用简单的非重叠窗口分区，减少了需要计算的自注意力的范围和冗余计算，大大节省了计算复杂性。低频注意力部分接收每个窗口经平均池化后获得的低频，将平均池化后的特征图投影成K(键)和V(值)，并保留来自原始特征图的Q(查询)，随即通过全局注意力来捕获特征图中丰富的低频信息，如形状、颜色分布等，其主要作用于下采样后的特征图上，可以减少处理的特征数量，进一步提高效率。最终，将改进的高频、低频特征整合起来，作为AIFI-HiLo模块的输出。由于每个注意力的复杂性都低于标准MSA，因此，AIFI-HiLo的整个框架保证了低复杂性，并确保了GPU上的高吞吐量，同时增强了模型捕获目标特征的能力。AIFI-HiLo计算过程为

$$\boldsymbol{Q}_{\mathrm{HiLo}}=\boldsymbol{K}_{\mathrm{HiLo}}=\boldsymbol{V}_{\mathrm{HiLo}}=\mathrm{Flatten}(\boldsymbol{S}_5) \tag{6}$$

$$\mathrm{AIFI\text{-}HiLo}(\boldsymbol{x})=[\mathrm{HiFi}(\boldsymbol{x}),\mathrm{LoFi}(\boldsymbol{x})] \tag{7}$$

$$\boldsymbol{F}_5=\mathrm{Reshape}(\mathrm{AIFI\text{-}HiLo}(\boldsymbol{Q}_{\mathrm{HiLo}},\boldsymbol{K}_{\mathrm{HiLo}},\boldsymbol{V}_{\mathrm{HiLo}})) \tag{8}$$

2.3 CA-HS-FPN

2.3.1 HS-FPN

HS-FPN[16]的结构如图6所示，包括特征选择和特征融合2个主要组成部分。

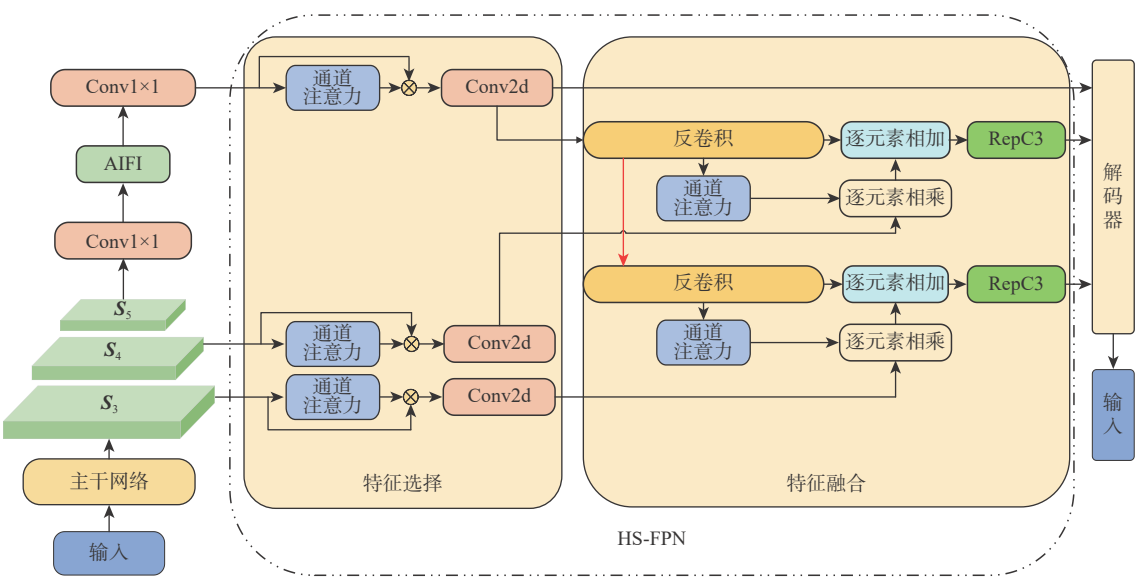


图6 HS-FPN结构

Fig. 6 HS-FPN architecture

在特征选择过程中，通道注意力[17]模块首先采用全局平均池化和全局最大池化对输入特征图进行处理，分别计算每个通道的平均值和最大值。然后，使用Sigmoid激活函数来确定每个通道的权重

值, 从而得到每个通道的权重。最后, 通过将权重信息与相应比例的特征图相乘来生成过滤后的特征图, 实现对不同尺度特征的筛选。最大池化的主要目的是从每个通道中提取最相关的数据, 而平均池化旨在统一地从特征图中获取所有数据, 从而最大限度地减少过度损失, 结合这些池化方法有助于从每个通道中提取最具代表性的信息, 同时最大限度地减少信息损失。

在特征融合模块中, 为了充分利用高级特征包含的丰富语义信息和低尺度特征提供的精确目标位置, HS-FPN 使用了选择性特征融合(selective feature fusion, SFF)模块。该机制不同于传统的融合方法, 不是将上采样的高级特征和低尺度特征像素值进行简单求和, 而是通过使用高级特征作为权重来过滤低尺度特征中包含的必要语义信息, 再将过滤后的低尺度特征与高级特征协同集成, 大大减少了融合过程中的信息冗余, 增强了模型的特征表达能力。SFF 结构如图 7 所示。图中: $\boldsymbol{P}_i$ 为低层原始输入特征图, $\boldsymbol{N}_i$ 为 SFF 融合输出后的新特征图。

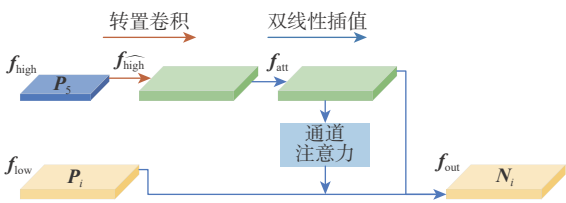


图 7　SFF 结构

Fig. 7　SFF structure

当给定一个输入高级特征 $\boldsymbol{f}_{\text{high}} \in \mathbf{R}^{C\times H\times W}$ 和一个输入低尺度特征 $\boldsymbol{f}_{\text{low}} \in \mathbf{R}^{C\times H\times W_1}$ 时, 高级特征首先使用一个步幅大小为 2、卷积核大小为 3×3 的转置卷积(T-Conv)进行扩展, 得到特征大小 $\boldsymbol{f}_{\widehat{\text{high}}} \in \mathbf{R}^{C\times 2H\times 2W}$。其次, 为统一高级特征和低尺度特征的维度, 使用双线性插值来向上或向下采样高级特征, 得到特征 $\boldsymbol{f}_{\text{att}} \in \mathbf{R}^{C\times H_1\times W_1}$。然后, 使用通道注意力模块将高级特征转换为相应的注意力权重, 在获得具有一致维度的特征时过滤低级特征。最后, 将过滤后的低尺度特征与高级特征融合, 以增强模型的特征表示, 并得到 $\boldsymbol{f}_{\text{out}} \in \mathbf{R}^{C\times H_1\times W_1}$。其中, C 为通道数, H 为高级特征图的高度, W 为高级特征图的宽度, W_1 为低尺度特征图的宽度, H_1 为将高级特征进行双线性插值处理后的特征图高度。在图像采样过程中, 通过采用转置卷积和双线性插值相结合的方法, 有效增强了模型的检测能力。SFF 选择特征融合过程为

$$\boldsymbol{f}_{\text{att}} = \text{BL}\left(\text{T-Conv}\left(\boldsymbol{f}_{\text{high}}\right)\right) \tag{9}$$

$$\boldsymbol{f}_{\text{out}} = \boldsymbol{f}_{\text{low}}\text{CA}\left(\boldsymbol{f}_{\text{att}}\right) + \boldsymbol{f}_{\text{att}} \tag{10}$$

式中: BL 表示双线性插值; CH 表示通道注意力。

2.3.2　坐标注意力机制

获取飞机舱门的位置和形状是完成飞机舱门检测任务的关键因素, 考虑到目标图像在实际情况中可能会出现不同尺度、受天气光照影响发生形变及遮挡等多种问题, 改进模型利用坐标注意力[18]替换 HS-FPN 中原始的通道注意力模块, 通过在特征图上引入空间坐标信息, 实现了对舱门位置的细粒度权重调整, 能够更好地捕捉舱门的精确位置和轮廓, 同时自适应地处理不同视角和光照条件下的变化, 有效整合舱门与周围环境信息, 增强 HS-FPN 的特征选择和 SFF 模块过滤低尺度特征的能力, 进而提高检测精度。此外, 相比于通道注意力及其他复杂的注意力机制, 坐标注意力整体采用轻量级设计, 易于集成至现有网络, 不会显著增加模型的复杂性和计算负担, 更为适用飞机舱门检测的现场部署应用场景。

坐标注意力模块结构如图 8 所示, 主要通过 2 个步骤来捕获通道间的依赖关系和位置信息。首先, 沿着一个空间维度(如宽度或高度)收集特征。然后, 沿着另一个维度聚合这些特征。具体而言, 坐标注意力模块使用尺寸为 $(H,1)$ 和 $(1,W)$ 池化核分别沿着输入的水平方向和垂直方向对每个通道进行编码, 高度为 h 时的第 c 个通道输出 $Z_c^h(h)$ 可表示为

$$\boldsymbol{Z}_c^h(h) = \frac{1}{W}\sum_{0\leqslant i\leqslant W}\boldsymbol{X}_c(h,i) \tag{11}$$

同理, 宽度为 w 时的第 c 个通道的输出 $Z_c^w(w)$ 可表示为

$$\boldsymbol{Z}_c^w(w) = \frac{1}{H}\sum_{0\leqslant j\leqslant H}\boldsymbol{X}_c(j,w) \tag{12}$$

式中: $\boldsymbol{X}_c(h,i)$ 为输入特征图沿水平方向的输入; $\boldsymbol{X}_c(j,w)$ 为输入特征图沿垂直方向的输入。

具有特定方向的特征图编码为 2 个保存位置信息的特征图, 位置信息指特征图沿水平和垂直方向上提取的信息, 之后使用 1×1 卷积对其进行变换操作:

$$\boldsymbol{f} = \delta\left(F_1\left[\boldsymbol{z}^h, \boldsymbol{z}^w\right]\right) \tag{13}$$

$$\boldsymbol{g}^h = \sigma\left(\boldsymbol{F}_h\left(\boldsymbol{f}^h\right)\right) \tag{14}$$

$$\boldsymbol{g}^w = \sigma\left(\boldsymbol{F}_w\left(\boldsymbol{f}^w\right)\right) \tag{15}$$

式中: F_1 表示卷积; δ 表示 Sigmoid 激活函数。水平和垂直方向上的空间信息包含进中间特征图 $\boldsymbol{f}$ 中, $\boldsymbol{f}^h \in \mathbf{R}^{C/r\times H}$ 和 $\boldsymbol{f}^w \in \mathbf{R}^{C/r\times W}$ 是将 $\boldsymbol{f}$ 沿水平和垂直方向拆分而来的 2 个特征图, 注意力权重 $\boldsymbol{g}^h$ 和 $\boldsymbol{g}^w$ 是经过 $\boldsymbol{f}^h$ 和 $\boldsymbol{f}^w$ 卷积将 $\boldsymbol{f}^h$ 和 $\boldsymbol{f}^w$ 这 2 个特征图的通道数转化

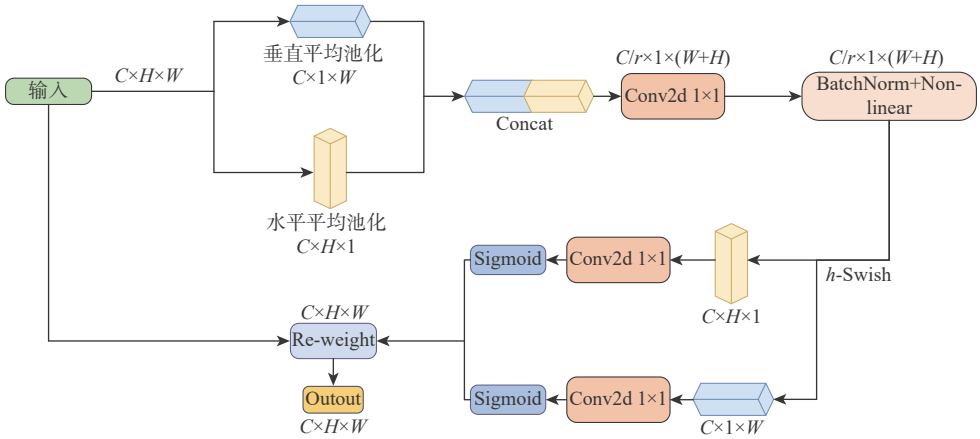


图 8 坐标注意力模块结构

Fig. 8 Structural of coord attention module

而来的，$\boldsymbol{g}^h$ 和 $\boldsymbol{g}^w$ 的通道数和输入特征图相同。

最后，利用乘法将权重 $\boldsymbol{g}^h$ 和 $\boldsymbol{g}^w$ 应用于输入特征图，得到注意力模块输出：

$$\boldsymbol{y}_c(i,j)=\boldsymbol{x}_c(i,j)\cdot\boldsymbol{g}_c^h(i)\cdot\boldsymbol{g}_c^w(i) \tag{16}$$

式中：$\boldsymbol{y}_c(i,j)$为第 c 个通道的输出；$\boldsymbol{x}_c(i,j)$为第 c 个通道的输入；$\boldsymbol{g}_c^h(i)$为第 c 个通道沿水平方向的权重；$\boldsymbol{g}_c^w(i)$为第 c 个通道沿垂直方向的权重。

3 实验结果与分析

3.1 实验环境

实验环境配置如下：基于 PyTorch 2.3.0 深度学习框架，系统环境为 Linux 操作系统（Ubuntu 22.04.4LTS），CPU 型号为 Intel® Xeon(R) Platinum 8256 CPU @ 3.80 GHz × 16，图像处理器（Graphics processing unit，GPU）型号为 NVIDIA Corporation GA100，40 GB 显存，CUDA 版本为 12.1。模型超参数设置如下：训练迭代周期数 epoch=150，各批次处理的样本数量 batch size=8，输入图像尺寸统一为 640 像素×640 像素，用于数据加载的线程数量为 4，使用 AdamW 作为优化器，网络初始学习率为 0.000 1，权重衰减系数为 0.000 1，其他超参数均保持默认值。

3.2 数据集搭建

由于目前没有针对飞机舱门的公共数据集，本文使用的数据集为自建数据集，图片来源主要是互联网、国内某机场及专用 3D 模拟软件，共 2 167 张图像，同一张图像上可能包含多种舱门，考虑到图像数量和雨雪等恶劣条件下的样本较少，经过旋转、水平翻转、亮度调节、对比度调节、增加噪声等数据增强技术，将图像扩增到 10 835 张，保证数据集的多样性，提高模型的鲁棒性。该数据集主要包含客舱门与货舱门 2 种典型飞机舱门目标，其中，客舱门目标为 14 145 个，货舱门目标为 7 360 个。数据集图像标注软件采用 LabelImg 工具，标注为 VOC 格式的标签文件，训练集、测试集和验证集的划分比例为 7∶2∶1。部分数据集图像如图 9 所示。

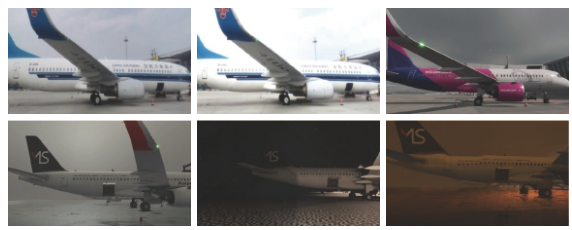


图 9 不同情况下的数据图像

Fig. 9 Images of data in different situations

3.3 评价指标

本文实验采用目标检测任务中常用的精度评估指标 mAP50 和 mAP50-90。mAP 是多个类别平均准确率（average precision，AP）的平均值，mAP 的数值越大，说明此检测模型的性能越优，是非常重要的评价指标。模型复杂度上选用参数量、浮点运算量及模型体积 3 种指标。其中，模型体积表示训练结束后生成权重文件的大小。比较不同模型之间的计算复杂度大小，参数量、浮点运算量、模型体积越大，模型越复杂，同时能够“吞吐”的数据量也越多，能完成复杂任务，但对硬件计算资源有更大要求；较小的参数量、浮点运算量和模型体积则表示任务或模型的计算需求较低，可能更加高效或轻量。特种车辆上外接设备大多为工控机、单片机等，硬件计算水平不高，因此，低参数量、低浮点运算量、模型体积小的检测模型更适合在特种车辆设备中使用。

3.4 消融实验

模型结构框架的改进基于 RT-DETR 模型，为验证各改进的有效性，在自建飞机舱门数据集上对检测精度与模型复杂度进行消融实验，实验结果如表 1 所示。由实验结果可知，加入 CG_Block 设计之后，模型的浮点运算量从 5.69×10^{10} 次降低到

4.29×10^{10} 次, 体积从 38.5 MB 减少到 27.5 MB, mAP50 从 93.1% 提升到 94.5%, 表明 CG_Block 能够在减少计算复杂度和模型大小的同时提高检测性能。单独添加 AIFI-HiLo 时, 模型的浮点运算量和体积几乎不变, 但 mAP50 从 93.1% 提升到 94.7%, 表示 AIFI-HiLo 能够在不改变模型复杂度的基础上显著提升检测精度。单独使用 CA-HS-FPN 网络结构替换 CCFM 模块时, 模型大小虽然只减小到了 33.4 MB, 但检测精度提升明显, 表示其同样能够在参数量和浮点运算量有所减少的情况下提升检测精度。当同时添加 2 个改进时(No.5、No.6、No.7), 可以看到, 模型仍能保留 CG_Block 和 CA-HS-FPN 降低计算复杂度的优点, 同时将检测精度保持或提升至较高水平。将 3 种改进方法结合起来, 模型的整体表现达到最优, 相较于原始的 RT-DETR 模型在参数量、浮点运算量、模型体积上分别减少了 41.3%、40%、41.6%, 在检测精度上提升了 1.8%, 表明改进后的飞机舱门检测模型在保持高检测率的同时, 实现了模型的轻量化, 使模型更契合机场特种车辆搭载舱门检测设备要求。

表 1　消融实验结果

Table 1　Ablation experiments results

No.	CG_Block	AIFI-HiLo	CA-HS-FPN	参数量	浮点运算量/10^{10}次	模型体积/MB	mAP50/%
1				19 874 328	5.69	38.5	93.1
2	√			14 066 768	4.29	27.5	94.5
3		√		19 748 888	5.70	38.5	94.7
4			√	17 406 152	4.79	33.4	94.7
5	√	√		13 941 328	4.29	27.3	94.9
6	√		√	12 275 712	3.92	23.9	94.3
7		√	√	17 280 712	4.80	33.2	94.4
8	√	√	√	11 676 160	3.41	22.5	94.9

3.5　对比实验

为验证本文改进模型在飞机舱门检测中具有优异的性能, 使用自建飞机舱门数据集, 挑选当今主流目标检测模型进行对比实验, 涵盖 YOLO 系列中模型较小的 YOLOv5m[19]、YOLOv6s[20]、YOLOv7-tiny[21]、YOLOv8s、YOLOv8m 版本。评价指标选取参数量、浮点运算量、模型体积、mAP50 及 mAP50-90 进行模型性能评估, 对比结果如表 2 所示。根据对比结果可以看出, 本文改进模型在多个关键指标上均展现出卓越的性能。与当前流行的 YOLO 系列模型相比, 改进模型的参数量、浮点运算量、模型体积分别为 11 676 160、3.41×10^{10} 次、22.5 MB, 较 YOLOv5m、YOLOv8m 大大减少, 与 YOLOv6s、YOLOv8s[22] 相近, 但高于 YOLOv7-tiny, 处于适中水平, 不会过于庞大以致于计算资源消耗过高, 也不会过于精简而牺牲太多性能, 实现了良好的平衡, 既降低了对硬件资源的需求, 又确保了高效的推理速度, 非常适合资源受限或需要快速响应的应用场景。与较为新颖的模型 RT-DETR-ELA-HS-FPN 和 RT-DETR-CAA-HS-FPN 相比, 本文改进模型不仅模型体积更小, 而且检测精度较高, 说明了利用坐标注意力机制进行优化的思路尽管较为常见, 但用在飞机舱门检测场景中更具备适用性和有效性, 有利于工程应用的落实。在平均精度方面, 本文改进模型不仅在常用的 mAP50 评估标准下达到了 94.9% 的高水平, 与 YOLOv8m 等先进模型相媲美, 甚至在更为严格的 mAP50-90 评估标准下也展现出了出色的性能, 达到了 71.5%, 充分证明了本文改进模型在复杂场景下的鲁棒性和准确性。由此可知, 本文改进模型通过优化网络结构和参数配置, 成功地在保持高效计算和较小体积的同时, 实现了高精度的飞机舱门检测性能, 为深度学习在飞机舱门检测领域的应用提供了新的思路和解决方案。

3.6　检测结果

本文通过分析 RT-DETR 基准模型与改进模型的测试效果图来评估其性能, 相关测试效果如图 10 和图 11 所示。从结果中可以看出, 改进后的检测模型通过捕获舱门的形状、轮廓及舱门与机身相对位置等特征, 在不同环境条件下均表现出较为稳定的检测效果, 能够准确检测出飞机处于 20 m 远时, 在雨雪雾天气、强弱光照等情况下飞机舱门的位置及类型, 置信度较高, 预测框能完整包裹住舱门和检测出未完全打开的舱门, 具体如图 10 所示。

相比之下, 基准网络在光线暗淡时易出现未检测到舱门轮廓特征的情况(无论舱门是否关闭), 即使检测到了舱门, 也存在置信度较低的问题, 如图 11(a)和图 11(b)所示; 在舱门边界受飞机涂装影响过大时往往会检测不到关闭状态的舱门轮廓, 如图 11(c)所示; 当图片中背景线条过于复杂时, 线条构成的轮廓特征易导致模型错检其为舱门轮廓特

表 2 对比实验结果

Table 2 Comparative experiments results

模型	参数量	浮点运算量/10^{10}次	模型体积/MB	mAP50/%	mAP50-90/%
YOLOv5m	25 046 374	6.40	48.2	94.6	70.4
YOLOv6s	16 297 814	4.40	31.3	93.7	67.4
YOLOv7-tiny	6 017 694	1.32	12.3	91.4	60.9
YOLOv8s	11 126 358	2.84	21.5	94.7	68.9
YOLOv8m	25 840 918	7.87	49.6	94.8	71.2
RT-DETR-ELA-HS-FPN	18 465 296	5.48	36.8	94.5	70.3
RT-DETR-CAA-HS-FPN	18 258 072	5.34	36.1	94.2	66.8
本文改进模型	11 676 160	3.41	22.5	94.9	71.5

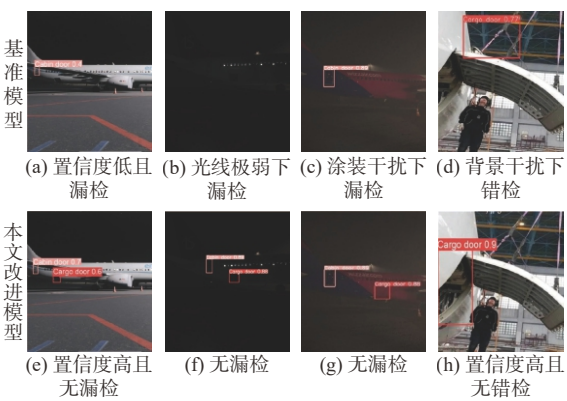


(a) 雨天 (b) 雪天 (c) 雾天

(d) 夜晚 (e) 日间 (f) 正午

图 10 不同环境条件下改进后模型的检测效果

Fig. 10 Detection effect of the improved model under different environmental conditions



基准模型

(a) 置信度低且漏检 (b) 光线极弱下漏检 (c) 涂装干扰下漏检 (d) 背景干扰下错检

本文改进模型

(e) 置信度高且无漏检 (f) 无漏检 (g) 无漏检 (h) 置信度高且无错检

图 11 改进后的 RT-DETR 模型检测效果

Fig. 11 Detection effect of improved RT-DETR model

征，如图 11(d)所示。这些极端环境下的检测效果，对于准确度要求极高的飞机舱门检测任务来说至关重要，改进后的模型在同样的环境下展现出了更具优势的检测性能，如图 11(e)～图 11(h)所示，不仅避免了错检漏检，而且保证了较高的置信度，更适合完成复杂条件下的飞机舱门检测。

4 结 论

1）本文模型可实现较为优异的检测性能，应对包含舱门过小、机身涂装影响过大、雨雪恶劣天气等复杂条件的数据集，在 mAP50 评估标准下达到 94.9% 的高水平，在更为严格的 mAP50-90 标准下也能够达到 71.5%，为深度学习在飞机舱门视觉检测领域的应用提供了研究思路与可行性验证。

2）本文模型在稳定提升检测准确率同时，相较于原始模型将参数量、浮点运算量、模型体积分别降低至 11 676 160、3.41×10^{10} 次和 22.5 MB，实现了模型的参数量、浮点运算量和模型体积大幅度降低，减轻了模型对硬件计算资源的要求，更符合模型在机场特种车辆应用场景中的实际部署需求。

为使本文改进模型后续能够更好地在现实场景中应用，仍需在数据集中不断扩充实际采集的各种复杂情况下的高分辨率舱门图像，并将模型部署进特种车辆系统中进一步实测验证。

参考文献（References）

[1] 邓览. 基于计算机视觉的登机桥全自动接机系统设计[J]. 科技创新导报, 2012, 9(13): 43-46.
Deng L. Design of automatic pick-up system for boarding bridge based on computer vision[J]. Science and Technology Innovation Herald, 2012, 9(13): 43-46(in Chinese).

[2] 陈鸿顺, 卓志辉, 陈汉樑. 自动乘客登机桥对接系统: CN201680060383.9[P]. 2018-06-08.
Chen H S, Zhuo Z H, Chen H L. Automated passenger boarding bridge docking system: CN201680060383.9[P]. 2018-06-08(in Chinese).

[3] Casado Merino J M, Belmecho A M, Freez Castro A, 等. 用于将乘客登机桥自动对接至飞机的方法: CN201980036068.6[P]. 2024-05-14.
Casado Merino J M, Belmecho A M, Freez Castro A, et al. Method for automatic docking of passenger boarding bridge to aircraft: CN201980036068.6[P]. 2024-05-14(in Chinese).

[4] Andonovski B, Wang J L. Computer vision system for cabin door detection and location[C]//Proceedings of the 2018 15th International Conference on Control, Automation, Robotics and Vision. Piscataway: IEEE Press, 2018: 1537-1542.

[5] 叶润, 张成, 李旭, 等. 基于计算机视觉的客机舱门识别与定位技

术研究[J]. 计算机测量与控制, 2021, 29(3): 224-229.
Ye R, Zhang C, Li X, et al. Research on recognition and positioning technology of passenger aircraft door based on computer vision[J]. Computer Measurement & Control, 2021, 29(3): 224-229 (in Chinese).

[6] 谢玉森. 面向登机廊桥自动导引的多源异构传感器数据融合和实时跟踪导航[D]. 北京: 北京信息科技大学, 2023.
Xie Y S. Multi-source heterogeneous sensor data fusion and real-time tracking navigation for automatic guidance of boarding corridor bridge[D]. Beijing: Beijing Information Science & Technology University, 2023(in Chinese).

[7] Wu T Y, Tang S, Zhang R, et al. CGNet: a light-weight context guided network for semantic segmentation[J]. IEEE Transactions on Image Processing, 2021, 30: 1169-1179.

[8] 胡佳乐, 周敏, 申飞. 面向无人机小目标的 RTDETR 改进检测算法[J]. 计算机工程与应用, 2024, 60(20): 198-206.
Hu J L, Zhou M, Shen F. Improved detection algorithm of RTDETR for UAV small target[J]. Computer Engineering and Applications, 2024, 60(20): 198-206(in Chinese).

[9] Zong Z F, Song G L, Liu Y. DETRs with collaborative hybrid assignments training[C]//Proceedings of the 2023 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2023: 6725-6735.

[10] Li Y, Ibanez-Guzman J. Lidar for autonomous driving: the principles, challenges, and trends for automotive lidar and perception systems[J]. IEEE Signal Processing Magazine, 2020, 37(4): 50-61.

[11] Rezatofighi H, Tsoi N, Gwak J, et al. Generalized intersection over union: a metric and a loss for bounding box regression[C]//Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2019: 658-666.

[12] Agarap A F M. Deep learning using rectified linear units (ReLU) [EB/OL]. (2026-04-14)[2026-09-01]. https://arxiv.org/abs/1803.08375.

[13] Wang S, Jiang H P, Yang J X, et al. Lightweight tomato ripeness detection algorithm based on the improved RT-DETR[J]. Frontiers in Plant Science, 2024, 15: 1415297.

[14] Messaoud W, Trabelsi R, Cabani A, et al. Multi-head self attention for enhanced object detection in the maritime domain[C]//Proceedings of the 2023 International Conference on Cyberworlds. Piscataway: IEEE Press, 2023: 179-184.

[15] Pan Z Z, Cai J F, Zhuang B H. Fast vision transformers with HiLo attention[C]//Proceedings of the Advances in Neural Information Processing Systems 35. San Diego: Neural Information Processing Systems Foundation, Inc., 2022: 14541-14554.

[16] Chen Y F, Zhang C Y, Chen B, et al. Accurate leukocyte detection based on deformable-DETR and multi-level feature fusion for aiding diagnosis of blood diseases[J]. Computers in Biology and Medicine, 2024, 170: 107917.

[17] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 7132-7141.

[18] Hou Q B, Zhou D Q, Feng J S. Coordinate attention for efficient mobile network design[C]//Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2021: 13708-13717.

[19] Chen J, Bao E, Pan J Y. Classification and positioning of circuit board components based on improved YOLOv5[J]. Procedia Computer Science, 2022, 208: 613-626.

[20] Li C Y, Li L L, Jiang H L, et al. YOLOv6: a single-stage object detection framework for industrial applications[EB/OL]. (2022-09-07)[2026-09-01]. https://arxiv.org/abs/2209.02976.

[21] Wang C Y, Bochkovskiy A, Liao H M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2023: 7464-7475.

[22] Varghese R M S. YOLOv8: a novel object detection algorithm with enhanced performance and robustness[C]//Proceedings of the 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems. Piscataway: IEEE Press, 2024: 1-6.

Improved RT-DETR model for aircraft door detection

ZHANG Changyong[1,*], ZHANG Xuancheng[1], QIAO Yahai[1], LI Zheng[2]

(1. College of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China;
2. College of Computer Science and Technology, Civil Aviation University of China, Tianjin 300300, China)

Abstract: Aircraft door detection is crucial for enabling the automatic docking of airport special vehicles. To address the issues of low detection accuracy and difficult model deployment caused by changes in weather and lighting conditions, interference from body coating, and equipment limitations, an improved real-time detection Transformer RT-DETR based aircraft door detection model is proposed, using a lightweight residual neural network ResNet18 as the backbone feature extraction benchmark network. By introducing the context guided block, the BasicBlock in the backbone network is optimized to enhance the utilization of contextual information and reduce the consumption of computing resources. The AIFI-HiLo module is built in the neck encoder network by incorporating the high-low frequency (HiLo) attention into an intra-scale feature interaction (AIFI) module. This innovation strengthens feature representation, effectively reducing missed and false detections. Replace cross-scale feature fusion module (CCFM) with a two-stage improved high-level screening feature pyramid network (HS-FPN) to enhance the model's ability to fuse multiscale features. The experimental results showed that the average accuracy of the improved model reached 94.9%, which was 1.8% higher than the benchmark model. The parameter count, floating point operation count, and memory usage were reduced by 41.2%, 40% and 41.5%, respectively. The improved model has the characteristics of small size and high accuracy, making it more suitable for airport special vehicles to carry equipment.

Keywords: aircraft door detection; airport special vehicles; real-time detection Transformer; context guidance block; high-low frequency attention; high-level screening feature pyramid network

Received: 2024-09-26; **Accepted**: 2024-10-25; **Published Online**: 2024-11-20 18:09
URL: link.cnki.net/urlid/11.2625.V.20241120.1428.001
Foundation item: The First Civil Aviation Key Project (3122023PY04)
* **Corresponding author**. E-mail: cyzhang@cauc.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0585

雷达低信噪比旋翼无人机与飞鸟分类方法

王晓亮*，王聪生，施宇翔，何炜琨
(中国民航大学 天津市智能信号与图像处理重点实验室，天津 300300)

摘 要：针对低空监视雷达如何在低信噪比条件下有效区分旋翼无人机与飞鸟的问题，提出一种有效的目标分类方法。通过对雷达回波信号进行小波包分解 (WPD) 和时频谱分割 (TFS)，分别提取由小波包分解和时频谱图得到的子带统计特征，利用子带统计特征构建特征向量，并用支持向量机 (SVM) 进行分类，通过分析不同统计特征分类性能的差别，优选出小波包分解子带能量比和时频谱图子带均值作为分类特征构建最终支持向量机分类器所用的特征向量。实验结果表明，所提方法在低信噪比条件下分类旋翼无人机与飞鸟的准确率较其他常见方法有显著提升。

关 键 词：旋翼无人机；飞鸟目标；小波包分解；时频分析；子带统计特征
中图分类号：TN958; V19
文献标志码：A **文章编号**：1001-5965(2026)11-3801-13

自民航业发展以来，鸟击事件一直是威胁航班安全的因素之一[1]。同时，以旋翼无人机为代表的消费级无人机产业兴起，其被应用到诸多行业及领域，但也带来了一系列的安全风险。为保障民航机场等重要基础设施的安全，近年来已研制出大量低空监视设备。常见的低空监视技术手段包括雷达探测、无线电监测、光电探测、音频探测等[2]，而目前雷达仍然是实现大范围区域无人机目标搜索与探测的主要技术手段。由于无人机与飞鸟的防范和处置措施有所不同，低空监视雷达对这2类目标的有效分类具有重要应用价值。

无人机和飞鸟均属于典型的“低慢小”目标，对于雷达中无人机与飞鸟的分类，提取微多普勒特征是最常用的方法之一。文献 [3] 对无人机和飞鸟的多普勒频谱进行正则化处理，提取其中的频谱宽度及谱线数目用于区分无人机和鸟类目标，但低信噪比下调制频谱难以检测；文献 [4] 利用微波暗室采集的回波信号，研究了利用不同方位角的目标微多普勒特征分类飞鸟和不同种类无人机的方法；文献 [5] 通过关联无人机和车辆、行人等非无人机目标雷达回波的波形熵、时频熵、微多普勒带宽等多个微多普勒特征，使用支持向量机 (support vector machine, SVM) 对特征向量训练和测试进行分类实验；相关研究人员还在K波段和W波段相干雷达系统下得到无人机和鹰类的微多普勒特征[6]，但由于鸟类翅膀的复杂运动，导致呈现的微多普勒特征不明显；文献 [7] 采用二维主成分分析 (two-dimension principal component analysis, 2D-PCA) 降低数据维数，提取无人机微多普勒特征，降低了计算的复杂度，对无人机的识别率有一定的提升；文献 [8] 对无人机雷达回波去除杂波后，采用奇异值分解 (singular value decomposition, SVD) 提取时频特征，利用支持向量机来分类检测无人机；文献 [9] 采用基于协方差的S变换，可以获得比短时傅里叶变换 (short time Fourier transform, STFT) 更好的时频分辨率，提高了通过时频谱识别目标的性能；文献 [10] 将微多普勒信号分解为一系列本征信号，通过 k 阶贝塞尔函数分解获得旋翼数量、叶片长度及转速，用以区

收稿日期：2024-08-02；**录用日期**：2024-10-07；**网络出版时间**：2024-10-30 10:24
网络出版地址：link.cnki.net/urlid/11.2625.V.20241029.1658.004
基金项目：中央高校基本科研业务费专项资金 (3122022085)
* **通信作者**. E-mail：wxl_ee@126.com

引用格式：*王晓亮，王聪生，施宇翔，等. 雷达低信噪比旋翼无人机与飞鸟分类方法 [J]. 北京航空航天大学学报，2026，52（11）：3801-3813.*
Wang X L，Wang C S，Shi Y X，et al. Classification method of rotor drones and flying birds under low signal-to-noise ratio for radar [J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：3801-3813 （in Chinese）.

分旋翼无人机与其他飞机或鸟类；Farshchian等[11]通过逆短时傅里叶变换和形态成分分析将飞鸟的微多普勒特征与鸟身的特征进行分离，既提升了雷达对飞鸟的检测性能，也能更好地区分飞鸟与无人机目标；文献[12]设计了一种残差金字塔池化网的神经网络，将鸟类和无人机的时频谱图输入其中进行分类；文献[13]提出多种卷积神经网络分类器，对应多个分类方案，包括单架无人机、单只鸟、多架无人机与多只鸟的微多普勒图像的组合，有助于区分不同数量的无人机和飞鸟；文献[14]提出了一种频谱定位和基于霍夫变换的优化算法，根据采集无人机和飞鸟的非平稳、线性、非线性、旋转、平移等运动多分量微多普勒特征生成准确的时频图像用于区分二者；Torvik等[15]详细研究了不同波段下野鸭的散射机制，分析其翅膀和身体对其后向散射功率的影响，最终得出在K波段飞鸟的微多普勒特征可用于与无人机区分的结论。

除提取微多普勒特征外，也有研究人员利用其他特征识别无人机目标。文献[16]利用无人机与其他目标运动方式的差异，基于建立的多种运动模型，对无人机目标及干扰目标进行跟踪，通过判断目标的运动方式进行模式转换频率的特征提取，根据模式转换频率识别出无人机目标；文献[17]通过分析无人机和飞鸟雷达数据中的速度均值、速度标准差、水平方向标准差、加速度和振荡因子等运动特征，并采用随机森林模型进行目标分类；文献[18]提取无人机群通信信号的高阶累积量和瞬时特征统计量，融合雷达航迹特征构建无人机群特征矩阵，并提出了邻域成分分析二次筛选算法来降低融合特征矩阵的维数，该方法主要用于无人机群的类型识别。

还有学者结合微多普勒特征与其他特征识别无人机目标。文献[19]通过结合极化特征和微多普勒特征解决携带有效载荷无人机的分类问题；文献[20]提出基于高分辨率雷达传感器的小型无人机识别的多特征融合方法，通过提取高分辨距离像中的结构特征和时频谱中的微多普勒特征，在多个不同视角下识别四旋翼无人机和双旋翼直升机。

由上述分析可以看出，微多普勒特征是雷达区分无人机与鸟等目标的重要且有效的特征。实际应用中，由于无人机与飞鸟雷达散射截面都很小，当无人机和飞鸟与雷达有一定距离时，常会面临信噪比较低的情况，上述方法对低信噪比条件下目标的分类问题讨论比较有限，因此，有必要进一步研究低信噪比条件下有效区分无人机与飞鸟目标的方法。

针对低空监视雷达低信噪比条件下旋翼无人机和飞鸟的分类问题，本文提出一种融合雷达回波信号小波包分解（wavelet packet decomposition, WPD）特征和时频谱图特征的目标分类方法。旋翼无人机和飞鸟在运动时各自微动部分运动的差异，致使它们产生的微多普勒特征不同，这也正是可以通过分析其不同频率子带统计特征以区分无人机和飞鸟的原因。首先，对目标雷达回波信号进行静态杂波和主体分量的去除，进行小波包分解，利用分解后的各分量得到子带统计特征；然后，利用短时傅里叶变换得到雷达回波信号时频谱图，通过时频谱分割 (time-frequency segmentation, TFS) 后各子带数据得到子带统计特征。在低信噪比条件下，2类目标的这些特征依然能体现出差异性。使用支持向量机（support vector machine, SVM）作为分类器，通过分析不同统计特征分类性能的差别，优选出小波包分解子带能量比和时频谱图子带均值作为分类特征构建特征向量。通过本文方法与其他常见方法在不同信噪比条件下的分类准确率的比较可以看出，在信噪比较低的条件下，本文方法分类准确率与其他常见方法相比有显著提升。

1 基于小波包分解与时频谱分割的目标分类方法

1.1 雷达回波信号预处理

由于低空监视雷达探测的无人机与飞鸟目标飞行高度通常较低，因此，雷达回波信号中往往会包含较强的地杂波。首先，要对雷达回波信号中的地杂波进行有效抑制。本文区分无人机和飞鸟目标主要通过二者微多普勒特征的差别，而无人机机身和飞鸟鸟身的平动通常也会产生较强的多普勒谱，对微多普勒特征的提取产生干扰，因此，也要对无人机机身和飞鸟鸟身平动的多普勒谱进行抑制。

对于低空目标经过脉冲压缩后的雷达回波信号$s(t)$，需将地杂波分量去除得到$s'(t)$，考虑到实际情况，将回波信号中多普勒频率f小于某一范围的频谱置0，达到抑制地杂波的目的：

$$F(f)=0 \qquad |f|<f_0 \tag{1}$$

式中：$F(f)$为雷达回波信号$s(t)$傅里叶变换后的频谱密度；f_0为频谱置0频率阈值。

通常，旋翼无人机机身对应的回波信号的能量显著大于旋转叶片对应的能量，飞鸟鸟身对应的回波信号的能量也显著大于飞鸟振翅对应的能量，因此，可以通过对地杂波抑制后的回波信号寻找多普

勒谱谱峰得到无人机机身和飞鸟鸟身对应的多普勒谱, 即

$$\hat{f} = \arg\max_{f}\{|F'(f)|\} \tag{2}$$

式中: $F'(f)$为地杂波抑制后雷达回波信号$s'(t)$傅里叶变换后得到的频谱密度; $\arg\max(\cdot)$表示取频谱密度模值最大值对应的频率f。根据目标主体频率估计值即可将目标主体多普勒频率补偿至零频, 再通过与去除地杂波类似的方式去除机身和鸟身信号分量, 将机身与鸟身频率两侧附近一定频率范围的频谱置 0, 达到抑制机身和鸟身信号的目的。

1.2　基于小波包分解的特征提取

小波包分解是在小波变换的基础上, 对低频近似分量进行分解的同时, 对高频细节分量进行分解, 即对信号不断进行滤波, 每次滤波得到的 2 个分量所占频带宽度相等。每次分解后, 下一步对近似和细节分量再重复上述的分解过程。

旋翼无人机雷达回波信号受旋转叶片调制, 通常其频谱会在机身周围出现频带展宽, 其频带展宽范围与叶片长度、转速及观测角度等有关, 而飞鸟翅膀的拍打也会造成在鸟身周围出现频带展宽。基于此特性, 利用小波包分解将雷达回波信号分解为处于不同频带范围的信号分量, 进而得到基于各子带分量的子带统计特征。

设小波包分解后得到 r 个子带, 其中, 每个子带包含 k 个系数, 可以由此构建$r\times k$的矩阵$\boldsymbol{D}$, 第 i 个子带的小波包系数为$\boldsymbol{D}_i$; 通过除以所有小波包系数的最大值进行归一化处理得到各子带的归一化小波系数构成的矩阵$\boldsymbol{C}$, 第 i 个子带的归一化小波包系数为$\boldsymbol{C}_i$, 再提取如下子带统计特征。

特征 1　能量比:

$$Z_i = E_i/E = E_i \Big/ \sum_{i=1}^{r} E_i \tag{3}$$

式中: $E_i = \|\boldsymbol{C}_i\|^2$表示小波包分解后第 i 个子带的小波能量, $\|\cdot\|$为求二范数。该特征描述了各子带相对能量比, 其构成能量比特征向量$\boldsymbol{Z} = [Z_1, Z_2, \cdots, Z_r]$。因为无人机旋转叶片的最大线速度通常明显大于飞鸟振翅的最大线速度, 所以当小波包分解级数适当时, 旋转叶片微多普勒频率跨越了多个小波包分解子带, 这些子带的能量比会明显大于没有受到旋转叶片调制的频率范围对应的子带, 而飞鸟目标一般仅有一个子带能量比较大。

特征 2　尺度熵:

$$W_i = -\sum_{k} p_i(k)\log_2 p_i(k) \tag{4}$$

式中: $p_i(k)$表示小波包分解后第 i 个子带归一化小波系数的出现概率。其构成尺度熵特征向量$\boldsymbol{W} = [W_1, W_2, \cdots, W_r]$, 表示子带小波分布的均匀程度。噪声在各个子带都有相近的分布, 而无人机和飞鸟信号受其旋转叶片和振翅的影响, 致使二者的尺度熵在各子带的分布有一定的规律性, 低频值较大, 高频值较小。无人机回波信号小波包分解后会有多个子带包含旋翼分量, 因此, 存在多个子带的尺度熵值会高于其他子带, 区别于飞鸟振翅的少数子带尺度熵值高于其他子带。

特征 3　奇异值比:

$$Q_i = \lambda_i/\lambda = \lambda_i \Big/ \sum_{i=1}^{r} \lambda_i \tag{5}$$

对矩阵$\boldsymbol{C}$进行奇异值分解即可得到式(5)的λ_i, 表示第 i 个子带对应的奇异值, 各子带奇异值比构成特征向量$\boldsymbol{Q} = [Q_1, Q_2, \cdots, Q_r]$。由于奇异值分解后得到的奇异值从大到小排列, 无人机旋翼调制频谱占据多个低频子带, 则有多个奇异值较大, 而飞鸟振翅一般仅存在一个较大奇异值。根据各子带的奇异值比不同, 可进行无人机和飞鸟的分类。

1.3　基于时频谱分割的特征提取

采用短时傅里叶变换对雷达回波信号进行时频分析, 记回波信号对应的短时傅里叶变换时频谱为$S(t,f)$。

旋翼无人机与飞鸟的时频谱具有不同的特征, 由于无人机旋翼频谱的对称性, 其时频谱的正频率已能体现与飞鸟振翅的差异, 故可将时频谱正频率部分沿频率轴等分为不同频段的 R 个子带, 设每个子带有$M\times N$个单元, 第 i 个子带的时频谱表示为$S_i(t_m, f_n)$, 提取各个子带的统计特征, 具体如下。

特征 4　子带均值:

$$T_i = \frac{1}{MN}\sum_{m=1}^{M}\sum_{n=1}^{N}|S_i(t_m, f_n)| \tag{6}$$

各子带均值构成特征向量$\boldsymbol{T} = [T_1, T_2, \cdots, T_R]$, 旋翼无人机回波受叶片转动调制而在时频图中出现的闪烁有多个子带均值会受影响, 而飞鸟在一般情况下其翅膀拍打的频率较小, 导致飞鸟的最大微多普勒频率与旋翼无人机存在差异[21], 且占据少数子带的频率范围, 意味着仅少数子带的均值会受影响。

特征 5　子带标准差:

$$\sigma_i = \sqrt{\frac{1}{MN}\sum_{m=1}^{M}\sum_{n=1}^{N}\left[S_i(t_m, f_n) - T_i\right]^2} \tag{7}$$

各子带标准差构成特征向量$\boldsymbol{\sigma} = [\sigma_1, \sigma_2, \cdots, \sigma_R]$, 时频谱分解后, 无人机与飞鸟的微动分量集中在低

频子带，其标准差会相较处于高频子带的噪声的标准差有所差别。因为无人机比飞鸟有更高的最大微多普勒频率，其会比飞鸟有更多子带的子带标准差与高频子带显著不同。

特征6 子带熵：

$$G_i = -\sum_{l} p_i(l)\log_2 p_i(l) \tag{8}$$

式中：$p_i(l)$表示第i个时频子带频谱密度值的出现概率。其构成子带熵特征向量$\boldsymbol{G}=[G_1,G_2,\cdots,G_R]$，此特征与尺度熵类似，包含无人机与飞鸟多普勒谱的子带因为包含更多的信息，会比纯噪声的子带具有更高的子带熵值，无人机含有较高子带熵的子带个数会比飞鸟更多。

1.4 基于支持向量机的目标分类

本文将利用小波包分解得到的各子带统计特征量和利用时频谱分割得到的各子带统计特征量放在一起构建特征向量，即可使用常见的基于特征向量的分类方法对目标进行分类。

本文分类中使用了支持向量机，将从旋翼无人机和飞鸟雷达回波提取的上述特征划分为训练集和测试集，训练样本空间中存在多个能够区分二者的超平面，“支持向量”为满足分类要求且距离超平面最近的若干样本点，本文需要找到可将二者区分的最优分类超平面，当2类支持向量到超平面的距离最大时，此时超平面就是最优分类超平面，具体可参见文献[22]。

2 分类特征分析与优选方法

针对低信噪比下无人机和飞鸟目标的分类，对1.2节和1.3节提到的特征量进行进一步优选。优选的方法是通过比较单独使用某个特征量和联合使用多个特征量分类准确率的差别，优选分类性能更好的特征量。

2.1 无人机与飞鸟雷达回波信号的获取

为进一步分析前述各子带统计特征在无人机与飞鸟目标分类中的有效性，本文使用仿真数据对无人机与飞鸟目标不同信噪比的上述子带统计特征的特点进行了详细分析，并利用仿真数据对不同子带统计特征的选择对最终分类结果的影响进行比较，以优化分类方法的设计。

在这些分析中，使用仿真数据更容易获得无人机与飞鸟目标的独特特征。

分类器的训练中，本文使用了不同观测俯仰角与方位角的旋翼无人机与飞鸟的仿真数据。

本文使用文献[23]的方法生成仿真的旋翼无人机雷达回波信号，通过旋翼无人机单个叶片上各散射点回波信号的积分建立单个旋转叶片雷达回波信号模型，而将无人机机身建模为具有一定速度、一定散射强度的点目标，再将多个旋转叶片和机身的回波信号累加得到无人机的雷达回波信号；使用文献[24]的方法生成仿真的飞鸟雷达回波信号，将飞鸟的扑翼运动看作翅膀各关节带动其前臂和上臂的运动，鸟身依然视为具有一定速度、一定散射强度的点目标，再将鸟身与鸟翼的回波信号叠加得到飞鸟的雷达回波信号。

仿真中生成了各种不同观测俯仰角与方位角的旋翼无人机与飞鸟的仿真雷达回波信号，旋翼无人机包含不同转速，飞鸟包含不同振翅频率。图1给出了某种情况下旋翼无人机和飞鸟雷达回波信号的时域波形及相应的时频谱。

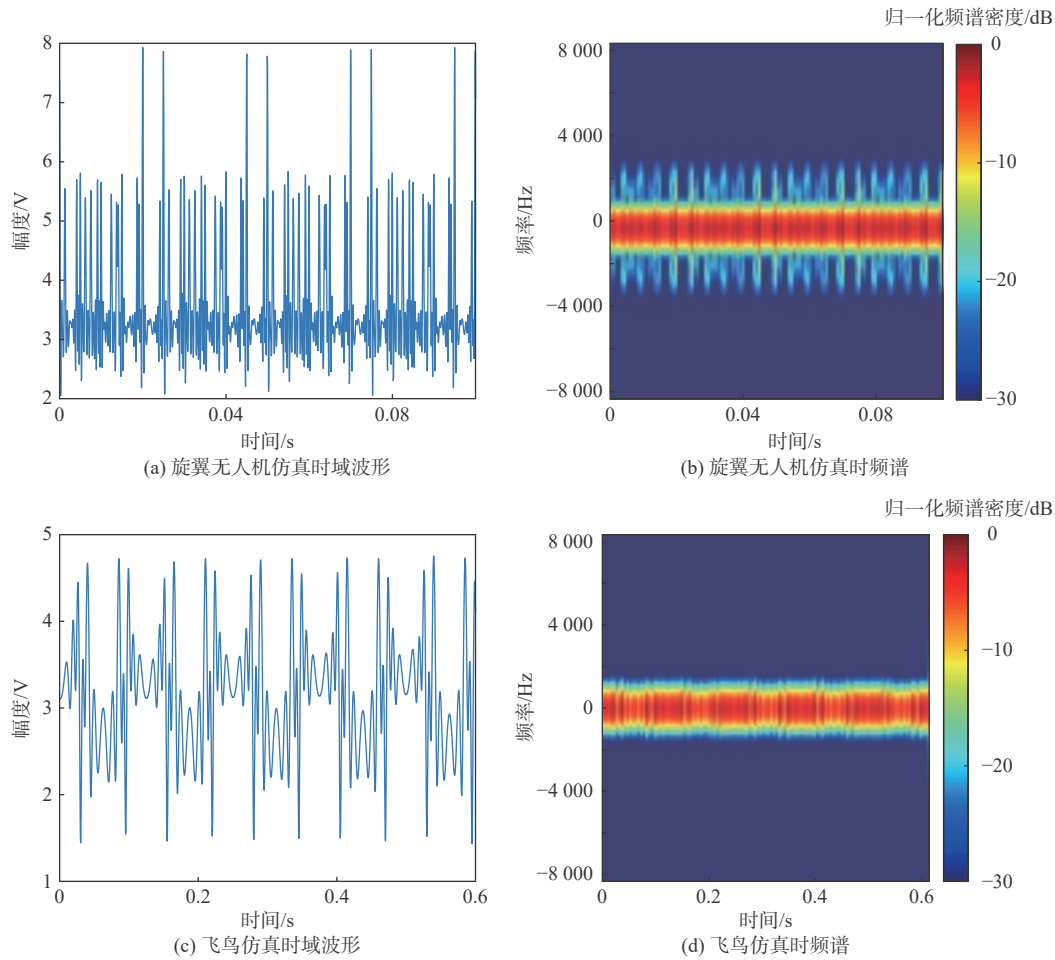
由于旋翼无人机的旋翼转速快，可以明显地观察到无人机的微多普勒特征；而飞鸟扑翼的拍打频率缓慢，微多普勒特征集中在较低的频率。改变设置的脉冲重复周期（或调制周期）可以使飞鸟的微多普勒特征更加清晰，如图2所示。从图2与文献[11,13,25]给出的实测飞鸟数据时频谱图的比较可以看出，本文所使用的仿真飞鸟数据与实测飞鸟数据都呈现出接近正弦波动的微多普勒特征，仿真数据与实测数据具有一致的微多普勒特征。

2.2 分类特征分析

对旋翼无人机和飞鸟的仿真雷达回波信号进行地杂波抑制和机身/鸟身抑制等预处理后，分别对其基于小波包分解的子带统计特征和基于时频谱分割的子带统计特征进行分析。图3为典型四旋翼无人机雷达回波信号经上述预处理后的频谱示意图，明显观察到，地杂波及机身信号得到很好的抑制，最终仅存无人机旋翼部分的信号。

对于基于小波包分解的子带统计特征，对预处理后的复数雷达回波信号的实部进行小波包分解，考虑到有效性和复杂性的折中，本文使用3层小波包分解，小波基使用Symlets小波基。定义第3层的第1个子带为(3,0)，其余子带依次类推，共计8个子带。经过每层分解，高频部分的频谱会发生翻转，导致频率顺序与节点顺序不同[26]，各子带的频率范围由低到高分别为：(3,0)，(3,1)，(3,3)，(3,2)，(3,6)，(3,7)，(3,5)，(3,4)，对各子带按频率范围由低到高重新排列。通过观察各子带统计特征量之间的差异，可判断该子带统计特征分类无人机和飞鸟目标的有效性。

无人机旋翼信号经小波包分解后，各子带的归一化幅度及时频谱正频率部分如图4(a)和图4(b)所示，飞鸟振翅信号的相应结果如图4(c)和图4(d)



(a) 旋翼无人机仿真时域波形　(b) 旋翼无人机仿真时频谱

(c) 飞鸟仿真时域波形　(d) 飞鸟仿真时频谱

图 1　旋翼无人机与飞鸟雷达回波信号仿真结果

Fig. 1　Radar echo signals simulation results of rotor drone and flying bird

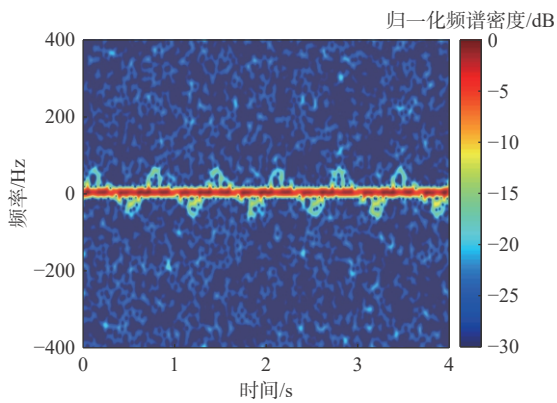


图 2　改变雷达参数的飞鸟雷达回波信号仿真数据时频谱

Fig. 2　Time-frequency spectrum of simulated radar echo data for a flying bird with changed radar parameters

所示。通过图 4 可知，小波包分解的低频子带与时频分析的低频带有明显的对应，低频子带的归一化幅度值高于高频子带，且旋翼信号幅度较大的低频子带数多于振翅信号，无人机旋翼比飞鸟振翅有更宽频率的时频谱，因此，可以根据子带的统计特征来区分二者。

为了便于分析无人机旋翼及飞鸟振翅的本质特征，后续将进行无噪情况下无人机旋翼、飞鸟振翅和纯高斯白噪声的基于小波包分解和时频谱分割的不同子带的统计特征值比较，以下分析是其中一种观测俯仰角与方位角的结果。

图 5 给出基于小波包分解的不同子带的统计特征值的比较。由图 5 可知，对于能量比特征，纯噪声不同子带的统计特征值差别不大，而无人机旋翼和飞鸟振翅低频子带的统计特征值明显高于高频子带，旋翼比振翅有更多的低频子带具有较大的统计特征值。尺度熵和奇异值比特征也具有与能量比特征相似的特点。可以看出，可以根据不同子带的小波包分解子带统计特征值的分布情况区分无人机与飞鸟。

图 6 和图 7 为不同信噪比条件下无人机旋翼和飞鸟振翅子带统计特征值在不同子带的分布变化，此处信噪比指旋翼部分或振翅部分的信号功率与噪声功率的比值。可以看到，无论是无人机旋翼还是飞鸟振翅，随着信噪比降低，不同子带的统计特征值逐渐趋于相近，差别越来越小。对比无人机旋翼和飞鸟振翅来看，在信噪比没有很低的条件下，不同信噪比下无人机旋翼多个低频子带特征值高

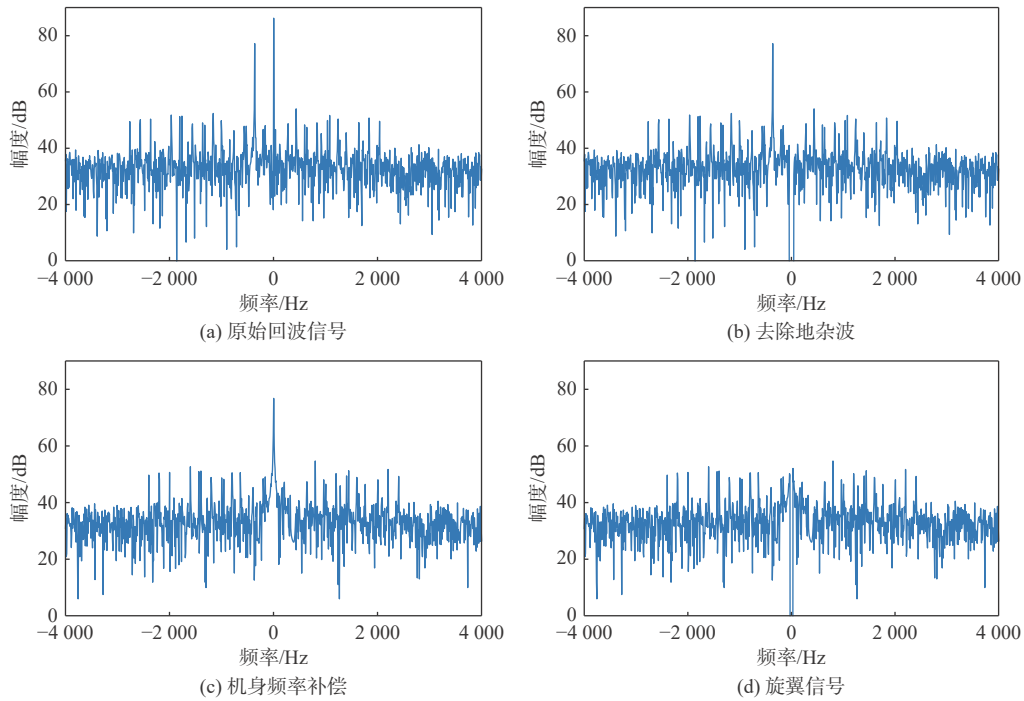


图3 四旋翼无人机雷达回波信号频谱图

Fig. 3 Spectrum of quadrotor UAV radar echo signal

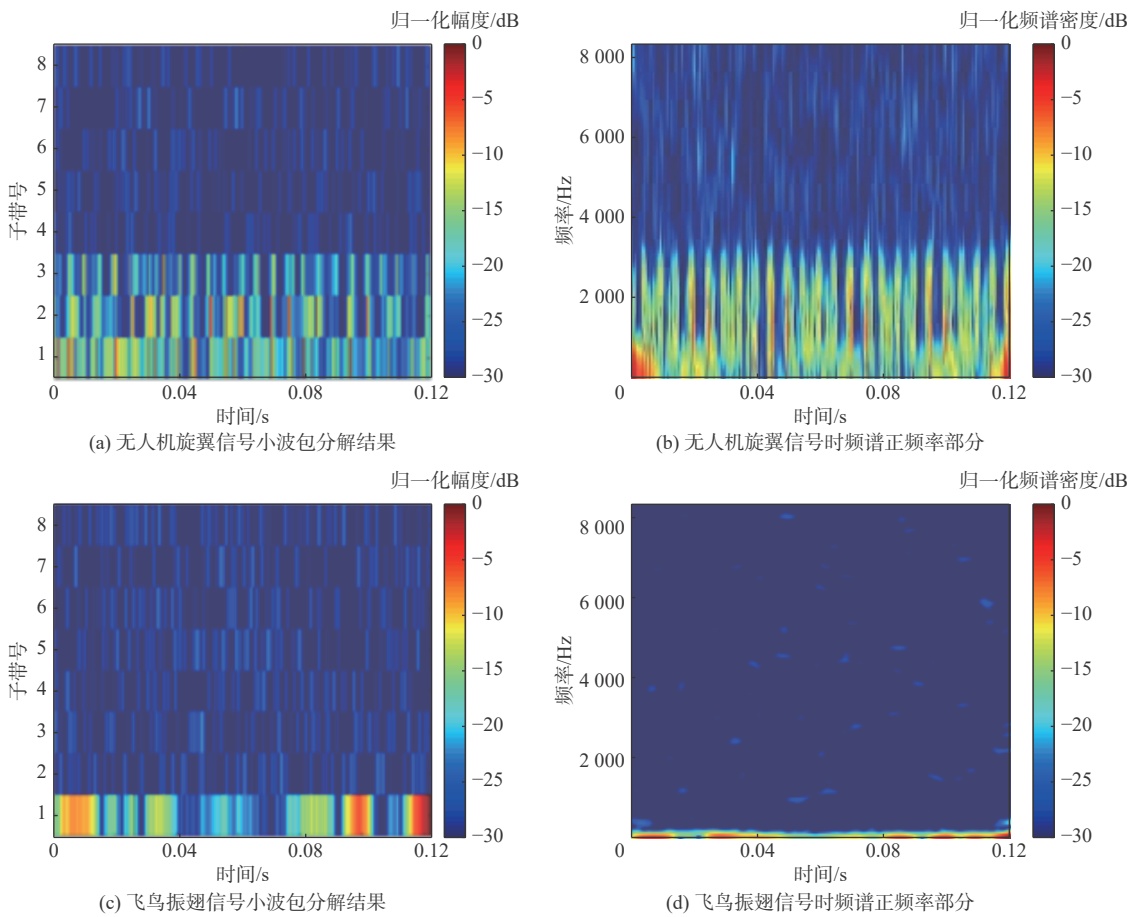


图4 无人机旋翼、飞鸟振翅信号小波包分解结果与时频谱正频率部分

Fig. 4 Wavelet packet decomposition results and the positive-frequency components of the time-frequency spectrum for drone rotors and flying bird wings

于高频子带和飞鸟振翅单个低频子带特征值高于高频子带的特点没有改变。还可以看出,不同子带统计特征对于无人机旋翼和飞鸟振翅的区分度也有所差别。

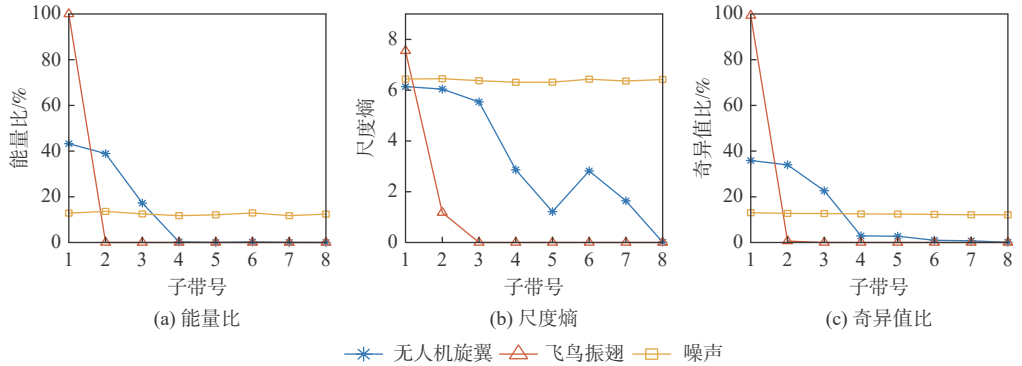


图 5　无人机旋翼、飞鸟振翅和噪声信号小波包分解子带统计特征值

Fig. 5　Values of statistical features of subbands for wavelet packet decomposition of drone rotors, flying bird wings and noise

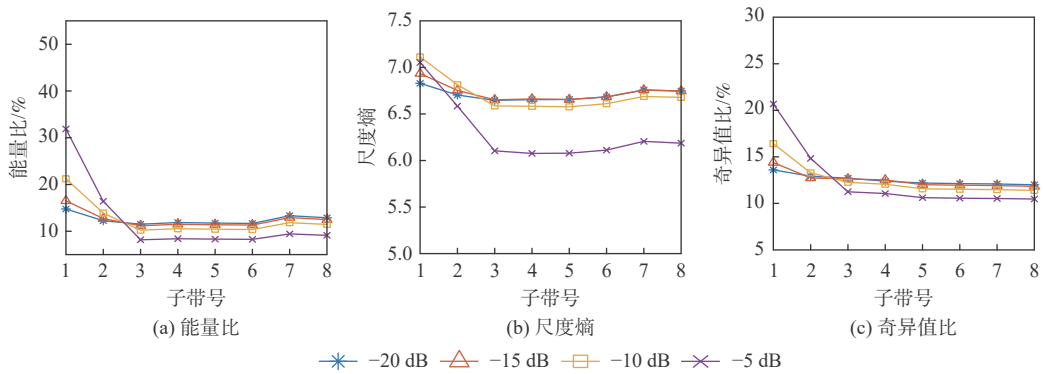


图 6　不同无人机旋翼信噪比时小波包分解子带统计特征值

Fig. 6　Values of statistical features of subbands of wavelet packet decomposition for different SNR of drone rotors

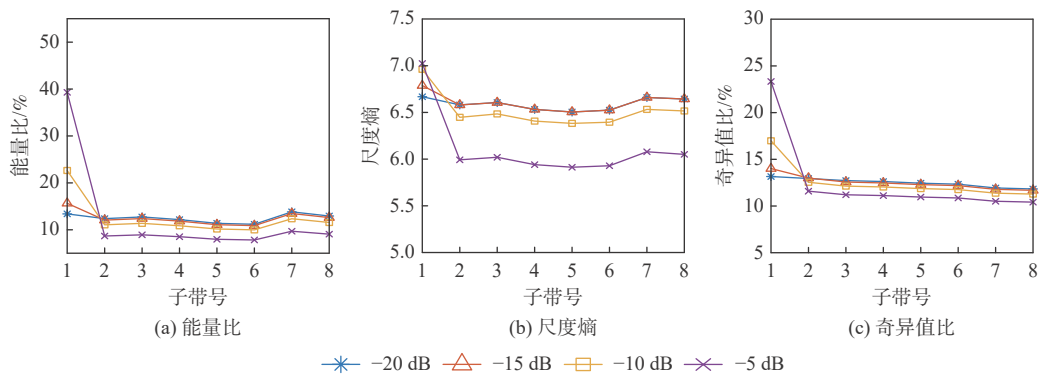


图 7　不同飞鸟振翅信噪比时小波包分解子带统计特征值

Fig. 7　Values of statistical features of subbands of wavelet packet decomposition for different SNR of flying bird wings

对于基于时频谱分割的子带统计特征，与小波包分解类似，对时频谱的正频率部分按照频率均匀划分成 8 个子带。由于旋转叶片和飞鸟振翅的影响，低频子带的时频谱区别于高频子带，从中提取的特征量也会有所不同，因此，可根据子带统计特征量之间的差异区分无人机和飞鸟目标。

图 8 给出了无噪情况下无人机旋翼、飞鸟振翅和纯高斯白噪声的基于时频谱分割的不同子带的统计特征值比较，同样是没有加入机身/鸟身和地杂波的结果。根据图 8 可以得到与基于小波包分解的子带统计特征相似的结论，仅含无人机旋翼和飞鸟振翅的雷达回波信号经时频分割后，低频子带的子带统计特征值与高频子带显著不同，无人机旋翼与飞鸟相比具有差异性的低频子带更多，而纯噪声不同子带的子带统计特征值分布相对均匀。

不同信噪比下基于时频谱分割的子带统计特征值在不同子带分布的变化如图 9 和图 10 所示。可以看到，与小波包分解的子带统计特征类似，无人机旋翼和飞鸟振翅不同子带统计特征值的分布存在差异，信噪比降低时差异的显著性也有所下降。

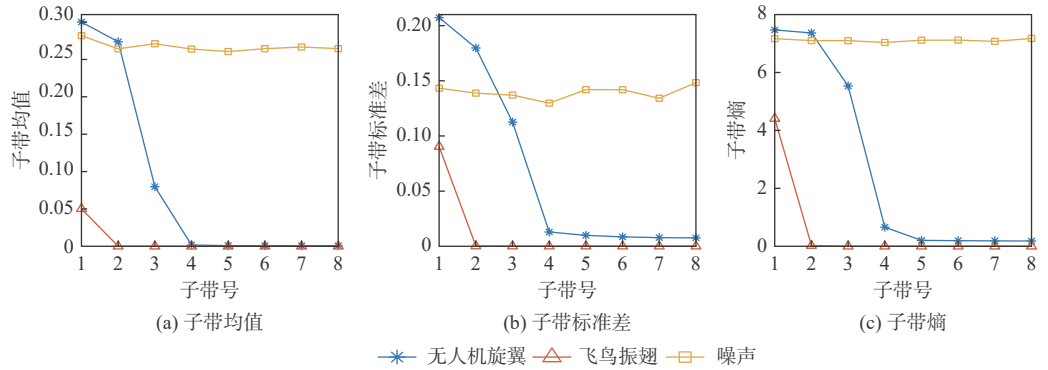


图 8 无人机旋翼、飞鸟振翅和噪声信号时频谱分割子带统计特征值

Fig. 8 Values of statistical features of subbands for time-frequency segmentation of drone rotors, flying bird wings and noise

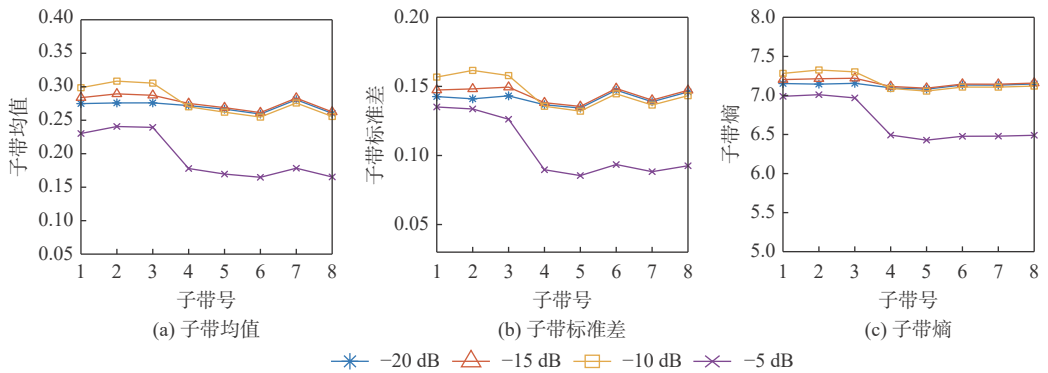


图 9 不同无人机旋翼信噪比下时频谱分割子带统计特征值

Fig. 9 Values of statistical features of subbands of time-frequency segmentation for different SNR of drone rotors

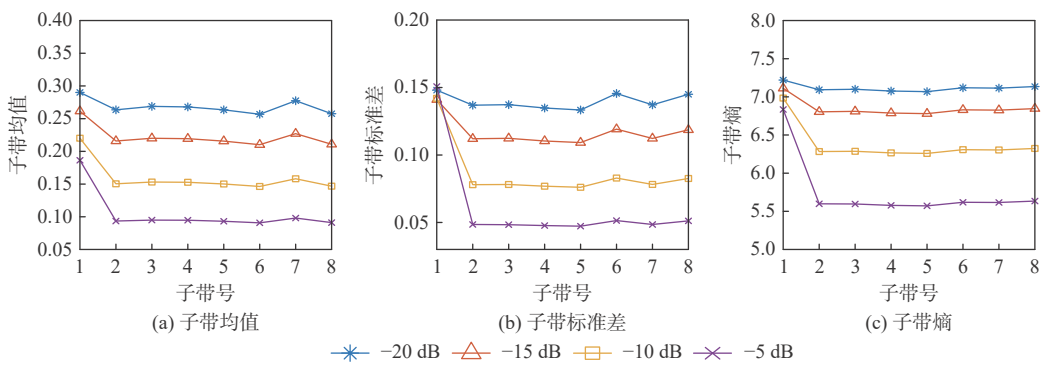


图 10 不同飞鸟振翅信噪比下时频谱分割子带统计特征值

Fig. 10 Values of statistical features of subbands of time-frequency segmentation for different SNR of flying bird wings

图 11 为无人机旋翼(飞鸟振翅)信噪比为−20 dB时无人机旋翼及飞鸟振翅的时频谱图。此时的时频谱图已难于观察到有效信息,而通过提取的子带统计特征值还能体现无人机与飞鸟的差异性。

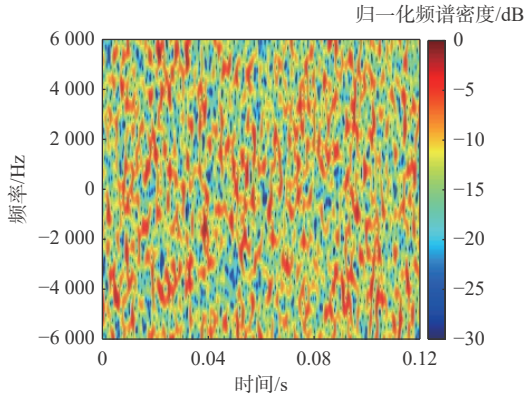
2.3 分类特征优选方法

使用 2.2 节所述的分类方法框架,通过分析不同子带统计特征的选取对分类性能的影响,优选最终使用的子带特征。

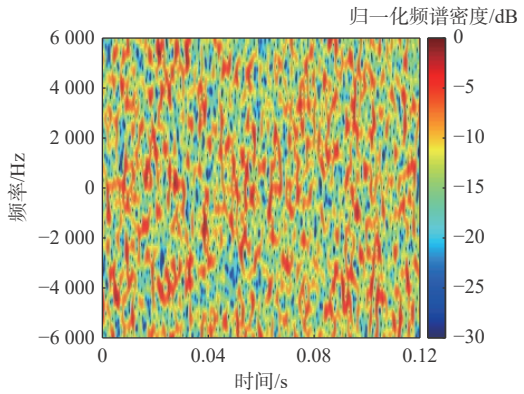
分类性能的比较使用仿真生成的全部数据样本,这些样本包含不同信噪比条件下旋翼无人机和飞鸟 2 种目标在不同观测俯仰角、不同观测方位角、不同旋翼转速和不同飞鸟振翅频率的雷达回波信号。使用 10 折交叉验证法计算不同信噪比下的分类性能,即在每种信噪比条件下,随机取全部数据样本集的 90% 作为训练集训练分类器,剩下的 10% 作为测试集计算分类性能。进行多次蒙特卡罗实验,最终取所有次数蒙特卡罗实验计算得到分类性能指标的平均值作为最终分类性能指标。

选取准确率,即正确分类的样本数占全部样本数的比例,作为分类性能指标。

对于基于小波包分解和时频谱分割这 2 类子带统计特征,分别分析使用单个特征和联合使用多个特征分类性能的差别。



(a) 无人机旋翼



(b) 飞鸟振翅

图 11　无人机旋翼与飞鸟振翅的时频谱 (信噪比为−20 dB)

Fig. 11　Time-frequency spectrum of drone rotors and bird wings (SNR is −20 dB)

3　分类实验结果与分析

3.1　仿真实验数据集说明

实验中生成仿真数据的具体参数如表 1 所示，其中，旋翼无人机使用最常见的四旋翼无人机，方位角和俯仰角的变化步长为 5°，旋翼转速的变化步长为 10 r/s(表示单个叶片每秒转动的圈数)，振翅拍打频率的变化步长为 1 Hz。同时，为了验证在不同信噪比条件下的准确率，信噪比的变化范围为−30～20 dB，变化步长为 5 dB，此处信噪比指雷达回波信号中无人机旋翼部分和飞鸟振翅部分与噪声的功率比。相同信噪比条件下为一组数据，每组数据包含 2 种目标、13 组方位角、9 组俯仰角、7 组旋翼转速(振翅频率)的样本，每组数据的样本量为 $2\times13\times9\times7=1\,638$个。

表 1　四旋翼无人机和飞鸟雷达回波信号仿真变化的参数

Table 1　Variable simulation parameters of radar echo signal of quadrotor UAV and flying bird

目标类型	俯仰角/(°)	方位角/(°)	旋翼1、旋翼2转速/(r·s^{-1})	旋翼3、旋翼4转速/(r·s^{-1})	振翅拍打频率/Hz
四旋翼无人机	20～60	0～60	60～120	80～140	
飞鸟	20～60	0～60			6～12

实验中所用雷达参数如表 2 所示。

表 2　雷达仿真参数

Table 2　Simulation parameters of radar

参数	数值
雷达工作频率/GHz	5.5
脉冲宽度/μs	1.5
脉冲重复间隔/μs	60
带宽/MHz	8

旋翼无人机、飞鸟的其他实验参数如表 3 所示。无人机各个叶片的初始相位设置为随机值。一般机身平均功率相较于旋翼平均功率高约 10 dB[27]，设置无人机机身部分与旋翼部分的功率比为 10 dB，为便于对照，鸟身与鸟翼的功率比也设置为 10 dB。因为在处理中机身和鸟身的信号会被抑制，该值并不影响旋翼与振翅部分和噪声的信噪比。

表 3　目标雷达回波信号仿真不变的参数

Table 3　Invariant simulation parameters of targets echo radar signal

目标类型	参数	数值
旋翼无人机	叶长/m	0.12
	叶片数量/个	2
	旋翼数量/个	4
	径向速度/(m·s^{-1})	10
飞鸟	上臂/m	0.12
	前臂/m	0.12
	上臂扇动角的幅度/(°)	40
	前臂扇动角的幅度/(°)	30
	上臂扑打角度的滞后/(°)	15
	前臂扑打角度的滞后/(°)	40
	前臂扭转角的幅度/(°)	20
	前臂扭转角的滞后/(°)	5
	径向速度/(m·s^{-1})	9

3.2　分类特征优选实验结果

根据 2.3 节所述方法，对不同子带统计特征分类性能进行比较，下面给出小波包分解和时频谱分割的特征优选结果。实验结果为 10 折交叉验证 50 次蒙特卡罗实验的平均值。

对于小波包分解，单独使用能量比、尺度熵、奇异值比及联合三者进行对比；对于时频谱分割，单独使用子带均值、子带标准差、子带熵及联合三者进行对比。

如表 4 所示，单独使用能量比的分类准确率总体优于尺度熵和奇异值比，同时接近联合使用 3 种特征的分类准确率。

如表 5 所示，使用时频谱子带均值的分类准确率总体上优于另 2 个特征，只有−15 dB 时略低于其

表 4 4种小波包分解特征提取方法分类准确率

Table 4 Classification accuracy of four wavelet packet decomposition feature extraction methods

无人机旋翼(飞鸟振翅)信噪比/dB	准确率/%			
	能量比	尺度熵	奇异值比	三者联合
−30	52.52	51.56	50.87	52.00
−25	57.35	56.43	52.22	57.09
−20	70.37	70.31	59.63	72.35
−15	87.07	86.43	84.19	87.30

表 5 4种时频谱分割特征提取方法分类准确率

Table 5 Classification accuracy of four time-frequency segmentation feature extraction methods

无人机旋翼(飞鸟振翅)信噪比/dB	准确率/%			
	子带均值	子带标准差	子带熵	三者联合
−30	54.41	52.68	51.87	53.31
−25	59.45	56.84	58.66	60.52
−20	72.06	69.82	69.97	72.31
−15	87.47	89.55	89.58	89.64

他特征,但总体上与联合使用3种特征的分类准确率接近。

因此,基于准确率与计算效率折中的考虑,本文最终的分类方法中选用基于小波包分解得到的子带能量比和基于时频谱分割得到的时频谱子带均值构建分类特征向量。

3.3 与其他方法的分类性能比较

由于无人机旋翼与飞鸟振翅最大多普勒频率的差别,容易想到利用谱宽检测对这2类目标进行分类,然而,在信噪比较低的条件下,谱宽检测往往会失效。

图12给出了不同信噪比下利用文献[28]方法得到的无人机和飞鸟雷达回波信号受微动调制的谱宽。此处信噪比依然为无人机旋翼和飞鸟振翅与噪声的功率比,按照机身(鸟身)与旋翼(振翅)的功率比为10 dB计算,目标整体的信噪比相较旋翼(振翅)的信噪比高10 dB左右。由图12可知,当无人机旋翼(飞鸟振翅)信噪比小于或等于−15 dB,也就是目标整体信噪比约−5 dB或更低时,谱宽检测结果为脉冲重复频率的一半,即多普勒谱的最大频率,此时谱宽检测已失效,无法通过谱宽检测区分旋翼无人机和飞鸟目标。

将本文方法的分类平均准确率与文献[8]基于离散小波变换和奇异值分解的方法(记为DWT-SVD)及文献[29]的基于经验模态分解的方法(记为EMD)进行比较,用于对比的方法也采用相同的支持向量机分类器进行实验,结果如图13所示。

图13中优选的联合使用基于小波包分解的子带能量比和基于时频谱分割的子带均值的结果记为“联合”,记为“小波包分解”的结果为单独使用能量比的结果,记为“时频谱分割”的结果为单独使用时频谱子带均值的结果。实验结果为10折交叉验证每种信噪比条件下进行50次蒙特卡罗实验的结果。由图13可知,当无人机旋翼(飞鸟振翅)信噪比低于5 dB时,DWT-SVD方法的分类准确率迅速下降,当无人机旋翼(飞鸟振翅)信噪比低于−10 dB时,EMD方法的分类准确率开始迅速下降。在无人机旋翼(飞鸟振翅)信噪比低于−10 dB,也就是目标整体的信噪比低于约0 dB的条件下,本文方法的分类准确率明显高于另2种方法。联合基于小波包分解和基于时频谱分割的子带统计特征的性能优于只使用一类子带统计特征的性能。例如,当无人机旋翼(飞鸟振翅)信噪比为−15 dB时,联合、小波包分解、时频谱分割、DWT-SVD、EMD这5种方法的分类准确率分别为89.22%、87.07%、87.43%、49.16%、62.04%。当无人机旋翼(飞鸟振翅)信噪比进一步下降到−20 dB时,DWT-SVD和EMD方法的分类准确率已下降到49.65%

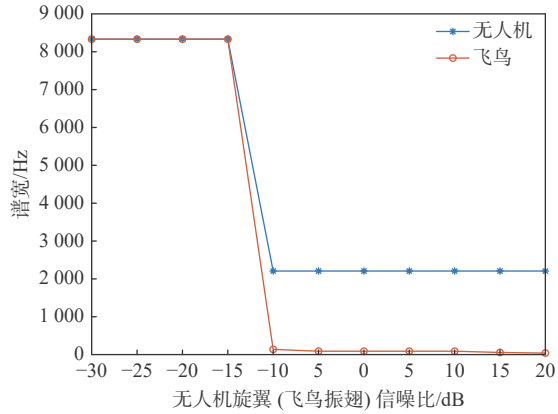


图12 无人机与飞鸟谱宽检测结果

Fig. 12 Result of spectral width detection of drones and birds

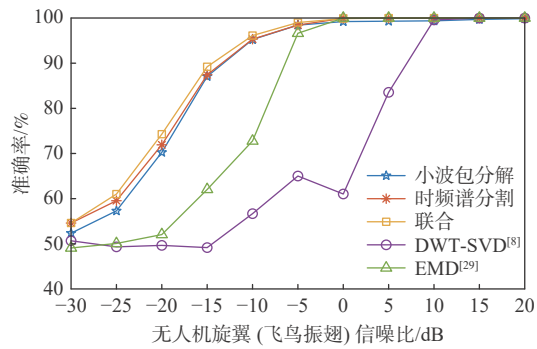


图13 不同无人机旋翼(飞鸟振翅)信噪比下本文方法与其他常见方法分类准确率的比较

Fig. 13 Comparison of the classification accuracy of the proposed method and other common methods under different SNR of drone rotors (flying bird wings)

和 52.05%, 而本文方法的分类准确率依然能达到 74.28%、70.26%、71.93%。当无人机旋翼(飞鸟振翅)信噪比为−25 dB 时, 本文方法的分类准确率为 61.02%, 同样优于其他常见方法。

图 14 为不同方法的统计特征量单次提取耗时对比, 用于衡量各方法的计算效率。由图 14 可知, 小波包分解耗时相对较少, 这是由于其存在 Mallat 快速算法[30]。基于小波包分解的统计特征提取耗时和 EMD 相当, 并且明显比其他方法耗时短。基于 DWT-SVD 方法耗时长, 而且从前面分析可知, 这种方法分类准确率在低信噪比条件下相较其他方法也更低。联合方法的耗时主要消耗在基于时频谱分割的子带统计特征提取上, 虽然耗时更长, 但却可以获得更高的分类准确率。

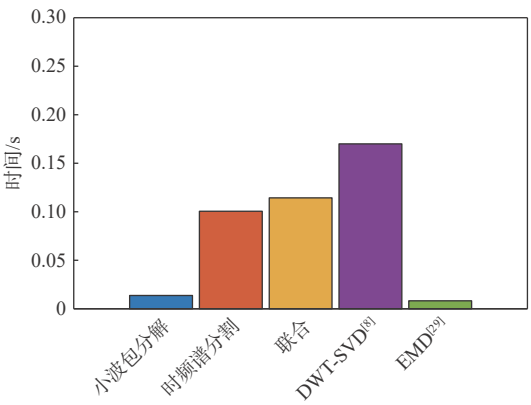


图 14　本文方法与其他常见方法分类特征提取耗时比较

Fig. 14　Time-cost comparison of classification feature extraction of the proposed method and other common methods

3.4　实测数据验证

使用文献 [31] 提供的无人机雷达回波数据集, 选用其中大疆御 2 及大疆悟 2 的 K 波段数据作为旋翼无人机的实测数据。该实测数据为近距离观测悬停状态的无人机获得, 回波数据可近似看作是无噪数据。实测数据不易直接控制旋翼部分的信噪比, 为比较不同无人机旋翼(飞鸟振翅)信噪比下的分类准确率, 本文对去除机身与地杂波的无人机实测数据添加指定信噪比的高斯白噪声。

目前, 公开发布的飞鸟雷达回波数据相对稀缺, 飞鸟数据仍然使用仿真数据, 其各项仿真参数与前述旋翼无人机实测数据的雷达参数保持一致, 雷达工作频率为 23.7 GHz, 调制周期为 0.3 ms。

本节无人机与飞鸟数据不加噪声情况下的示例如图 15 所示, 该组数据分类性能比较如图 16 所示。可以看到, 包含实测数据的实验中, 本文方法在信噪比较低情况下的分类性能依然明显高于其他 2 种方法, 例如, 当无人机旋翼(飞鸟振翅)信噪比为−10 dB 时, 联合、小波包分解、时频谱分割、

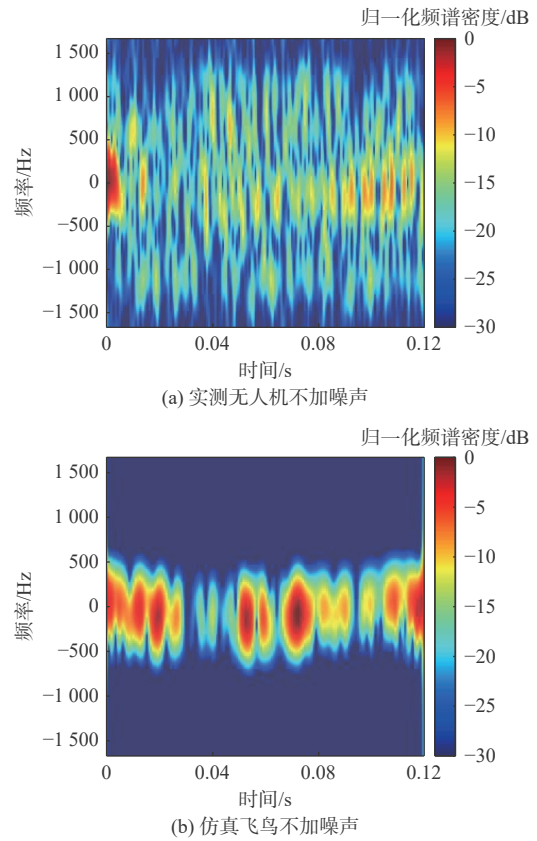


图 15　实测无人机与仿真飞鸟不加噪声示例

Fig. 15　Example of a real UAV and a simulated flying bird without noise

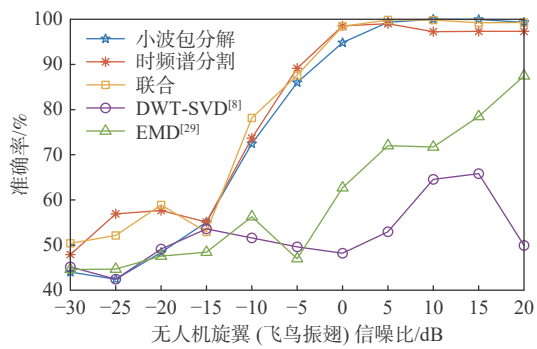


图 16　不同无人机旋翼(飞鸟振翅)信噪比下实测无人机与仿真飞鸟分类准确率的比较

Fig. 16　Comparison of the classification accuracy of actual drones' echo and simulated birds' echo under different SNR of drone rotors (flying bird wings)

DWT-SVD、EMD 这 5 种方法的分类准确率分别为 78.15%、72.44%、73.68%、51.59%、56.28%。包含实测数据的实验分类准确率虽然较仿真数据实验有一定下降, 但在信噪比为−10 dB 时仍有接近 80% 的准确率。本文在实验中将实测无人机数据视为无噪数据, 但实际上, 尽管其信噪比较高, 但也并非完全无噪, 从图 15(a) 中也可看出, 该数据时频图在不加噪声的情况下微多普勒特征也有不小的波动, 并非像理想情况下体现出理想的周期性。此外, 实

测的调制周期较仿真数据更大，时间分辨率更低，这些都是造成分类准确率下降的可能原因。

4 结 论

针对目标与雷达有一定距离而信噪比较低时旋翼无人机和飞鸟目标的分类，提出一种准确率更高的分类方法。

1）利用不同信噪比条件下，由不同观测俯仰角、方位角的不同旋翼转速无人机和不同振翅频率飞鸟构建的仿真数据集进行的实验表明，在本文给出的雷达参数下，当无人机旋翼（飞鸟振翅）信噪比在−20～−10 dB之间时，也就是目标整体的信噪比在约−10～0 dB的低信噪比条件下，本文方法能够获得显著优于其他常见方法的分类准确率。在无人机旋翼（飞鸟振翅）信噪比为−20 dB，本文方法的分类准确率仍能达到74.28%。

2）仿真数据集进行的实验表明，在本文给出的雷达参数下，当无人机旋翼（飞鸟振翅）信噪比为−25 dB时，本文方法的分类准确率为61.02%，同样优于其他常见方法的分类准确率，虽然准确率明显降低，但也是优于随机判决50%准确率的弱分类器。

3）在包含实测数据的实验中，相比仿真数据的实验，本文方法分类准确率有一定的下降，在无人机旋翼（飞鸟振翅）信噪比为0 dB、−5 dB和−10 dB时，本文方法的分类准确率分别为98.41%、87.61%和78.15%，但依然明显优于其他2种方法。

参考文献（References）

[1] Gazovova S, Perdoch J, Matousek Z, et al. Analysis of airport bird strike avoidance by pulse-Doppler radar[C]//Proceedings of the 2020 New Trends in Aviation Development. Piscataway: IEEE Press, 2020: 84-88.

[2] 陈小龙, 陈唯实, 饶云华, 等. 飞鸟与无人机目标雷达探测与识别技术进展与展望[J]. 雷达学报, 2020, 9(5): 803-827.
Chen X L, Chen W S, Rao Y H, et al. Progress and prospects of radar target detection and recognition technology for flying birds and unmanned aerial vehicles[J]. Journal of Radars, 2020, 9(5): 803-827(in Chinese).

[3] Wu Q, Zhao J H, Zhang Y, et al. Radar micro-Doppler signatures model simulation and feature extraction of three typical LSS targets[C]//Proceedings of the 2019 6th International Conference on Information Science and Control Engineering. Piscataway: IEEE Press, 2019: 1103-1108.

[4] Matsuda T, Yataka R, Gocho M, et al. Micro-Doppler analysis under various aspect angles for small UAV classification[C]//Proceedings of the 2019 IEEE Asia-Pacific Microwave Conference. Piscataway: IEEE Press, 2019: 102-104.

[5] Ma B L, Chen B X, Zhang Z R, et al. Classification of UAV and ground targets by micro-Doppler signatures based on PD surveillance radar[C]//Proceedings of the 2021 CIE International Conference on Radar. Piscataway: IEEE Press, 2021: 1361-1365.

[6] Rahman S, Robertson D A. Radar micro-Doppler signatures of drones and birds at K-band and W-band[J]. Scientific Reports, 2018, 8: 17396.

[7] Wang Y L, Zhao C D, Luo G G. A lightweight UAV recognition algorithm based on micro-Doppler features[C]//Proceedings of the 2021 IEEE/CIC International Conference on Communications in China. Piscataway: IEEE Press, 2021: 6-10.

[8] Li S, Chai Y, Guo M Y, et al. Research on detection method of UAV based on micro-Doppler effect[C]//Proceedings of the 2020 39th Chinese Control Conference. Piscataway: IEEE Press, 2020: 3118-3122.

[9] Hasan M M, Pandey A, Bazil Raj A A. UAV classification from micro-Doppler signature-based time frequency images using SVM[C]//Proceedings of the 2022 International Conference on Augmented Intelligence and Sustainable Systems. Piscataway: IEEE Press, 2022: 1225-1230.

[10] Wen J, Tu L, Wang L, et al. Multi-rotors UAV motion recognition based on micro-Doppler feature extraction[C]//Proceedings of the 2019 IEEE International Conference on Signal, Information and Data Processing. Piscataway: IEEE Press, 2019: 1-4.

[11] Farshchian M, Selesnick I, Parekh A. Bird body and wing-beat radar Doppler signature separation using sparse optimization[C]//Proceedings of the 2016 4th International Workshop on Compressed Sensing Theory and Its Applications to Radar, Sonar and Remote Sensing. Piscataway: IEEE Press, 2016: 71-74.

[12] Li J L, Li W D, Wang R, et al. Classification of bird and drone based on radar time-frequency analysis[C]//Proceedings of the IET International Radar Conference. London: IET, 2023: 4137-4141.

[13] Yoon S, Kim S, Jung J, et al. Efficient protocol to use FMCW radar and CNN to distinguish micro-Doppler signatures of multiple drones and birds[J]. IEEE Access, 2022, 10: 26033-26044.

[14] Kumawat H C, Raj A A B, Samczynski P. Spectrum localization and Hough transform-based β tuning for LSS targets' accurate micro-Doppler imaging system[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-11.

[15] Torvik B, Olsen K E, Griffiths H. K-band radar signature analysis of a flying mallard duck[C]//Proceedings of the International Radar Symposium. Piscataway: IEEE Press, 2013: 584-591.

[16] 陈唯实, 刘佳, 陈小龙, 等. 基于运动模型的低空非合作无人机目标识别[J]. 北京航空航天大学学报, 2019, 45(4): 687-694.
Chen W S, Liu J, Chen X L, et al. Non-cooperative UAV target recognition in low-altitude airspace based on motion model[J]. Journal of Beijing University of Aeronautics and Astronautics, 2019, 45(4): 687-694(in Chinese).

[17] Liu J, Xu Q Y, Chen W S. Classification of bird and drone targets based on motion characteristics and random forest model using surveillance radar data[J]. IEEE Access, 2021, 9: 160135-160144.

[18] Zhang S H, Zhai R P, Liu Y K. UAV swarm type recognition algorithm based on dual-domain fusion features and feature selection[C]//Proceedings of the 2022 IEEE 22nd International Conference on Communication Technology. Piscataway: IEEE Press, 2022: 578-584.

[19] Sethuraman H V, Yarovoy A, Fioranelli F. Classification of unmanned aerial vehicles (UAVs) carrying payloads with polarimetric radar[C]//Proceedings of the 2021 18th European Radar Confer-

ence. Piscataway: IEEE Press, 2022: 365-368.

[20] Jiang W, Liu Y, Wei Q C, et al. A high-resolution radar automatic target recognition method for small UAVs based on multi-feature fusion[C]//Proceedings of the 2022 IEEE 25th International Conference on Computer Supported Cooperative Work in Design. Piscataway: IEEE Press, 2022: 775-779.

[21] 陈唯实, 黄毅峰, 陈小龙, 等. 机场净空区飞鸟与非合作无人机目标识别[J]. 民航学报, 2020, 4(3): 27-33.
Chen W S, Huang Y F, Chen X L, et al. Recognition methods of flying bird and non-cooperative drone targets in airport clearance area[J]. Journal of Civil Aviation, 2020, 4(3): 27-33(in Chinese).

[22] 朱凌智. 基于微多普勒效应的无人机载雷达对地面目标分类方法研究[D]. 南京: 南京理工大学, 2021.
Zhu L Z. Research on classification methods of ground targets based on micro-Doppler effect and radar equipped on the UAV[D]. Nanjing: Nanjing University of Science and Technology, 2021(in Chinese).

[23] 王晓亮, 王承祥, 何炜琨. 利用飞控特征的四旋翼无人机雷达回波信号仿真[J]. 信号处理, 2021, 37(2): 292-303.
Wang X L, Wang C X, He W K. Radar echoes simulation of the quadrotor drone utilizing flight control characteristics[J]. Journal of Signal Processing, 2021, 37(2): 292-303(in Chinese).

[24] 陈小龙, 南钊, 张海, 等. 飞鸟与旋翼无人机雷达微多普勒测量实验研究[J]. 电波科学学报, 2021, 36(5): 704-714.
Chen X L, Nan Z, Zhang H, et al. Experimental research on radar micro-Doppler of flying bird and rotor UAV[J]. Chinese Journal of Radio Science, 2021, 36(5): 704-714(in Chinese).

[25] Molchanov P, Egiazarian K, Astola J, et al. Classification of small UAVs and birds by micro-Doppler signatures[C]//Proceedings of the 2013 European Radar Conference. Piscataway: IEEE Press, 2013: 172-175.

[26] Zarei J, Poshtan J. Bearing fault detection using wavelet packet transform of induction motor stator current[J]. Tribology International, 2007, 40(5): 763-769.

[27] Ritchie M, Fioranelli F, Griffiths H, et al. Monostatic and bistatic radar measurements of birds and micro-drone[C]//Proceedings of the 2016 IEEE Radar Conference. Piscataway: IEEE Press, 2016: 1-5.

[28] Kang K B, Choi J H, Cho B L, et al. Analysis of micro-Doppler signatures of small UAVs based on Doppler spectrum[J]. IEEE Transactions on Aerospace and Electronic Systems, 2021, 57(5): 3252-3267.

[29] Oh B S, Guo X, Wan F Y, et al. Micro-Doppler mini-UAV classification using empirical-mode decomposition features[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(2): 227-231.

[30] Kang P P, Chen Z M. Aircraft classification method based on the kurtosis-skewness feature and wavelet decomposition and linear discriminant analysis[J]. The Journal of Engineering, 2019, 2019(21): 7855-7859.

[31] 陈小龙, 袁旺, 杜晓林, 等. 多波段 FMCW 雷达低慢小探测数据集 (LSS-FMCWR-1.0) 及高分辨微动特征提取方法[J]. 雷达学报 (中英文), 2024, 13(3): 539-553.
Chen X L, Yuan W, Du X L, et al. Multiband FMCW radar LSS-target detection dataset (LSS-FMCWR-1.0) and high-resolution micromotion feature extraction method[J]. Journal of Radars, 2024, 13(3): 539-553(in Chinese).

Classification method of rotor drones and flying birds under low signal-to-noise ratio for radar

WANG Xiaoliang*, WANG Congsheng, SHI Yuxiang, HE Weikun

(Tianjin Key Lab for Advanced Signal Processing, Civil Aviation University of China, Tianjin 300300, China)

Abstract: Aiming at the problem of how to classify multirotor drones and flying birds under low signal-to-noise ratio conditions for low-altitude surveillance radar, an effective target classification method is proposed. The subband statistical features, which are obtained respectively from wavelet packet decomposition (WPD) and time-frequency segmentation (TFS) of the radar echo signals, are extracted first in the method. The feature vectors are then created using the subband statistical features, and the targets are classified using a support vector machine (SVM). The subband energy ratio of wavelet packet decomposition and the subband mean value of time-frequency spectrogram are chosen as the classification features to build the feature vectors that are used by the final support vector machine classifier by examining the variations in classification performance of various statistical features. The experimental results show that the classification accuracy of the proposed method for classifying multirotor drones and flying birds under low SNR conditions is significantly improved compared with other common methods.

Keywords: rotor drones; flying birds target; wavelet packet decomposition; time-frequency analysis; statistical features of subband

Received: 2024-08-02; **Accepted**: 2024-10-07; **Published Online**: 2024-10-30 10:24

URL: link.cnki.net/urlid/11.2625.V.20241029.1658.004

Foundation item: The Fundamental Research Funds for the Central Universities (3122022085)

* **Corresponding author**. E-mail: wxl_ee@126.com

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0429

基于多策略高尔夫优化算法的无人机三维航迹规划

孙博[1,2]，章文鹏[2]，吴泽萱[2]，苏烨博[2]，魏明[1,2,*]

(1. 中国民航大学 民航航班广域监视与安全管控技术重点实验室，天津 300300；
2. 中国民航大学 空中交通管理学院，天津 300300)

摘 要：考虑动态限制区、无线电干扰、障碍物、无人机性能等因素，根据任务的起讫点和计划时间，建立一种无人机(UAV)三维航迹规划问题的数学模型，确定无人机航迹和实际出发时间，追求航迹长度成本、飞行高度成本、威胁成本和平滑成本最少。根据问题特征，设计求解该问题的多策略高尔夫优化算法(MSGOA)，利用Sine映射产生更具多样性的初始种群，在算法的探索阶段融合Piecewise混沌映射和黄金正弦策略以扩大算法的全局探索能力，在算法的开发阶段使用柯西变异策略以增加算法的局部寻优能力。将改进算法与其他5种主流群智能算法在10个标准测试函数上进行求解对比，证明改进算法的有效性。以中国香港的真实数字高程模型(DEM)地图为例，剖析不同参数的变化对最佳无人机三维航迹的影响，并对比不同算法在该问题上的求解性能差异，从而证明模型和算法的优越性。

关 键 词：无人机；三维航迹规划；高尔夫优化算法；混沌映射；黄金正弦算法；柯西变异
中图分类号：U8; V32
文献标志码：A **文章编号**：1001-5965(2026)11-3814-10

鉴于无人机(unmanned aerial vehicle, UAV)的灵活度高、机动性强、安全风险系数小、成本低等特点，其被广泛应用于搜索巡逻、侦察监视、抢险救灾、物流配送、电力巡检、农业灌溉等军用或民用任务。无人机三维轨迹规划是飞行任务规划系统的核心部分，在综合考虑任务起讫点和时间、油耗、威胁及飞行区域等因素的前提下，无人机不断调整飞行高度，找到一条匹配三维限制飞行区形态变化的最佳飞行轨迹，显然，其比传统车辆路径规划复杂，吸引了国内外学者的广泛关注[1-5]。

目前，现有文献将真实三维空间网格化，采用运筹优化思路，研究不同目标(如任务完成效率最高[1]、任务完成时间最短[2]、运行总成本最小[3-8]、飞行距离最短[9-10]、能量消耗最小[11])和约束条件(如无人机性能[3-6]、障碍物及威胁分布[5-8]、能耗[11]和有无冲突飞行[3])下的无人机航迹生成，均将无人机航迹规划和运行时间分开。闫少强等[7]探讨了考虑复杂地形的无人机航迹规划和运行时间协同优化。进一步地，这些文献均是根据静态环境做无人机航迹预案，较少涉及动态环境下无人机航迹的实时调整问题。汪瀚洋[12]和李波[13]等探讨了动态威胁下的无人机在线航迹规划问题。此外，少数文献将无人机配送线路与航迹规划集成为一体。魏明等[14-15]提出无人机配送线路及航迹协同规划的模型；王飞等[16]提出多无人机物流配送的双层任务规划方法。求解算法一般分为启发式算法(如改进快速搜索随机树算法[17]、稀疏A*算法[3]等)、群智能算法(如粒子群优化算法[5]、鲸鱼优化算法[8]等)、深度学习(如深度Q网络算法[1]、指针网络[15]等)。

由上可知，现有不足主要有：①虽然部分文献

收稿日期：2024-06-13；**录用日期**：2024-08-16；**网络出版时间**：2024-09-25 12:03
网络出版地址：link.cnki.net/urlid/11.2625.V.20240924.1536.004
基金项目：民航航班广域监视与安全管控技术重点实验室开放基金(202203,202205)；教育部人文社科项目(20YJCZH176)
*通信作者. E-mail：mwei@cauc.edu.cn

引用格式：孙博，章文鹏，吴泽萱，等. 基于多策略高尔夫优化算法的无人机三维航迹规划[J]. 北京航空航天大学学报，2026，52(11)：3814-3823. Sun B，Zhang W P，Wu Z X，et al. Three-dimensional path planning of UAVs based on multi-strategy golf optimization algorithm[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3814-3823 (in Chinese).

探讨限制区(障碍物、无线电干扰和坠地风险等)、无人机性能等安全因素对航迹规划的影响,但是考虑综合成本(航迹、高度、威胁和平滑等)的集成研究较为少见;②现有文献较少考虑动态限制区影响下无人机航迹与出发时间协同优化问题。综上所述,本文研究了一种考虑动态限制区、无线电干扰、障碍物、无人机性能等的无人机三维航迹规划数学模型,根据飞行任务的起讫点和计划时间,在满足不同无线电信号强度等条件阈值情形下,搜索出一条避免危险区的安全有效航迹,并计算最佳推迟时间。根据问题特征,设计求解无人机三维航迹规划的多策略高尔夫优化算法 (multi-strategy golf optimization algorithm, MSGOA), 主要工作包括: 在算法的初始阶段,使用 Sine 映射,增加了种群多样性,加快了算法收敛速度; 在算法的探索阶段,融合 Piecewise 混沌映射和黄金正弦策略,扩大算法的搜索空间,增强了算法的全局探索能力; 在算法的开发阶段,使用柯西变异策略,增加算法局部寻优能力以避免陷入局部最优解。将本文改进 MSGOA 与其他 5 种主流群智能算法在 10 个标准测试函数上进行求解对比,证明改进算法不同策略的有效性。以中国香港的数字高程模型 (digital elevation model, DEM) 地图为例,生成不同典型任务场景下的无人机三维航迹,从而验证模型和算法的正确性。

1　无人机三维航迹规划问题的混合整数规划模型

1.1　问题描述

将某城市真实立体地图数据按照等分空间的划分方法进行三维空间网格化,共n个栅格,任意栅格与地形障碍物、无人机的性能(大小、速度v)等多因素之间交互决定。显然地,每个栅格可以被抽象为一个节点i,其三维网格坐标为$\boldsymbol{U}_i=(x_i,y_i,z_i)$,节点$i$和$j$之间距离为$d_{ij}=\sqrt{(x_j-x_i)^2+(y_j-y_i)^2+(z_j-z_i)^2}$。若任意 2 个栅格的节点$i$和$j$相邻(即: $x_j=x_i\pm1$, $y_j=y_i\pm1, z_j=z_i\pm1$),则它们之间连通, $b_{ij}=1$; 否则, $b_{ij}=0$。将建筑等各类障碍物、空域限制区、无线电干扰威胁等数据导入,可以确定每个栅格节点在各个可行时间段$[t_i^{\mathrm{s}},t_i^{\mathrm{e}}]$的通行状态$h_i$(0 和 1)。在已知$m$个无线电发射源的位置及其第 k 个所在信号强度r_k基础上,可以计算每个栅格节点i的无线电信号强度$p_i=\sum_{k=1}^{m}\frac{r_k}{4\pi d_{ik}^2}$,以及其坠落风险$q_i=u^{\mathrm{uav}}u_i^{\mathrm{h}}A_i\theta_i$,其中, u^{uav}为无人机的坠毁概率, A_i、θ_i、u_i^{h}分别为栅格节点i的面积、人口密度、坠毁人员伤亡率[14]。

假设无人机沿着栅格中心位置飞行,考虑无线电干扰阈值R、安全距离D、无人机性能(最大转弯角度、飞行高度)等约束,可以建立航空器的可行飞行通道网络。在此基础上,根据某次飞行任务的起点s、终点e和出发时间T_{S},可以在飞行通道网络找到一条安全的最短航迹,即优化决策变量o_{ij}和t_i表示无人机是否依次途径节点i、j和到达时间。

1.2　目标函数

根据无人机的任务目标,考虑航迹长度成本f_1、飞行高度成本f_2、威胁成本f_3和平滑成本f_4这 4 个目标,基于其权重$w_1\sim w_4$,获得无人机三维航迹规划的总成本函数f:

$$f=w_1f_1+w_2f_2+w_3f_3+w_4f_4 \tag{1}$$

式中: 航迹长度成本$f_1=\sum_{i,j=1}^{n}o_{ij}d_{ij}$表示无人机途径全部航路点的里程成本; 飞行高度成本$f_2=\sum_{i=1}^{n}\left(\sum_{j=1}^{n}o_{ij}\right)F(z_i)$限定无人机安全高度范围内飞行,其中, $F(z_i)=\begin{cases}\left|z_i-\dfrac{h_{\min}+h_{\max}}{2}\right| & h_{\min}\leqslant z_i\leqslant h_{\max}\\ \infty & \text{其他}\end{cases}$; 威胁成本$f_3=\sum_{i=1}^{n}\left(\sum_{j=1}^{n}o_{ij}\right)L(d_i)$限定无人机与障碍物保持安全间隔,其中, $L(d_i)=\begin{cases}\infty & d_i\leqslant D\\ 0 & \text{其他}\end{cases}$; 平滑成本$f_4=\sum_{i,j=1}^{n}o_{ij}(a\phi_{ij}+b\varphi_{ij})$表示无人机在实际飞行中水平转向角和垂直俯仰角的平滑成本,其中, $\phi_{ij}=\arctan\left(\|\boldsymbol{U}_i-\boldsymbol{U}_j\|/|\boldsymbol{U}_i-\boldsymbol{U}_j\right)$为投影在水平面 2 个连续路径段的水平转向角, $\varphi_{ij}=\arctan\left(z_i-z_j/\left\|\boldsymbol{U}_i-\boldsymbol{U}_j\right\|\right)$为投影在竖轴上 2 个连续路径段之间的垂直俯仰角, a和b分别为水平转向角和垂直俯仰角的惩罚系数。

1.3　约束条件

1) 无人机路径与节点之间的网络流约束,即一架无人机不同时途径多个节点,一个节点不同时被多架无人机访问:

$$\sum_{j=1}^{n}o_{ij}-\sum_{j=1}^{n}o_{ji}=\begin{cases}1 & i=s\\ -1 & i=e, i=1,2,\cdots,n\\ 0 & i\neq s,e\end{cases} \tag{2}$$

2) 无人机的航迹仅能途径相邻节点,并满足可行飞行区域、无线电强度、与限制区之间安全距离、坠落风险等安全阈值:

$$o_{ij}\leqslant b_{ij}\qquad i,j=1,2,\cdots,n \tag{3}$$

$$2o_{ij}\leqslant h_i+h_j\qquad i,j=1,2,\cdots,n \tag{4}$$

$$o_{ij}p_i\leqslant R\qquad i,j=1,2,\cdots,n \tag{5}$$

$$o_{ij}q_i \leqslant Q \qquad i,j=1,2,\cdots,n \tag{6}$$

$$\sum_{j'=1}^{n} o_{ij}d_{ij} - 10\,000\left(1-b_{ij}\right) \geqslant D \qquad i,j=1,2,\cdots,n \tag{7}$$

3）无人机访问相邻节点的到达时间关系，在规定的出发时间出发后，必须在规定时间内通过动态空域限制区：

$$t_i + d_{ij}/v - 10\,000\left(1-o_{ij}\right) \geqslant t_j \qquad i,j=1,2,\cdots,n \tag{8}$$

$$t_i + d_{ij}/v + 10\,000\left(1-o_{ij}\right) \leqslant t_j \qquad i,j=1,2,\cdots,n \tag{9}$$

$$t_i^s \leqslant t_i \leqslant t_i^e \qquad i=1,2,\cdots,n \tag{10}$$

$$t_s = T_S \tag{11}$$

4）无人机的性能约束，包括水平转向角和垂直俯仰角等要求：

$$o_{ij}\phi_{ij} \leqslant \phi_{\max} \qquad i,j=1,2,\cdots,n \tag{12}$$

$$o_{ij}\varphi_{ij} \leqslant \varphi_{\max} \qquad i,j=1,2,\cdots,n \tag{13}$$

5）2个决策变量的取值范围：

$$o_{ij} \in \{0,1\} \qquad t_i \in \mathbf{Z}^+ \tag{14}$$

2 求解无人机三维航迹的MSGOA

2.1 高尔夫优化算法

高尔夫优化算法(golf optimization algorithm, GOA)是Montazeri等于2023年提出的一种元启发式群智能优化算法[18]，主要模拟高尔夫运动中观察到的球员行为，具有结构简单、调优参数少和易于实现等优点，已经被应用在能源[18]、调度[19]等领域，尚未被应用在无人机三维航迹规划中。

2.1.1 解编码

在GOA中，高尔夫球员的位置表示问题的解。本文采用球形坐标体系对解向量进行编码，不仅可以描述无人机从某个点到下一个点的运动轨迹，也可以解决运动轨迹中相邻节点的转向角和俯仰角的平滑成本问题。与传统的直角坐标体系相比，该方式生成的解质量更高，球形坐标与直角坐标的转换关系如下：

$$x_{ij} = x_{i,j-1} + \rho_{ij}\sin\psi_{ij}\cos\lambda_{ij} \tag{15}$$

$$y_{ij} = y_{i,j-1} + \rho_{ij}\sin\psi_{ij}\sin\lambda_{ij} \tag{16}$$

$$z_{ij} = z_{i,j-1} + \rho_{ij}\cos\psi_{ij} \tag{17}$$

式中：ρ为径向距离；ψ为极角；λ为方位角。利用目标函数评估每个高尔夫球员的位置好坏，从而确定最佳球员。

2.1.2 种群初始化

在GOA中，高尔夫球员的种群多样性决定算法收敛速度和精度。引入Sine映射随机生成初始种群的任意个体$\boldsymbol{X}_i=(x_{i,1},x_{i,2},\cdots,x_{i,n+1})$，不仅改善了高尔夫球员位置的边缘聚集情况，而且使得球员在非边缘地区的位置更加均匀，扩大了算法的搜索范围，提高了算法的搜索效率。Sine映射如下：

$$N_c(d+1) = t\sin(\pi N_c(d)) \tag{18}$$

式中：t取1.9。

由于随机生成的个体$\boldsymbol{X}_i$可能不满足式(3)～式(8)、式(11)的各种限制区、式(12)和式(13)的无人机性能等现实约束，基于式(18)和球员i的第d维度变量边界$x_{i,d}^{\mathrm{L}}$和$x_{i,d}^{\mathrm{U}}$不断反复生成一个可行变量$x_{i,d}=x_{i,d}^{\mathrm{L}}+N_c(d)(x_{i,d}^{\mathrm{U}}-x_{i,d}^{\mathrm{L}})$组成可行个体$\boldsymbol{X}_i$，直至找到组成种群的全部可行个体。

2.1.3 球员的位置更新

在GOA中，当种群产生后，根据探索和开发2个阶段更新球员的位置，具体如下：

1）在探索阶段，模拟球员对球的最强击球，使用式(19)计算每个高尔夫球员的新位置。若新位置比原先的位置好，根据式(20)替换球员之前的位置。此外，在式(19)中使用参数I模拟球员可能会在球经过洞或接近洞的地方击球。如$I=1$，表示球接近球洞；否则，$I=2$，表示增加球移动的距离以搜索不同区域，增加GOA的全局探索能力。

$$\boldsymbol{X}_i^{\mathrm{P1}} : \boldsymbol{X}_{i,d}^{\mathrm{P1}} = x_{i,d} + r\left(B_d - I x_{i,d}\right) \tag{19}$$

$$\boldsymbol{X}_i = \begin{cases} \boldsymbol{X}_i^{\mathrm{P1}} & F_i^{\mathrm{P1}} < F_i \\ \boldsymbol{X}_i & \text{其他} \end{cases} \tag{20}$$

式中：$\boldsymbol{X}_i^{\mathrm{P1}}$为基于探索阶段的第$i$个高尔夫球员的更新状态；$\boldsymbol{X}_{i,d}^{\mathrm{P1}}$为此球员的第$d$维度；$F_i^{P1}$为目标函数值；$B$为最佳的高尔夫球员；$B_d$为此球员的第$d$维度；$r$为区间[0,1]内的随机数；$I$为从集合{1,2}随机选取的数。

2）在开发阶段，模拟球员用较小的力量推杆把高尔夫球打入果岭区的球洞，使用式(21)计算每个高尔夫球员的新位置，增强GOA的局部搜索能力。同上，若其新位置比原先的位置好，根据式(22)替换球员之前的位置。

$$\boldsymbol{X}_i^{\mathrm{P2}} : \boldsymbol{X}_{i,d}^{\mathrm{P2}} = x_{i,d} + (1-2r)[lb_d + r(ub_d - lb_d)]/t \tag{21}$$

$$\boldsymbol{X}_i = \begin{cases} \boldsymbol{X}_i^{\mathrm{P2}} & F_i^{\mathrm{P2}} < F_i \\ \boldsymbol{X}_i & \text{其他} \end{cases} \tag{22}$$

式中：$\boldsymbol{X}_i^{\mathrm{P2}}$为开发阶段的第$i$个高尔夫球员的新计算位置；$\boldsymbol{X}_{i,d}^{\mathrm{P2}}$为球员的第$d$维度；$F_i^{\mathrm{P2}}$为目标函数值；$t$为迭代次数。

2.2　改进策略

针对 GOA 的搜索区域分布不均、算法收敛精度低和易陷入局部最优等缺点, 将 GOA 与 piecewise 混沌映射、黄金正弦策略、柯西变异策略等相互融合, 具体过程如下。

2.2.1　piecewise 混沌映射

针对 GOA 在探索阶段的随机搜索无法遍历解空间的缺陷, 引入 Piecewise 混沌映射, 使每次迭代的探索步长更具有随机性和多样性, 从而提高找到全局最优解的概率。基于 Piecewise 混沌映射的高尔夫球员的位置更新式如下:

$$x_{i,d}=\begin{cases}x_{i,d}p & 0\leqslant x_{i,d}<p\\ (x_{i,d}-p)/(0.5-p) & p\leqslant x_{i,d}<0.5\\ (1-p-x_{i,d})/(0.5-p) & 0.5\leqslant x_{i,d}<1-p\\ (1-x_{i,d})/p & 1-p\leqslant x_{i,d}<1\end{cases}\tag{23}$$

式中: p 为控制参数, 取值 0.35 时效果较好。

2.2.2　黄金正弦策略

针对 GOA 的种群在探索阶段趋于同质化的缺陷, 利用黄金正弦算法对高尔夫球员的位置 $\boldsymbol{X}_i$ 进入扰动, 以找到更好的位置 $\boldsymbol{X}_i'$。基于黄金正弦策略的高尔夫球员的位置更新式如下:

$$\boldsymbol{X}_i'=\boldsymbol{X}_i|\sin r_1|+r_2\sin r_2(c_1\boldsymbol{B}-c_2\boldsymbol{X}_i)\tag{24}$$

式中: r_1 和 r_2 分别为取值 [0,2π] 和 [0,π] 的随机数, 表示下一代个体移动的距离和方向; c_1 和 c_2 为黄金分割参数, 用来缩小搜索空间, 引导个体向最优值收敛; B 为最优个体位置。黄金分割参数 c_1 和 c_2 使用式(25)和式(26)设置:

$$c_1=a(1-\mu)+b\mu\tag{25}$$

$$c_2=a\mu+b(1-\mu)\tag{26}$$

式中: a 取 $-\pi$; b 取 π; μ 为黄金分割数, 近似等于 0.618。

2.2.3　柯西变异策略

针对 GOA 在开发阶段易陷入局部最优值的缺陷, 利用柯西分布函数对高尔夫球员的位置 $\boldsymbol{X}_i$ 进行扰动, 以获取新位置 $\boldsymbol{X}_i'$, 增加高尔夫球员位置的多样性, 扩大搜索空间, 避免陷入局部最优解。基于柯西变异策略的高尔夫球员的位置更新式如下:

$$\boldsymbol{X}_i'=\boldsymbol{X}_i+\boldsymbol{X}_i\mathrm{Cauchy}(0,1)\tag{27}$$

式中: $\boldsymbol{X}_i'$ 为更新后高尔夫球员的位置。柯西分布函数可以采用以原点为中心的一维柯西变异函数:

$$\mathrm{Cauchy}(x)=\frac{1}{\pi}\left(\frac{1}{x^2+1}\right)\qquad -\infty<x<\infty\tag{28}$$

2.3　MSGOA 流程

MSGOA 的流程如图 1 所示。

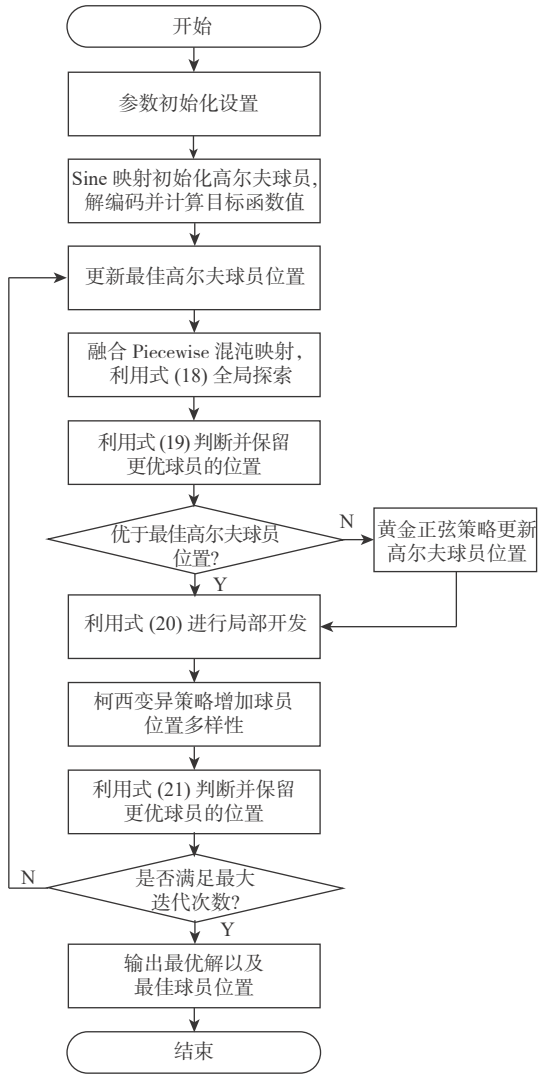


图 1　MSGOA 流程

Fig. 1　Flow chart of MSGOA

3　算法性能测试与分析

为验证改进算法的性能, 将本文改进的 MSGOA 与标准 GOA、蜣螂优化 (dung beetle optimization, DBO) 算法、灰狼优化 (grey wolf optimizer, GWO) 算法、粒子群优化 (particle swarm optimization, PSO) 算法和麻雀搜索算法(sparrow search algorithm, SSA)在基准测试函数上进行比较, 其种群数均设为 50, 迭代次数为 500 次。仿真环境采用 Windows11 64 bit 操作系统, 其中, 内存为 16 GB, CPU 为 Intel(R) Core(TM) i7-11800H @ 2.30 GHz, 仿真软件为 MATLAB R2021b。

3.1　测试函数及参数设置

实验选取了 10 种基准测试函数, 其维度、定义域和最优值如表 1 所示, 其中, F_1～F_3 为单峰测试函数, 主要用于测试算法的局部搜索能力, F_4～F_{10} 为多峰测试函数, 主要用来测试算法的全局搜索和跳出局部最优的能力。为降低实验结果的偶然性、

增加其说服力，将不同算法在这些测试函数上独立运行30次，计算其最优值、标准差和平均值，其中，第1项指标验证算法的勘探性能，后2项指标评估算法的收敛精度和稳定性。

表1 测试函数

Table 1 Test functions

函数类别	序号	函数名称	维度	定义域	最优值
单峰测试函数	F_1	Shifted and Rotated Bent Cigar Function	20	[−100,100]	0
	F_2	Shifted Schwefel's Problem 1.2	30	[−10,10]	0
	F_3	Shifted Schwefel's Problem 1.2 with Noise in Fitness	30	[−100,100]	0
多峰测试函数	F_4	Hybrid Function 1(N=3)	20	[−100,100]	0
	F_5	Composition Function 1 (N=4)	20	[−100,100]	0
	F_6	Composition Function 2 (N=4)	20	[−100,100]	0
	F_7	Shifted Rotated Griewank's Function without Bounds	30	[−1.28,1.28]	0
	F_8	Expanded Extended Griewank's plus Rosenbrock's Function	30	[−50,50]	0
	F_9	Hybrid Composition Function	4	[−5,5]	0.000 307 5
	F_{10}	Rotated Hybrid Composition Function	4	[0,10]	−10.153 199 679

3.2 测试函数结果比较

不同算法的对比实验结果如表2～表4所示。MSGOA算法求解10个测试函数的最优值、平均值和标准差均优于或等于其他算法，其中：①在单峰函数方面，MSGOA求解F_1～F_3的最优值、标准差和平均值均为0，说明开发阶段使用柯西变异策略极大增强了算法的局部探索能力。虽然SSA也能收敛到理论最优值0，但其平均值和标准差均不为0，说明SSA的稳定性不如MSGOA。②在多峰函数中，与多数算法相比，MSGOA的最优值均能达到最好，达到了10次方数量级以上的优化效果，说明算法初始化阶段的Sine映射及探索阶段融合Piecewise混沌映射和黄金正弦策略，极大增强了算法全局探索能力，有效避免了陷入局部最优。③比较这6种算法求解F_1～F_{10}的标准差，除F_9外，MSGOA均排名第1，这说明MSGOA具有极强的稳定性。

3.3 收敛曲线及箱线图分析

不同算法求解10个测试函数的箱线图如图2所示。各个算法求解不同测试函数的平均值及标准差如表3和表4所示，MSGOA均小于其他算

表2 MSGOA与经典优化算法最优值对比

Table 2 Comparison of MSGOA and classical optimization algorithms for optimal values

算法	最优值									
	F_1	F_2	F_3	F_4	F_5	F_6	F_7	F_8	F_9	F_{10}
MSGOA	0	0	0	0	0	0	4.95×10^{-7}	1.35×10^{-32}	3.08×10^{-4}	10.2
GOA	5.34×10^{-332}	2.57×10^{-162}	4.80×10^{-161}	6.16×10^{-300}	0	0	5.19×10^{-7}	1.35×10^{-32}	3.08×10^{-4}	10.2
DBO	5.82×10^{-161}	8.13×10^{-82}	5.71×10^{-86}	2.59×10^{-154}	7.43×10^{-176}	2.41×10^{-4}	2.71×10^{-4}	4.65×10^{-9}	3.08×10^{-4}	10.2
GWO	3.04×10^{-40}	1.41×10^{-20}	1.67×10^{-9}	2.71×10^{-21}	1.78×10^{-14}	51.20	6.71×10^{-5}	9.60×10^{-2}	3.07×10^{-4}	10.2
PSO	6.23	1.11×10^{-2}	3.29	1.62×10^{2}	4.27×10^{-3}	49.20	4.32×10^{-4}	3.06×10^{-3}	3.07×10^{-4}	10.2
SSA	0	0	0	0	0	0	5.81×10^{-5}	1.91×10^{-15}	3.07×10^{-4}	10.2

表3 MSGOA与经典优化算法标准差对比

Table 3 Comparison of MSGOA and classical optimization algorithms for standard deviation

算法	标准差									
	F_1	F_2	F_3	F_4	F_5	F_6	F_7	F_8	F_9	F_{10}
MSGOA	0	0	0	0	0	0	1.18×10^{-5}	5.57×10^{-48}	1.71×10^{-5}	1.58×10^{-2}
GOA	0	3.70×10^{-155}	2.73×10^{-150}	0	0	0	1.48×10^{-5}	5.57×10^{-48}	6.41×10^{-5}	2.22
DBO	3.04×10^{-101}	3.17×10^{-53}	6.75×10^{-55}	7.57	1.44×10^{-95}	34.40	9.67×10^{-4}	6.15×10^{-2}	3.63×10^{-4}	2.75
GWO	2.72×10^{-37}	4.28×10^{-20}	1.92×10^{-8}	2.30	8.54×10^{-15}	14.50	3.31×10^{-4}	1.88×10^{-1}	8.96×10^{-3}	2.06
PSO	2.53×10^{3}	1.58×10^{-2}	1.19	1.84×10^{4}	8.31×10^{-1}	14.80	1.32×10^{-3}	6.37×10^{-2}	3.65×10^{-3}	3.30
SSA	4.45×10^{-117}	4.76×10^{-74}	4.00×10^{-74}	3.62×10^{-18}	1.85×10^{-91}	1.85×10^{-12}	3.88×10^{-4}	1.51×10^{-10}	7.70×10^{-5}	1.29

表 4　MSGOA 与经典优化算法平均值对比

Table 4　Comparison of MSGOA and classical optimization algorithms for average values

算法	平均值									
	F_1	F_2	F_3	F_4	F_5	F_6	F_7	F_8	F_9	F_{10}
MSGOA	0	0	0	0	0	0	1.26×10^{-5}	1.35×10^{-32}	3.19×10^{-4}	−10.10
GOA	1.55×10^{-304}	7.13×10^{-156}	5.62×10^{-151}	2.84×10^{-251}	8.76×10^{-300}	1.19×10^{-285}	1.76×10^{-5}	1.35×10^{-32}	3.61×10^{-4}	−5.06
DBO	5.57×10^{-102}	5.81×10^{-54}	1.24×10^{-55}	2.16	2.62×10^{-96}	64.10	1.59×10^{-3}	6.32×10^{-2}	7.93×10^{-4}	−2.63
GWO	1.29×10^{-37}	5.45×10^{-20}	2.15×10^{-8}	1.55	2.49×10^{-14}	73.00	4.57×10^{-4}	3.79×10^{-1}	5.77×10^{-3}	5.06
PSO	7.35×10^{2}	3.35×10^{-2}	5.74	5.27×10^{3}	2.46×10^{-1}	63.10	1.97×10^{-3}	9.89×10^{-2}	1.17×10^{-3}	2.63
SSA	8.12×10^{-118}	8.70×10^{-75}	7.31×10^{-75}	1.16×10^{-18}	4.23×10^{-92}	3.46×10^{-13}	4.53×10^{-4}	4.19×10^{-11}	3.27×10^{-4}	5.06

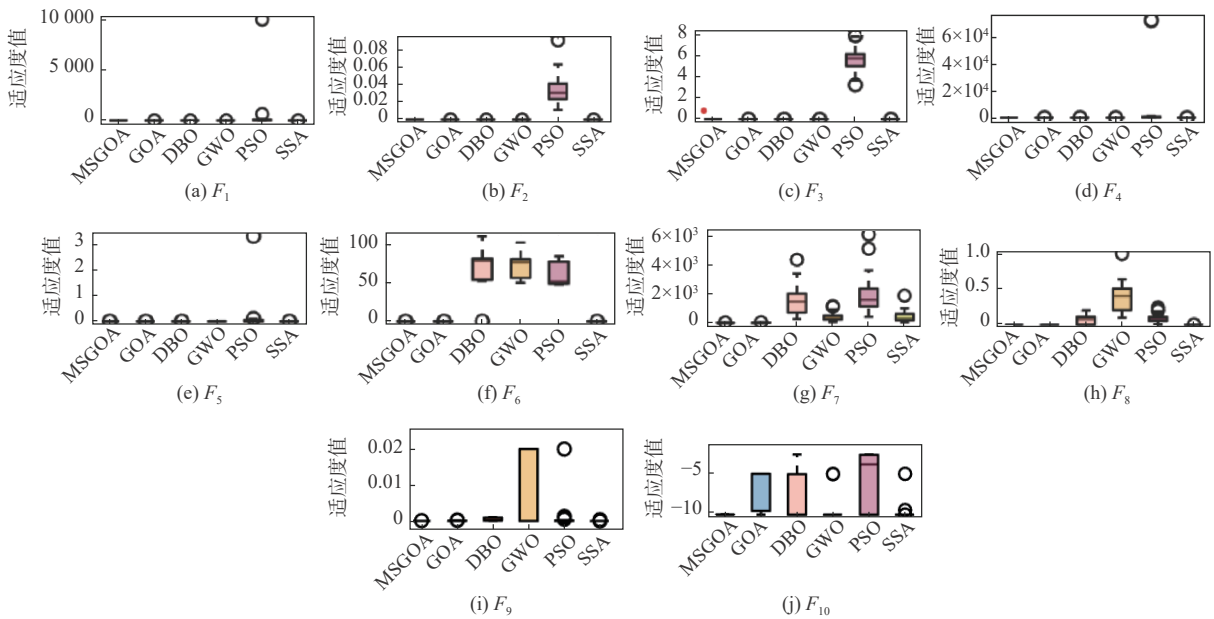


图 2　各算法箱线图

Fig. 2　Algorithms box plot

法, 说明其具有良好的寻优效果和稳定性。

3.4　Wilcoxon 秩和检验

如表 5 所示, 引入 Wilcoxon 秩和检验, 利用 p 值来验证改进后的 MSGOA 与其他 5 种算法是否具有显著差异性。若 $p<0.05$ 时, 2 种算法之间具有显著差异性。N/A 表示 2 种算法性能相当, 且为最优。“+/=/−”分别表示 MSGOA 在性能上“优于/相当/逊于”其他算法。由表 5 可知, MSGOA 在 F_1～F_{10} 的 p 值多数小于 0.05 且为“+”, 说明 MSGOA 比其他 5 种算法性能更优, 其中, MSGOA 与 GOA 在 F_5～F_8 的全局寻优上性能相当, 皆能取得最优值, MSGOA 与 GWO 在 F_9 与 F_{10} 的性能相当。

表 5　Wilcoxon 秩和检验的 p 值

Table 5　p value of Wilcoxon rank-sum test

算法	p值										+/=/−
	F_1	F_2	F_3	F_4	F_5	F_6	F_7	F_8	F_9	F_{10}	
GOA	1.21×10^{-12}	1.21×10^{-12}	1.21×10^{-12}	1.21×10^{-12}	N/A	2.98×10^{-11}	N/A	N/A	2.00×10^{-4}	2.87×10^{-10}	7/3/0
DBO	1.21×10^{-12}	1.21×10^{-12}	1.21×10^{-12}	1.21×10^{-12}	3.02×10^{-11}	2.98×10^{-11}	3.02×10^{-11}	1.21×10^{-12}	1.85×10^{-8}	N/A	9/1/0
GWO	1.21×10^{-12}	1.21×10^{-12}	1.21×10^{-12}	1.21×10^{-12}	1.55×10^{-11}	2.98×10^{-11}	3.02×10^{-11}	1.21×10^{-12}	N/A	N/A	8/2/0
PSO	1.21×10^{-12}	1.21×10^{-12}	1.21×10^{-12}	1.21×10^{-12}	3.02×10^{-11}	2.98×10^{-11}	3.02×10^{-11}	1.21×10^{-12}	N/A	7.73×10^{-3}	9/1/0
SSA	4.57×10^{-12}	5.77×10^{-11}	6.25×10^{-10}	5.77×10^{-11}	8.48×10^{-9}	8.39×10^{-9}	3.02×10^{-11}	1.21×10^{-12}	8.48×10^{-9}	8.26×10^{-8}	10/0/0

4　无人机三维航迹仿真测试

以 30 m 分辨率的香港 DEM 地图为例, 障碍物环境如表 6 所示, 涉及 5 个普通障碍物、1 个动态限制区和 3 个无线电干扰源, 其无人机坠落风险参考文献 [14] 进行计算。无人机的飞行速度为 19.5 km/h,

表 6 障碍物环境

Table 6 Environmental limitation parameter

序号	坐标/m	半径/km	类型	备注
1	[400,500,0]	1.50	普通障碍物	
2	[600,200,0]	1.20	普通障碍物	
3	[500,350,0]	1.50	普通障碍物	
4	[300,850,0]	1.35	普通障碍物	
5	[1 000,950,0]	1.05	普通障碍物	
6	[790,1 030,0]	2.55	动态限制区	限制通行时间: 6:00—8:00
7	[766,914,0]		无线电	干扰强度值为60
8	[387,267,0]		无线电	干扰强度值为35
9	[459,874,0]		无线电	干扰强度值为85

任务起讫点坐标分别为(200,100,150)和(916,1 225,100), 无线电干扰阈值 R 为 8.5 dB, 坠落风险阈值 Q 为 200, 预计出发时间为 6:00。此外, 设置 4 个成本目标函数的权重分别为 100、80、120 和 50, 水平转向角和垂直俯仰角的惩罚系数 a、b 均为 50。

计算的最佳无人机航迹如图 3 所示。通过计算, 无人机需要延误时间 24 min 出发(即 6:24 出发)才可以避开动态限制区, 经过 124 min, 飞行里程 40.4 km 到达目标点, 飞行总成本值为 24 635, 其中, 航迹长度权重成本为 9 982, 障碍物威胁权重成本为 7 264, 飞行高度权重成本为 3 610, 平滑权重成本为 3 779。

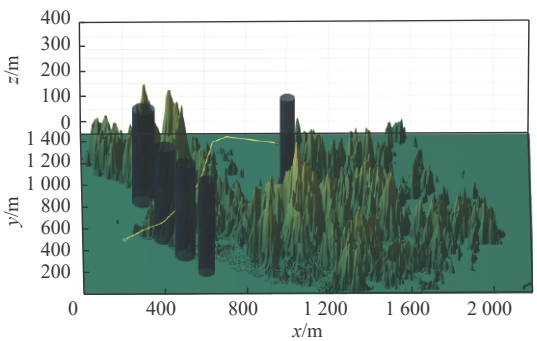


图 3 最佳航迹的三维可视化图

Fig. 3 3D visualization of the optimal path

此外, 进一步分析有无延误时间、无线电干扰阈值 R 和坠落风险阈值 Q 对航迹的影响, 如图 4～图 6 所示。由图可知:

1) 图 4 对比有无延误时间的无人机航迹差异。若按传统模型的固定计划时间出发(即 6:00 出发), 无人机则在 7:41 接近动态限制区, 经过绕行在 8:27 到达目标点, 飞行里程为 47.7 km。与可以推迟出发时间的本模型相比, 无人机的飞行时间增加 18.5%, 飞行里程增加 18.1%, 飞行总成本值增加 22.1%。

2) 图 5 对比在无线电干扰安全阈值 R 为 8.5 dB 和 4.5 dB 下的无人机航迹差异。随着 R 的降低, 为避免无人机飞行受到无线电干扰, 其必然绕飞避开无线电干扰区, 从而导致总航迹里程增加约 19.2%, 总航迹成本值增加约 13.7%。

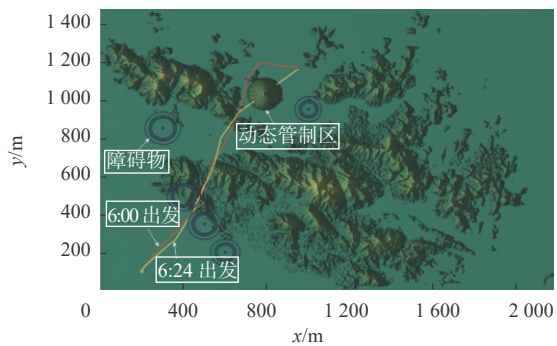


图 4 有无延误时间的无人机航迹对比

Fig. 4 Path comparison of with or without delay time

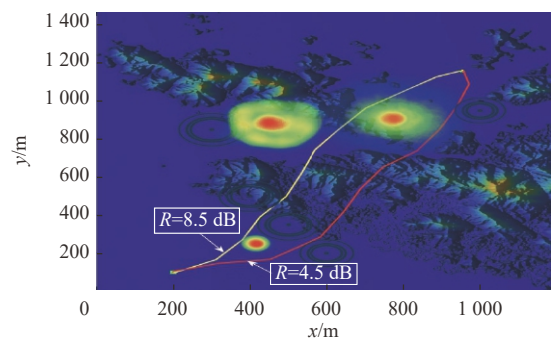


图 5 不同无线电干扰阈值的航迹对比

Fig. 5 Path comparison of different radio interference thresholds

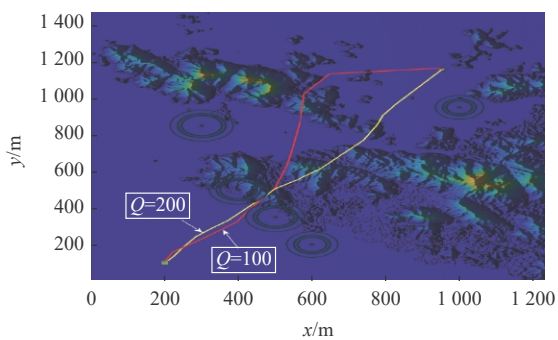


图 6 不同坠落风险阈值的航迹对比

Fig. 6 Path comparison of different fall risk thresholds

3) 图 6 对比在坠落风险阈值 Q 为 200 和 100 下的无人机航迹差异。与图 5 类似, 随着 Q 的降低, 为避免无人机在高坠落风险内飞行, 必然绕飞高风险坠地区域, 从而导致总航迹里程增加约 17.4%, 总航迹成本值增加约 12.5%。

将本文 MSGOA 与 5 种群智能算法求解无人机三维航迹规划模型, 实验结果如图 7、图 8 和表 7 所示, 从中可知: ①MSGOA 利用 Sine 映射初始种群, 加快算法收敛速度, 其收敛迭代次数远小于其他算法; ②MSGOA 在探索阶段融合 Piecewise 混沌映射和黄金正弦策略, 有利于算法早期跳出局部最优解和后期拓展解的搜索空间, 保持群体多样性, 从而克服了算法陷入局部最优的问题; ③MSGOA 在开发阶段使用柯西变异策略提高了算法后期寻优精度, 其规划的航迹长度权重成本远低于其他算法。

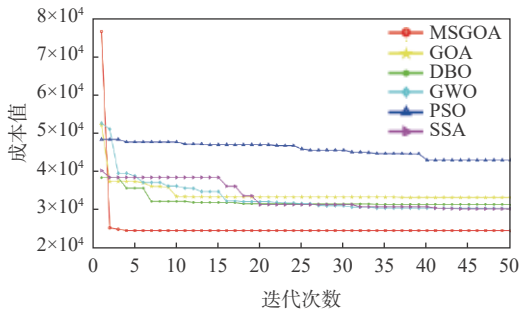


图 7　不同算法求解无人机航迹的迭代曲线差异

Fig. 7　Iterative curve of different algorithms for solving UAV path

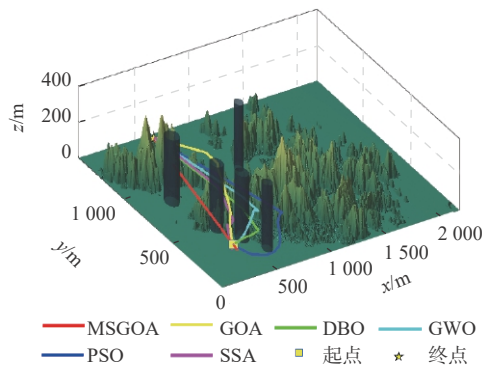


图 8　不同算法求解无人机航迹的三维可视化图

Fig. 8　Three-dimensional visualization of different algorithms for solving UAV path

表 7　不同算法求解无人机航迹的性能差异

Table 7　Performance of different algorithms for solving UAV path

算法	平均迭代次数	平均总成本值	MSGOA总成本值占比/%	MSGOA收敛迭代次数占比/%	航迹长度成本	障碍物威胁成本	飞行高度成本	平滑成本
MSGOA	4	24 548	100.0	100.0	9 819	7 364	3 562	3 803
GOA	10	33 268	73.8	40.0	13 307	9 871	5 012	5 078
DBO	7	31 335	78.3	57.1	12 412	9 536	4 734	4 653
GWO	31	30 262	81.1	12.9	12 845	8 943	4 521	3 953
PSO	40	43 019	57.1	10.0	17 440	11 876	7 012	6 691
SSA	32	30 169	81.4	12.5	12 554	9 032	4 613	3 970

5　结　论

本文建立考虑动态限制区、无线电干扰、障碍物、无人机性能等多重安全因素的无人机三维航迹规划模型, 并设计求解该问题的 MSGOA。将本文算法与 5 种主流算法通过 10 个测试函数进行比较, 从多个角度验证了 MSGOA 的不同改进策略的有效性。以中国香港的 DEM 地图为例, 比较不同算法求解无人机三维航迹规划的性能差异, 从而证明 MSGOA 的实践性。研究表明:

1) 本文模型可以精确计算无人机在复杂环境下的航迹, 在避障基础上, 同时满足避免其在规定时间内到达动态限制区, 以及访问每个位置的无线电干扰威胁。随着这些限制条件收紧, 无人机的航迹里程增加, 但是其路径安全可靠, 计算结果符合实际。

2) 本文 MSGOA 利用 Sine 映射初始种群, 探索阶段融合 Piecewise 混沌映射和黄金正弦策略, 开发阶段使用柯西变异策略。与其他群智能算法相比, MSGOA 拥有更好的收敛速度、全局探索能力及局部寻优能力, 并在三维无人机航迹规划问题中能够规划更好的路径。

本文不足之处包括: ①未涉及多架无人机路径之间冲突解脱问题; ②未将无人机的三维轨迹规划与物流配送线路规划集成为一体; ③没有考虑无人机的控制性能与航迹之间关系。因此, 探索基于 MSGOA 的多目标无人机物流配送线路、三维航迹和控制协同优化问题, 这将是未来的研究方向。

参考文献 (References)

[1] 张建行, 康凯, 钱骅, 等. 面向物联网的深度 Q 网络无人机路径规划[J]. 电子与信息学报, 2022, 44(11): 3850-3857.
Zhang J H, Kang K, Qian H, et al. UAV trajectory planning based on deep Q-network for internet of things[J]. Journal of Electronics & Information Technology, 2022, 44(11): 3850-3857(in Chinese).

[2] Chen J C, Ling F Y, Zhang Y, et al. Coverage path planning of heterogeneous unmanned aerial vehicles based on ant colony system [J]. Swarm and Evolutionary Computation, 2022, 69: 101005.

[3] Liu X X, Su Y Z, Wu Y, et al. Multi-conflict-based optimal algorithm for multi-UAV cooperative path planning[J]. Drones, 2023, 7(3): 217.

[4] 朱孝山, 刘伟伟. 融合多策略改进黑猩猩优化算法的 UAV 航迹规划[J]. 电光与控制, 2024, 31(8): 50-57.
Zhu X S, Liu W W. Path planning for UAVs based on multi-strategy improved chimp optimization algorithm[J]. Electronics Optics & Control, 2024, 31(8): 50-57(in Chinese).

[5] 隋东, 杨振宇, 丁松滨, 等. 基于 EMSDBO 算法的无人机三维航迹规划[J]. 系统工程与电子技术, 2024, 46(5): 1756-1766.
Sui D, Yang Z Y, Ding S B, et al. Three-dimensional path planning of UAV based on EMSDBO algorithm[J]. Systems Engineering and Electronics, 2024, 46(5): 1756-1766(in Chinese).

[6] 王康, 司鹏, 陈莉, 等. 基于改进沙猫群算法的无人机三维航迹规划[J]. 兵工学报, 2023, 44(11): 3382-3393.
Wang K, Si P, Chen L, et al. 3D path planning of unmanned aerial vehicle based on enhanced sand cat swarm optimization algorithm [J]. Acta Armamentarii, 2023, 44(11): 3382-3393(in Chinese).

[7] 闫少强, 杨萍, 刘卫东, 等. 基于 GPSSA 算法的复杂地形多无人机航迹规划[J]. 北京航空航天大学学报, 2025, 51(1): 303-313.
Yan S Q, Yang P, Liu W D, et al. Multi-UAV trajectory planning for complex terrain based on GPSSA algorithm[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(1): 303-313(in Chinese).

[8] 王兴旺, 张清杨, 姜守勇, 等. 基于改进鲸鱼优化算法的动态无人机路径规划[J]. 计算机应用, 2025, 45(3): 928-936.
Wang X W, Zhang Q Y, Jiang S Y, et al. Dynamic UAV path planning based on modified whale optimization algorithm[J]. Journal of Computer Applications, 2025, 45(3): 928-936(in Chinese).

[9] Yu X B, Jiang N J, Wang X M, et al. A hybrid algorithm based on grey wolf optimizer and differential evolution for UAV path planning[J]. Expert Systems with Applications, 2023, 215: 119327.

[10] Yu X B, Luo W G. Reinforcement learning-based multi-strategy cuckoo search algorithm for 3D UAV path planning[J]. Expert Systems with Applications, 2023, 223: 119910.

[11] 匡银虎, 张虹波. 基于物联网的多无人机协作能耗控制算法仿真[J]. 计算机仿真, 2023, 40(2): 454-458.
Kuang Y H, Zhang H B. Simulation of multi-UAV cooperative energy consumption control algorithm based on internet of things[J]. Computer Simulation, 2023, 40(2): 454-458(in Chinese).

[12] 汪瀚洋, 陈亮, 徐海, 等. 基于 MOEA/D-ARMS 的无人机在线航迹规划[J]. 系统工程与电子技术, 2022, 44(11): 3505-3514.
Wang H Y, Chen L, Xu H, et al. UAV online trajectory planning based on MOEA/D-ARMS[J]. Systems Engineering and Electronics, 2022, 44(11): 3505-3514(in Chinese).

[13] 李波, 屈原, 郝巧梅, 等. 基于 DMPC-PSO 动态威胁下的多 UAV 在线航迹规划[J]. 内蒙古大学学报 (自然科学版), 2023, 54(5): 509-518.
Li B, Qu Y, Hao Q M, et al. Multiple unmanned aerial vehicles online route planning under dynamic threat based on DMPC-PSO[J]. Journal of Inner Mongolia University (Natural Science Edition), 2023, 54(5): 509-518(in Chinese).

[14] 魏明, 孙雅茹, 孙博, 等. 基于深度强化学习的无人机线路及航迹协同规划[J]. 中国安全科学学报, 2023, 33(8): 68-76.
Wei M, Sun Y R, Sun B, et al. UAV distribution route and flight path collaborative planning based on deep reinforcement learning [J]. China Safety Science Journal, 2023, 33(8): 68-76(in Chinese).

[15] 魏明, 孙雅茹, 孙博, 等. 带软时间窗的多调度中心 UAV 安全运输线路和航迹协同规划[J]. 北京航空航天大学学报, 2025, 51(10): 3233-3242.
Wei M, Sun Y R, Sun B, et al. Cooperative planning for safe transportation routes and flight paths of UAV with multiple dispatching centers and soft time windows[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(10): 3233-3242(in Chinese).

[16] 王飞, 杨清平. 面向多无人机物流配送的双层任务规划方法[J]. 北京航空航天大学学报, 2026, 52(1): 94-103.
Wang F, Yang Q P. Two-layer task planning method for multi-UAV logistics distribution[J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(1): 94-103(in Chinese).

[17] 王东振, 张岳, 赵宇, 等. 基于 RRT-Dubins 的无人机航迹优化方法[J]. 兵工学报, 2024, 45(8): 2761-2773.
Wang D Z, Zhang Y, Zhao Y, et al. A UAV trajectory optimization method based on RRT-Dubins[J]. Acta Armamentarii, 2024, 45(8): 2761-2773(in Chinese).

[18] Montazeri Z, Niknam T, Aghaei J, et al. Golf optimization algorithm: a new game-based metaheuristic algorithm and its application to energy commitment problem considering resilience[J]. Biomimetics, 2023, 8(5): 386.

[19] Al-Baik O, Alomari S, Alssayed O, et al. Pufferfish optimization algorithm: a new bio-inspired metaheuristic algorithm for solving optimization problems[J]. Biomimetics, 2024, 9(2): 65.

Three-dimensional path planning of UAVs based on multi-strategy golf optimization algorithm

SUN Bo[1, 2], ZHANG Wenpeng[2], WU Zexuan[2], SU Yebo[2], WEI Ming[1, 2, *]

(1. Key Laboratory of Wide-Area Surveillance and Safety Control Technology of Civil Aviation Flights, Civil Aviation University of China, Tianjin 300300, China;
2. College of Air Traffic Management, Civil Aviation University of China, Tianjin 300300, China)

Abstract: This paper establishes a mathematical model for the three-dimensional path planning problem of a UAV to determine the unmanned aerial vehicle(UAV) trajectory and the actual departure time to minimize the total cost of path length, flight height, threat, and smoothing. This model also takes into account a number of limitations, including obstructions, radio interference, dynamic limited areas, UAV performance, and other elements. A multi-strategy golf optimization algorithm (MSGOA) is designed to solve this problem. Sine mapping is used to generate more diverse initial populations. In the exploration phase of the algorithm, Piecewise chaotic mapping and golden sine strategy are integrated to expand the global exploration capability of the algorithm. In the development stage of the algorithm, the Cauchy variation strategy is used to increase the local optimization ability of the algorithm. The improved algorithm is compared with other five mainstream swarm intelligence algorithms on 10 standard test functions to prove the effectiveness of MSGOA. In order to demonstrate the superiority of the model and algorithm, the impact of various factors on the optimal 3D flight route of UAVs is examined, and the performance differences of several algorithms on this topic are compared, using the digital elevation model (DEM) of Hong Kong, China as an example.

Keywords: unmanned aerial vehicle; three-dimensional path planning; golf optimization algorithm; chaotic mapping; golden sine algorithm; Cauchy mutation

Received: 2024-06-13; **Accepted**: 2024-08-16; **Published Online**: 2024-09-25 12:03

URL: link.cnki.net/urlid/11.2625.V.20240924.1536.004

Foundation items: Open Fund for the Key Laboratory of Wide-Area Surveillance and Security Control Technology of Civil Aviation Flights (202203,202205); Humanities and Social Science Project of Ministry of Education (20YJCZH176)

* **Corresponding author**. E-mail: mwei@cauc.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0496

自由空域环境下多旋翼无人机进场三维航迹规划

王建忠*，梁飞达
(中国民航大学 空中交通管理学院，天津 300300)

摘 要：自由空域环境下，针对城市空间环境运行的多旋翼无人机(UAV)进场环节，提出一种考虑区域避拥堵的多旋翼无人机无冲突航迹规划方法，保证无人机安全高效进场运行，提高空域利用效率。对进场空间范围进行定义；采用栅格法对三维空间运行环境进行离散化处理，引入栅格占用时间概念，将无人机视为动态障碍物，构建以飞行时间最小为目标的无冲突航迹规划模型；设计基于三维拥堵权值地图的改进A*算法，求解避拥堵的多旋翼无人机飞行航迹；在不同障碍物环境下，面向10,15,20架无人机进场情景进行仿真分析。结果表明：在复杂障碍物环境下，与A*算法相比，改进算法在权重系数为0.4、0.6时增加0.96%的飞行时间即可减少52%的拥堵区域数量，优化效果明显，验证了所提模型和算法的可行性和有效性。

关 键 词：无人机；航迹规划；栅格占用时间；A*算法；拥堵权值地图
中图分类号：V279
文献标志码：A **文章编号**：1001-5965(2026)11-3824-08

随着低空空域的逐步开放和政策利好，中国低空经济迎来了快速发展的春天，特别是民用无人机产业发展迅猛，使得无人机在各领域的应用频率不断上升，扮演着越来越重要的角色。在航迹规划方面，多旋翼无人机(unmanned aerial vehicle, UAV)运行已经基于各种运行场景进行了研究，如城市物流配送[1]、河道巡检[2]、无人机巡逻[3]等。航迹规划是保障飞行效率和安全的关键，已经成为多旋翼无人机研究领域的热点，其核心思想是通过考虑无人机的飞行性能[4]、无人机与障碍物的最小安全距离[1]及飞行区域开放情况等因素，为无人机规划出最优或最满意的飞行航迹。

当前多旋翼无人机航迹规划研究主要集中在航路飞行阶段，航路阶段的航迹规划又可分为单机航迹规划和多机航迹规划两大类。单机航迹规划主要以最小化所需飞行时间、能量消耗[5]、航程距离[4]、运行风险[1,6]、噪声水平[1]等为目标，规划一条保证无人机可以更高效、安全、可接受的路径。而对于多机航迹规划则变得更加复杂，因为多架无人机必须协调它们的飞行以实现整体最优。在这些场景中，航迹规划不仅要考虑每架无人机的个体约束，还要考虑无人机之间的相互作用，包括协调、任务分配[7]、避免多机碰撞[8]等。而对于城市环境下多旋翼无人机进场阶段的研究主要集中于空域结构设计的进场控制，从空域结构设计来看，目前主要集中在环形空域结构设计[9]和路网结构的空域设计上[10]；从进场方式来看，主要包括3种，分别为水平进场垂直下降[11]、沿斜线进近[12-13]和基于环形结构运行[14-17]；从起降点设计来看，主要包括单起降点[14-15]、多起降点[10,16]；从运行速度来看，基于空域结构设计的模式，为更好地控制无人机进场运行，多旋翼无人机的飞行速度通常较为单一[9,14-15]。

综上可知，目前国内外对于无人机航迹规划主要存在以下不足：①无人机航迹规划主要集中在航

收稿日期：2024-07-01；录用日期：2024-09-20；网络出版时间：2024-10-11 16:43
网络出版地址：link.cnki.net/urlid/11.2625.V.20241010.2004.005
基金项目：天津市教委科研计划(2018KJ249)
*通信作者. E-mail：jz-wang@cauc.edu.cn

引用格式：王建忠，梁飞达. 自由空域环境下多旋翼无人机进场三维航迹规划[J]. 北京航空航天大学学报，2026，52(11)：3824-3831.
Wang J Z，Liang F D. Three-dimensional track planning for multi-UAV approach in free airspace environment[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3824-3831 (in Chinese).

路运行阶段, 对于无人机进场航迹规划也停留在空域结构设计下, 对自由空域环境下的进场运行却鲜有研究; ②大多数航迹规划研究针对航空器单一运行速度, 未充分考虑航空器选择不同飞行方向时的速度差异; ③现有航迹规划中对于航迹点周遭使用情况的考量仅停留在二维平面, 未能从三维空间角度入手。综上所述, 本文针对进场空间范围内多旋翼无人机航迹规划问题, 考虑多旋翼无人机在不同方向上的飞行速度, 明确记录各栅格占用时间, 构建以飞行时间最小为目标的无人机进场航迹规划模型, 设计基于三维拥堵权值地图的改进 A*算法进行求解, 得到一系列无冲突、避拥堵的进场航迹。

1　多旋翼无人机进场航迹规划问题建模

1.1　进场范围定义及问题描述

无人机飞行高度在 120 m 以下, 由于目前相关研究对无人机进场范围还没有统一的定义和描述, 文献 [9] 提出最大安全距离概念, 在给定环境下, 可利用在起降点周围控制障碍物距离减去缓冲余度来确定进场范围半径为 44.88 m。文献 [14] 通过考虑等待点之间的间隔和空域容量计算出在分支排队进场(branch-queuing approach, BQA)和基于顺序进场(sequence-based approach, SBA)2 种进场策略下的最优进场范围半径分别为 92.4 m 和 79.8 m。综上, 为方便进场空间栅格划分, 可将进场空间范围定为 120 m×120 m×120 m 的正方体区域。设某城市空间环境中建有无人机起降场, 无人机架次和进场位置已知, 机型为充电多旋翼式无人机, 无人机进场航迹规划问题即可表示为: 需要对某一时间段进场航空器进行无冲突航迹规划, 以确保多架次无人机安全、高效到达。

1.2　空间环境建模

1.2.1　城市空间环境表征

设 O 为原点建立空间直角坐标系, 无人机在长、宽、高分别为 X、Y、Z 的立方体进场空间环境运行, 将城市空域等分成 $n_x \times n_y \times n_z$ 个三维栅格。设栅格划分精度为 r, 则 $n_x = \mathrm{int}(X/r)$、$n_y = \mathrm{int}(Y/r)$、$n_z = \mathrm{int}(Z/r)$, int为取整函数。将 $B_{a,b,c}$ 表示为栅格中心点, 其中, a、b、c 分别表示其在 x 轴、y 轴和 z 轴方向上的序号, a=1,2,⋯,n_x, b=1,2,⋯,n_y, c=1,2,⋯,n_z。索引 $B_{a,b,c}$ 转换为坐标 $B(x,y,z)$, 其中, $x = ar$, $y = br$, $z = cr$。

针对城市空间环境中的静态障碍物, 采用二进制 0-1 来表示对应栅格空间是否被占用, 每个栅格状态信息表达式为

$$\mathrm{Occup}(B_{a,b,c}) = \begin{cases} 0 \\ 1 \end{cases} \tag{1}$$

式中: 0 表示未被占用, 1 表示被占用。

此外, 引入栅格占用时间概念, 以便更好地记录栅格的使用情况[8]。基于无人机的进场时刻和位置点, 在进行航迹规划的同时明确各栅格无人机使用时间, 将无人机作为动态障碍物, 对栅格使用状态进行动态更新。t 时刻的栅格 $B_{a,b,c}$ 状态信息则可以表示为

$$\mathrm{Occup}(B_{a,b,c},t) \begin{cases} 0 & t \in [T_{\mathrm{enter}}, T_{\mathrm{exit}}] \\ 1 & t \in [T_{\mathrm{enter}}, T_{\mathrm{exit}}] \end{cases} \tag{2}$$

式中: 0 表示未被占用; 1 表示被占用; T_{enter} 为栅格进入时间; T_{exit} 为栅格离开时间。

1.2.2　航迹节点扩展及飞行时间表征

航迹节点扩展即无人机在进行航迹规划时从当前点寻找下一个可选航迹点的过程。无人机可以从栅格的中心点沿着栅格的边、面对角线或沿体对角线飞行至下一可选航迹点, 可选航迹点共计 26 个, 航迹节点扩展如图 1 所示。

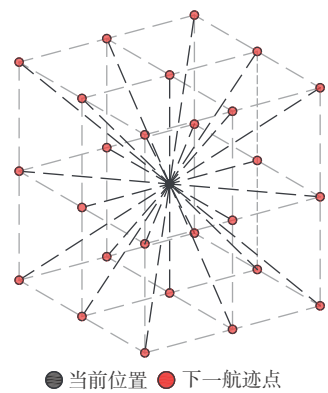


图 1　航迹节点扩展示意图

Fig. 1　Schematic diagram of track node expansion

以 x、y、z 轴的正方向为例, 存在 7 种不同飞行方向, 用向量可将移动方向分别标记为 $(x,0,0)$, $(0,y,0)$, $(0,0,z)$, $(x,y,0)$, $(0,y,z)$, $(x,0,z)$, (x,y,z)。考虑不同飞行方向移动速度的差异, 设置 5 种不同的飞行速度[18], 表示为

$$V = \{V_1, V_2, V_3, V_4, V_5\} \tag{3}$$

式中: V_1 为沿 x 轴方向最大飞行速度; V_2 为沿 y 轴方向最大飞行速度; V_3 为沿 z 轴方向最大飞行速度; V_4 为沿面对角线方向最大飞行速度; V_5 为沿体对角线方向最大飞行速度。

结合多旋翼无人机选定的下一个航迹点则可以确定其飞行方向、飞行速度和飞行距离, 则当前无人机在对应栅格内的运行时间可以表示为

$$T^u=\begin{cases}\dfrac{\left|B^u(x,y,z),B^{u+1}(x,y,z)\right|}{2V^{u,u+1}} & u=1\\ \dfrac{\left|B^{u-1}(x,y,z),B^u(x,y,z)\right|}{2V^{u-1,u}}+\dfrac{\left|B^u(x,y,z),B^{u+1}(x,y,z)\right|}{2V^{u,u+1}} & 1<u<n\\ \dfrac{\left|B^{u-1}(x,y,z),B^u(x,y,z)\right|}{2V^{u-1,u}} & u=n\end{cases} \tag{4}$$

式中：$\left|B^u(x,y,z),B^{u+1}(x,y,z)\right|$为2个航迹点之间的欧氏距离，$B^u(x,y,z)$为无人机所经过的第$u$个航迹点，当$u$=1和$u$=$n$时分别表示为进场点和着陆点。

无人机第u个航迹点的栅格进入和离开时间则可以表示为

$$T^u_{\text{enter}}=\begin{cases}T_{\text{approach}} & u=1\\ T_{\text{approach}}+\sum_{p=1}^{u-1}T^p & u>1\end{cases} \tag{5}$$

$$T^u_{\text{exit}}=T^u_{\text{enter}}+T^u \tag{6}$$

式中：T_{approach}为多旋翼无人机进场时间。

1.3 多旋翼无人机进场航迹规划模型

1.3.1 目标函数

本文将进场飞行时间最小作为目标，设无人机数量为N，其中，第i架无人机进场点坐标为$B_i^{(1)}(x,y,z)$，着陆点坐标为$B_i^{(n)}(x,y,z)$，则第i架无人机的目标函数为

$$F_i=\min\sum_{u=1}^{n}T_i^u \tag{7}$$

1.3.2 约束条件

1）进场飞行高度约束。无人机所处飞行高度会随着环境的变化而变化，但必须符合飞行高度标准，即

$$H_{\min}\leqslant H_i^u\leqslant H_{\max} \tag{8}$$

式中：H_i^u为第i架无人机在第u个航迹点的高度；$H_{\min}$和$H_{\max}$分别为飞行高度的下限和上限。

2）飞行范围约束。无人机飞行的航迹点集合都必须处于所指定的空间范围内，即

$$\begin{cases}x_i^u=ar & a=1,2,\cdots,n_x\\ y_i^u=br & b=1,2,\cdots,n_y\\ z_i^u=cr & c=1,2,\cdots,n_z\end{cases} \tag{9}$$

式中：(x_i^u,y_i^u,z_i^u)为第i架无人机的第u个航迹点实际坐标。

3）无人机与障碍物间隔约束。障碍物的大小决定了障碍物占据栅格的数量，由于在无人机进场航迹规划阶段，所经航迹点均不能穿越障碍物，且需与障碍物保持一定的安全间隔，则无人机需要与每个被占据栅格保持安全距离，即

$$\sqrt{\left(x_i^u-x_{\text{ob}}\right)^2+\left(y_i^u-y_{\text{ob}}\right)^2+\left(z_i^u-z_{\text{ob}}\right)^2}\geqslant D_{\min} \tag{10}$$

式中：$(x_{\text{ob}},y_{\text{ob}},z_{\text{ob}})$为障碍物所占据的栅格点实际坐标；$D_{\min}$为无人机与障碍物之间的最小安全距离。

4）无人机之间避撞约束。无人机进场空间环境中可能存在多架无人机，对任意2架航空器i、j，任意航迹点之间的距离均应保证大于安全距离：

$$\sqrt{\left(x_i^u-x_j^p\right)^2+\left(y_i^u-y_j^p\right)^2+\left(z_i^u-z_j^p\right)^2}\geqslant D_{\text{r}} \tag{11}$$

式中：(x_j^p,y_j^p,z_j^p)为第j架无人机的第p个航迹点坐标；D_{r}为无人机之间的最小安全距离。

2 多旋翼无人机进场航迹规划方法

对于多旋翼无人机进场航迹规划，需要在城市空间环境中搜索出每架无人机安全到达着陆点的航迹。A*算法通常用于无人机航迹规划中，通过计算起始点至扩展节点及扩展点至目标点的成本代价来规划合适的飞行航迹，其能够很好地解决在地图网格上寻找最优路径的问题。因此，本文在A*算法的基础上，面向三维空间环境，提出加入拥堵权值地图的改进A*算法（记为Weighted Map A*，简称WM-A*）。WM-A*算法主要通过获取前机的航迹规划结果进行拥堵权值地图更新，后续架次无人机在此基础上进行航迹规划，使得无人机在航迹规划时一定程度上避开拥堵区域，提高空域利用效率。航迹规划结果会随无人机航迹规划的顺序不同而变化，且所有可能规划的顺序数量是无人机进场规模的阶乘函数，具有高度复杂性，鉴于此，在算法里添加可变换顺序的时间间隔约束，即将进场时间间隔为Q（含）以内的无人机进行顺序调换，时间间隔的单位为s，适当减少考虑的进场顺序数量，降低算法计算的复杂性和运行时间，提高航迹规划结果的质量。本文算法流程如图2所示。

2.1 拥堵权值地图初始化和构建

二维的拥堵权值地图在无人机协同路径规划中有所使用，构建方法参考文献[19]。拥堵权值地图的基本原理是将栅格地图划分为m个拥堵检测区域。拥堵检测区域越小，航迹规划复杂度越高；反之，便会损失航迹规划质量。因此，拥堵检测区域需要权衡航迹规划的效率和质量，本文提出三维环境下的拥堵权值地图，拥堵检测区域划分方法如下：

1）确定拥堵检测区域体积。比例因子设定为λ，拥堵检测区域体积为LWH/λ^3，其中，L、W、H分别为进场范围的长、宽、高。

2）确定拥堵检测区域栅格数量。根据拥堵区域体积及栅格分辨率可以计算出每个拥堵检测区域包含栅格数量为$LWH/\left(\lambda^3r^3\right)$。

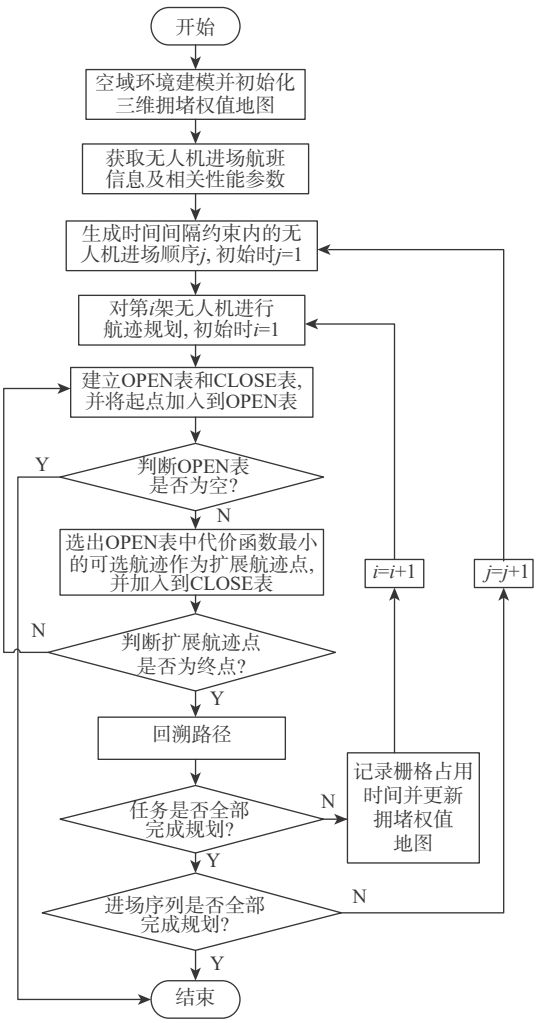


图 2　WM-A*算法流程

Fig. 2　Flow of WM-A* algorithm

3）拥堵检测区域编号规则。从栅格地图坐标轴开始，x、y、z 轴上分别按照从左到右、从前到后、从下到上的顺序为每个检测区域分配从 1 开始的连续整数作为区域编号。

拥堵权值地图构建完成后，将每个检测区域所对应的拥堵权值初始化为 0，之后每规划完成一架无人机的航迹便更新一次拥堵权值地图：记录规划完成的无人机航迹在每个检测区域的占有时间，并更新所对应拥堵权值。假设第 j 个拥堵检测区域（j=1,2,⋯,m）存在重复时间段，则将对应的拥堵权值进行叠加。拥堵权值的更新可表示为

$$M_j = M_j + 1 \tag{12}$$

2.2　航迹节点代价计算

在进行航迹节点扩展的过程中，计算无人机到达扩展航迹点的时间 t_d，查询该扩展航迹点所在拥堵检测区域的占有时间 $[t_h, t_f]$。若 t_d 在检测区域的占有时间 $[t_h, t_f]$ 内，则令 M 等于 $[t_h, t_f]$ 对应的拥堵权值。节点代价计算的评估函数表示为

$$f(u) = \omega_1 (g(u) + h(u)) + \omega_2 M \tag{13}$$

式中：$g(u)$ 为实际代价函数，表示进场航迹点 $B^{(1)}(x,y,z)$ 至扩展航迹点 $B^{(u)}(x,y,z)$ 的实际代价；$h(u)$ 为启发函数，表示扩展航迹点 $B^{(u)}(x,y,z)$ 至着陆点 $B^{(m)}(x,y,z)$ 的预估代价；ω_1 和 ω_2 分别为代价函数和拥堵权值的权重系数。

1）实际代价函数设计。为更精确地表示节点扩展中实际代价的计算，根据目标函数式（7）可知实际代价函数 $g(u)$ 为

$$g(u) = \sum_{p=1}^{u} T^p \tag{14}$$

式中：$g(u)$ 表示进场航迹点 $B^{(1)}(x,y,z)$ 至扩展航迹点 $B^{(u)}(x,y,z)$ 的实际飞行时间。

2）启发函数设计。启发函数 $h(u)$ 对路径点的求解速度和质量有重要影响，传统的启发函数采用单一距离代价计算方法，往往与实际飞行航程存在较大差距，导致所得到的路径通常不是最优解，此处采用欧氏距离与平均飞行速度的比值来表示：

$$h(u) = \sqrt{(x^u - x^n)^2 + (y^u - y^n)^2 + (z^u - z^n)^2} \Big/ \overline{V} \tag{15}$$

式中：$\overline{V}$ 为无人机 5 种不同飞行速度的平均值。

3　仿真验证及分析

3.1　仿真环境和参数设置

为验证本文算法在城市空间环境下对多旋翼无人机进场航迹规划的有效性，开展仿真实验。实验中选取 120 m×120 m×120 m 作为航迹规划环境空间，障碍物数量为 7 个，障碍物位置随机生成。城市空间模拟环境三维图像如图 3 所示。仿真所需设置参数如表 1 所示。

3.2　仿真结果分析

3.2.1　多旋翼无人机航迹规划方法有效性验证

选取数量分别为 10, 15, 20 架无人机进行航迹规划，无人机进场点 S 和起降点 G 信息已知，起降点数量设置为 3 个，同一起降点航空器落地间隔为 10 m。其中，10 架降落至起降点 G_1、G_2、G_3 的数量分别为 3、3、4；15 架降落至起降点 G_1、G_2、G_3 的数量分别为 6、5、4；20 架降落至起降点 G_1、G_2、G_3 的数量分别为 5、8、7。对本文算法开展有效性实验，采用本文算法及表 1 参数设置，其中，20 架无人机运行规模下进场航迹规划的结果如图 4 所示。

3.2.2　WM-A*算法效果分析

为评估 WM-A*算法在自由空域环境下多无人机进场航迹规划中的性能表现，本文基于不同架次的无人机进场规模，将改进后的 WM-A*算法与传统 A*算法进行实验并对比分析。考虑到无人机需要与障碍物及其他无人机之间保持安全距离，在拥

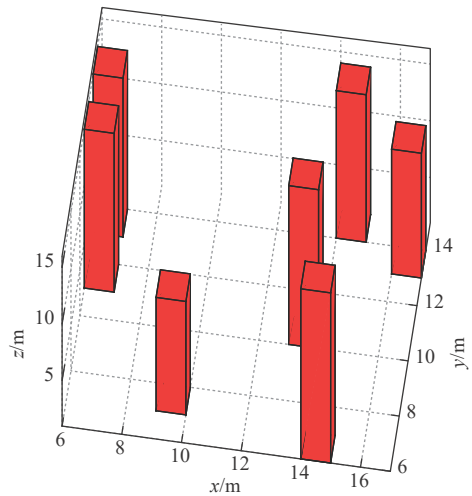


图3 三维空间环境地图

Fig. 3 Three dimensional space environment map

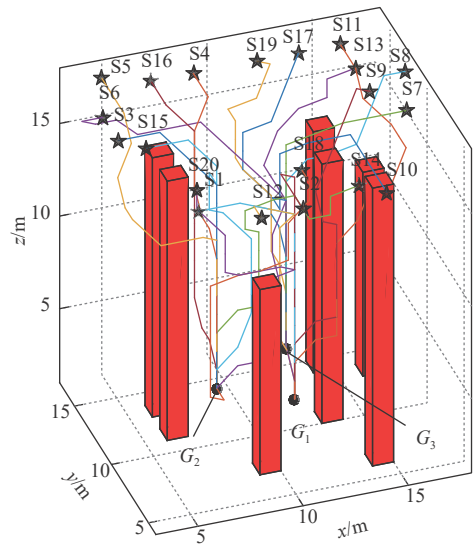


图4 20架无人机规模下航迹规划示意图

Fig. 4 Schematic diagram of track planning under scale of 20 unmanned aerial vehicles

表1 航迹规划模型及算法所需参数

Table 1 Required parameters of track planning model and algorithm

参数	数值
飞行高度最大值H_{max}/m	120
飞行高度最小值H_{min}/m	0
无人机与障碍物之间的最小安全间隔D_{min}/m	10
无人机之间的最小安全间隔D_r/m	10
栅格分辨率r/m	5
时间间隔约束Q/s	2
比例因子λ/m	8
沿x轴最大飞行速度V_1/(m·s^{-1})	6
沿y轴最大飞行速度V_2/(m·s^{-1})	6
沿z轴最大飞行速度V_3/(m·s^{-1})	3
沿面对角线最大飞行速度V_4/(m·s^{-1})	3
沿体对角线最大飞行速度V_5/(m·s^{-1})	3
代价函数权重系数ω_1	0.1
拥堵权值权重系数ω_2	0.9

堵权值地图中采用比例因子为8来划分拥堵检测区域，并且将具有重叠时间段、经过4架及以上无人机的区域认定为“拥堵区域”。

采用WM-A*算法、A*算法对无人机规模分别为10, 15, 20架的情况进行进场航迹规划，结果如表2所示。可知，本文WM-A*算法相较传统A*算法在规划多机进场时能够在保持牺牲较少飞行时间的提前下使区域避拥堵效果明显。在10, 15, 20架无人机进场运行过程中，总飞行时间分别牺牲了0.61%、1.91%、1.97%的情况下，对应的“拥堵区域”数量分别减少了48%、59.46%、61.11%，表明本文算法设计合理。

3.2.3 复杂障碍物环境下有效性验证及效果分析

为验证本文算法在其他环境下的有效性，增加障碍物数量至14个，障碍物大小、位置随机生成，保持其他参数不变，20架无人机进场运行的航迹规划结果如图5所示，本文WM-A*算法和传统A*算法航迹规划结果如表3所示。

由表3可知，在10, 15, 20架无人机进场运行过程中，总飞行时间分别牺牲了1.16%、2.15%、2.75%的情况下，对应的“拥堵区域”数量分别减少了45%、52.38%、44%。这表明在较复杂的障碍物空间环境下，WM-A*算法相比于A*算法依然可以规划出进场航迹并表现出良好的性能，得到的航迹规划结果可以保持牺牲较少飞行时间得到较好的避拥堵效果。

3.2.4 权重系数分析

面向复杂障碍物环境下无人机进场运行场景，针对10, 15, 20架无人机规模，分别通过设置9组不同的权重系数组合进行对照实验，分析权重系数ω_1、ω_2在不同取值情况下对实验结果产生的影响，

表2 不同进场规模下2种算法航迹规划结果对比

Table 2 Comparison of track planning results of two algorithms under different approach sizes

算法	飞行时间/s			拥堵区域个数		
	无人机为10架	无人机为15架	无人机为20架	无人机为10架	无人机为15架	无人机为20架
A*	272.06	429.22	571.86	25	37	54
WH-A*	273.71	437.40	583.10	13	15	21

其中, 20 架无人机规模实验数据如表 4 和图 6 所示。

表 4 给出了 20 架无人机规模在不同权重系数取值下的实验结果, 图 6 给出了该结果相较于传统 A*算法的变化情况。由表 3 可知, 传统 A*算法规划的飞行时间为 555.46 s, 拥堵区域数量为 50 个。通过表 4 和图 6 可知, 相较于传统 A*算法, 改进后的 WM-A*算法规划的飞行时间有所提高, 而区域拥堵数量有所下降。在ω_1取 0.8, ω_2取 0.2 时, 达到权重系数组合中飞行时间最小, 相较于传统 A*算法增加了 0.53%, 拥堵区域数量减少了 36%; 而当ω_1取 0.4, ω_2取 0.6 时, 飞行时间增加了 0.96%, 拥堵区域数量减少了 52%, 相较于前者在飞行时间多增加了 0.43% 的情况下拥堵区域数量多减少了 16%, 可取得较优结果。

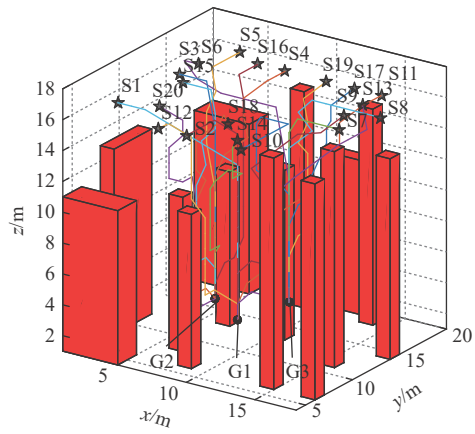


图 5　复杂障碍物环境下 20 架无人机规模下航迹规划示意图

Fig. 5　Schematic diagram of track planning under scale of 20 unmanned aerial vehicles under complex obstacle environment

表 3　复杂障碍物环境下 2 种算法航迹规划结果对比

Table 3　Comparison of track planning results between two algorithms under complex obstacle environment

算法	飞行时间/s			拥堵区域个数		
	无人机为10架	无人机为15架	无人机为20架	无人机为10架	无人机为15架	无人机为20架
A*	267.76	418.33	555.46	20	42	50
WH-A*	270.86	427.32	570.72	11	20	28

表 4　权重系数取值对航迹规划结果的影响

Table 4　Influence of weight value on result of track planning

ω_1	ω_2	飞行时间/s	拥堵区域个数
0.1	0.9	570.72	28
0.2	0.8	563.92	30
0.3	0.7	558.74	29
0.4	0.6	560.77	24
0.5	0.5	561.88	33
0.6	0.4	561.50	31
0.7	0.3	565.48	26
0.8	0.2	558.39	32
0.9	0.1	560.62	36

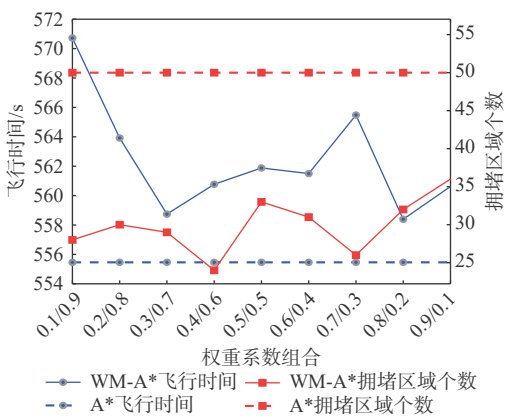


图 6　2 种算法下不同权重系数取值对航迹规划结果的影响

Fig. 6　Influence of different weight coefficient values on result of track planning under two algorithms

4　结　论

1) 结合现有研究基础定义进场空间范围, 面向自由空间环境构建以飞行时间最小为目标的无冲突航迹规划模型, 设计基于三维拥堵权值地图的改进 A*算法求解, 在多起降点的场景下实现多旋翼无人机避拥堵的无冲突进场。

2) 通过对比实验验证了在不同无人机规模、不同障碍物环境下 WM-A*相较于 A*算法在规划结果上有明显优势, 在最多牺牲 2.75% 的飞行时间时可使三维空间内拥堵区域分流效果明显, 提高空域利用效率。

3) 针对 10,15,20 架的无人机进场规模, 分别通过 9 组对照实验进行权重系数分析, 得出在多机进场航迹规划时, 较优权重系数ω_1为 0.4, ω_2为 0.6 时取得。在实际运行时可通过追求目标的侧重点来设置最有利的权重组合。

参考文献（References）

[1] 张洪海, 张连东, 刘嶂, 等. 城市低空物流无人机航迹规划模型研究[J]. 交通运输系统工程与信息, 2022, 22(1): 256-264.
Zhang H H, Zhang L D, Liu H, et al. Track planning model for logistics unmanned aerial vehicle in urban low-altitude airspace[J]. Journal of Transportation Systems Engineering and Information Technology, 2022, 22(1): 256-264(in Chinese).

[2] 马德进, 陈洋, 朱振华. 面向河道巡检的多无人机协作路径规划[J]. 控制工程, 2025, 32(3): 545-552.

Ma D J, Chen Y, Zhu Z H. Multi UAVs cooperative path planning for river monitoring[J]. Control Engineering of China, 2025, 32(3): 545-552(in Chinese).

[3] 尹洪玉, 吴宇, 梁天骄. 固定翼无人机巡逻覆盖协同路径规划方法[J]. 航空学报, 2024, 45(6): 323-337.
Yin H Y, Wu Y, Liang T J. Cooperative path planning for patrol coverage of fixed wing UAV[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(6): 323-337(in Chinese).

[4] 张洪海, 李翰, 刘皞, 等. 城市区域物流无人机路径规划[J]. 交通运输系统工程与信息, 2020, 20(6): 22-29.
Zhang H H, Li H, Liu H, et al. Path planning for logistics unmanned aerial vehicle in urban area[J]. Journal of Transportation Systems Engineering and Information Technology, 2020, 20(6): 22-29(in Chinese).

[5] 张启钱, 许卫卫, 张洪海, 等. 复杂低空物流无人机路径规划[J]. 北京航空航天大学学报, 2020, 46(7): 1275-1286.
Zhang Q Q, Xu W W, Zhang H H, et al. Path planning for logistics UAV in complex low-altitude airspace[J]. Journal of Beijing University of Aeronautics and Astronautics, 2020, 46(7): 1275-1286(in Chinese).

[6] 胡莘婷, 吴宇. 面向城市飞行安全的无人机离散型多路径规划方法[J]. 航空学报, 2021, 42(6): 452-463.
Hu S T, Wu Y. Risk-based discrete multi-path planning method for UAVs in urban environments[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(6): 452-463(in Chinese).

[7] 魏明, 孙雅茹, 孙博, 等. 带软时间窗的多调度中心 UAV 安全运输线路和航迹协同规划[J]. 北京航空航天大学学报, 2025, 51(10): 3233-3242.
Wei M, Sun Y R, Sun B, et al. Cooperative planning for safe transportation routes and flight paths of UAV with multiple dispatching centers and soft time windows[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(10): 3233-3242(in Chinese).

[8] Dai W, Pang B Z, Low K H. Conflict-free four-dimensional path planning for urban air mobility considering airspace occupancy[J]. Aerospace Science and Technology, 2021, 119: 107154.

[9] 赵嶷飞, 袁一凡. 小型多旋翼城市物流无人机进场航线设计方法研究[J]. 飞行力学, 2024, 42(4): 78-87.
Zhao Y F, Yuan Y F. Research on approach flight route design method of small multi-rotor urban logistics UAVs[J]. Flight Dynamics, 2024, 42(4): 78-87(in Chinese).

[10] 崔恺, 曾国奇, 林伟, 等. 一种基于图论的机场空域无人机流量控制方法[J]. 北京航空航天大学学报, 2020, 46(5): 978-987.
Cui K, Zeng G Q, Lin W, et al. Flow control method for UAV airport airspace based on graph theory[J]. Journal of Beijing University of Aeronautics and Astronautics, 2020, 46(5): 978-987(in Chinese).

[11] Pradeep P, Wei P. Heuristic approach for arrival sequencing and scheduling for eVTOL aircraft in on-demand urban air mobility [C]//Proceedings of the IEEE/AIAA 37th Digital Avionics Systems Conference. Piscataway: IEEE Press, 2018: 1-7.

[12] Kleinbekman I C, Mitici M, Wei P. Rolling-horizon electric vertical takeoff and landing arrival scheduling for on-demand urban air mobility[J]. Journal of Aerospace Information Systems, 2019, 17(3): 150-159.

[13] Kleinbekman I C, Mitici M A, Wei P. eVTOL arrival sequencing and scheduling for on-demand urban air mobility[C]//Proceedings of the IEEE/AIAA 37th Digital Avionics Systems Conference. Piscataway: IEEE Press, 2018: 1-7.

[14] Song K, Yeo H, Moon J H. Approach control concepts and optimal vertiport airspace design for urban air mobility (UAM) operation[J]. International Journal of Aeronautical and Space Sciences, 2021, 22(4): 982-994.

[15] Song K, Yeo H. Development of optimal scheduling strategy and approach control model of multicopter VTOL aircraft for urban air mobility (UAM) operation[J]. Transportation Research Part C: Emerging Technologies, 2021, 128: 103181.

[16] Shao Q, Shao M X, Lu Y. Terminal area control rules and eVTOL adaptive scheduling model for multi-vertiport system in urban air Mobility[J]. Transportation Research Part C: Emerging Technologies, 2021, 132: 103385.

[17] Bertram J, Wei P. An efficient algorithm for self-organized terminal arrival in urban air mobility[C]//Proceedings of the AIAA Scitech 2020 Forum. Reston: AIAA, 2020.

[18] 程洁. 基于智能算法的多无人机协同 4D 路径规划研究[D]. 广汉: 中国民用航空飞行学院, 2023: 19.
Cheng J. Multi-UAV collaborative 4D path planning algorithm based on intelligent algorithm[D]. Guanghan: Civil Aviation Flight University of China, 2023: 19(in Chinese).

[19] 王祝, 张梦通, 张振鹏, 等. 基于多指标动态优先级的无人机协同路径规划[J]. 航空学报, 2024, 45(4): 256-269.
Wang Z, Zhang M T, Zhang Z P, et al. Multi-UAV cooperative path planning based on multi-index dynamic priority[J]. Acta Aeronautica et Astronautica Sinica, 2024, 45(4): 256-269(in Chinese).

Three-dimensional track planning for multi-UAV approach in free airspace environment

WANG Jianzhong*，LIANG Feida

(College of Air Traffic Management，Civil Aviation University of China，Tianjin 300300，China)

Abstract：In order to prevent congestion during regional approach phases, this study suggests a conflict-free multi-unmanned aerial vehicle (UAV) track planning strategy for metropolitan spatial environments under free airspace conditions. The method aims to ensure safe and efficient UAV approach operations while enhancing airspace utilization efficiency. Firstly, we defined the spatial scope of the approach phase. Secondly, we discretized the three-dimensional operational environment using the grid method and introduced the concept of grid occupancy time. UAV acted as dynamic obstacles, and we developed a conflict-free track planning model to minimize flight time. Subsequently, we enhanced the A* algorithm based on a three-dimensional congestion weight map to compute congestion-avoiding flight tracks for multiple UAV. Finally, we simulated approach scenarios with 10, 15, and 20 UAV under various obstacle environments. With cost weight coefficient values of 0.4, 0.6, the results demonstrate that in a complex obstacle environment, the improved algorithm decreases congested areas by 52% while sacrificing just 0.96% of flight time when compared to the A* algorithm. This significant optimization underscores the effectiveness of the model, confirming both its feasibility and the efficacy of the algorithm.

Keywords：unmanned aerial vehicle；track planning；grid occupancy time；A* algorithm；congestion weight map

Received：2024-07-01；**Accepted**：2024-09-20；**Published Online**：2024-10-11 16：43

URL：link.cnki.net/urlid/11.2625.V.20241010.2004.005

Foundation item：Tianjin Education Commission Scientific Research Project (2018KJ249)

* **Corresponding author**. E-mail：jz-wang@cauc.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0561

基于状态空间模型的航拍图像小目标检测算法

滕尚志*，龚曦，李宝安，吕学强
(北京信息科技大学 网络文化与数字传播北京市重点实验室，北京 100192)

摘 要：小目标检测旨在解决传统目标检测算法处理微小目标时的困难。小目标检测需要克服目标尺寸小、像素少、目标与背景之间差异小导致难以检测的问题，对目标检测算法的鲁棒性、准确性提出更高的要求。基于此，设计了一种基于状态空间模型的小目标检测算法，探索状态空间模型在目标检测领域的应用。设计了滑动窗口扫描机制以将二维图像转换为一维序列，更适用于小目标检测任务；设计了空间信息聚合模块，通过双分支结构分别计算全局和局部注意力，抑制无关背景信息；针对传统交并比损失进行改进，关注边界框形状和尺度对检测性能的影响，并使用辅助框加速模型收敛。在公开数据集 VisDrone2019 上进行了充分的实验，论证了所提算法的有效性。

关 键 词：小目标检测；状态空间模型；空间信息聚合；注意力机制；辅助边界框
中图分类号：TP391; TP751; V557
文献标志码：A **文章编号**：1001-5965(2026)11-3832-10

目标检测是对图像、视频中感兴趣的目标进行分类和定位的一项重要任务。由于深度卷积神经网络强大的学习能力和庞大的数据量，近年来目标检测取得了显著的成就。小目标检测(small object detection, SOD)作为通用目标检测的一个子领域，专注于对小尺寸物体的检测，在监控、无人机场景分析、行人检测、自动驾驶交通标志检测等多种场景中具有重要的理论和现实意义。从定义上理解，小目标被分为相对小目标和绝对小目标，相对小目标即相对原图目标尺寸为其 1/10 或更小，绝对小目标指目标面积小于 32 像素×32 像素。随着人工智能的发展，无人机广泛应用于航拍、城市交通、遥感测绘、电力线巡航等领域。无人机作为一种高效的图像采集系统，具有高智能、高机动性和广阔视野等优点，在大范围、远距离搜索目标这一新兴领域得到了广泛的应用。在无人机视角下检测地面物体是一个非常具有挑战性的任务，因为从无人机视角下获得的图像中大多数目标的尺度小，信噪比低，容易受到背景的干扰。由于无人机运行过程中飞行高度的不断改变，极易造成拍摄物体尺度变化剧烈、采集图像模糊等问题。此外，拍摄广度的改变可能会导致出现背景复杂、遮挡目标无法识别等问题。针对上述问题，航拍图像小目标检测具有很高的研究与应用价值。

基于深度学习的目标检测算法根据算法的流程主要分为 2 类：两阶段和单阶段。两阶段目标检测的代表性算法有基于区域的卷积神经网络(region-based convolutional neural network, R-CNN)[1]、Fast R-CNN[2]、Faster R-CNN[3] 等。两阶段模型的算法流程主要是先选择出若干目标候选区域，再对候选区域进行进一步的分类以及边界框调整，尽管能够得到较高的准确率，但是由于存在大量的冗余计算导致推理速度较慢。单阶段目标检测的代表性算法有 YOLO[4] 系列、单次多边框检测器(single shot multibox detector, SSD)[5]、RetinaNet[6] 等。单阶段模型的算法流程主要是在图像上直接进行目标的

收稿日期：2024-07-23；**录用日期**：2024-09-14；**网络出版时间**：2024-10-14 16:19
网络出版地址：link.cnki.net/urlid/11.2625.V.20241014.1513.003
基金项目：国家自然科学基金 (62202061)；北京市自然科学基金 (4232025)；北京市教育委员会科研计划 (KM202311232002)
* **通信作者**. E-mail：tengshangzhi@bistu.edu.cn

引用格式：滕尚志，龚曦，李宝安，等. 基于状态空间模型的航拍图像小目标检测算法 [J]. 北京航空航天大学学报，2026，52（11）：3832-3841.
Teng S Z，Gong X，Li B A，et al. Aerial image small object detection algorithm based on state space model[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：3832-3841（in Chinese）.

分类及调整边界框, 大大减少了计算量, 能够在保证一定准确率的前提下大幅度地提高检测速度, 因此, 在现实中得到了广泛应用。但在小目标检测领域, 深度卷积神经网络由于其感受野随深度增加而变大, 更着重于图像的全局特征, 往往容易忽略小目标检测所需的局部特征。Transformer[7] 模型最开始是应用在自然语言处理中, 近年来, 学者们逐渐将 Transformer 的应用扩展到计算机视觉领域。DETR[8] 是 Facebook 团队提出的基于 Transformer 的端到端目标检测器, 没有非极大值抑制(non-maximum suppression, NMS)后处理步骤、没有 anchor 等先验知识和约束, 整个由网络实现端到端的目标检测实现, 大大简化了目标检测的框架。DETR 利用 Transformer 的全局建模能力, 直接对图像进行集合预测, 其性能优于传统的基于 CNN 的目标检测器。自 DETR 提出后, Transformer 在计算机视觉领域持续发力, Deformable DETR[9] 将注意力机制视为训练收敛慢的主要原因, 提出了 Deformable Attention, 加快模型收敛速度并降低算法复杂度。SMCA-DETR[10] 提出一种空间调制的协同注意模块, 取代了 DETR 中现有的协同注意力机制, 以克服 DETR 训练收敛速度慢的缺点。REGO-DETR[11] 提出一种基于感兴趣区域的检测改进方法, 以改进 DETR 中的注意力机制。DINO[12] 考虑了正负噪声对象查询, 以使训练收敛更快, 并增强对小目标的检测性能。RT-DETR[13] 设计了一个混合编码器来解耦尺度内和尺度间的同时交互, 提出了交并比 (intersection over union, IoU) 感知查询选择机制, 通过为解码器提供更高质量的初始对象查询来进一步提升性能。这些目标检测模型受限于 Transformer 的二次计算复杂度, 对计算资源和内存消耗较大, 难以处理长序列任务。Sparse Semi-DETR[14] 集成了一个查询细化模块, 以提高对象查询的质量, 显著提高了对小目标和部分模糊目标的检测能力。Salience DETR[15] 提出了分层显著过滤细化, 只对过滤的判别查询执行 Transformer 编码, 以更好地权衡计算效率和精度。

最近, 状态空间模型(state space model, SSM)在处理长序列建模方面表现出了效率上的优势, 为解决深度学习任务中的远程依赖建模提供了另一种选择。与 Transformer 相比, SSM 效率更高, 因为其随序列长度线性扩展, 并且保留了对远程依赖关系建模的优越能力。SSM 进一步将其应用扩展到复杂的视觉任务中, 在这些任务中, 其有望比 CNN 和 ViT[16] 更具有效率上的优势。Mamba[17] 进一步完善了 SSM, 提出一种依赖于数据的 SSM 层, 并构建了一个通用语言模型主干 Mamba, 在大规模真实数据上, 其在多个方面都优于 Transformer, 并且在序列长度上保持线性计算复杂度, 展示了其优秀的性能。这一特点凸显了 Mamba 作为语言建模变革性架构的潜力, 表明 SSM 可以成为 Transformers 在深度学习应用领域的有力竞争者。S4ND[18] 是第一个将 SSM 应用到视觉任务的工作, 并展示了其性能可与 ViT 竞争的潜力, 然而 S4ND 仅仅对 S4[19] 模型进行了简单的扩展, 无法以数据依赖的方式有效地捕获图像信息。ViM[20] 将 Mamba 的成功扩展到视觉任务中, 通过整合双向选择性 SSM 和位置嵌入, 增强了视觉表示学习, 在 ImageNet 分类及密集预测任务上表现出了超越 DeiT[21] 的卓越性能。同时, VMamba[22] 专注于在视觉表示学习中提高效率和可扩展性。VMamba 引入了交叉扫描机制, 以在二维图像空间中实现一维选择性扫描, 在保持全局接受域的同时, 将计算复杂度从二次降低到线性。这一设计及架构的改进, 使得 VMamba 成为了在性能上与主流视觉模型 (如 ResNet[23]、ViT、Swin Transformer[24]) 相匹配甚至超越的有竞争力的主干模型。此外, U-Mamba[25] 解决了在生物医学图像分割中对高效距离依赖建模的需求。通过将 CNN 在局部特征提取方面的优势与 SSM 在捕捉长距离上下文方面的优势相结合, U-Mamba 展示了混合架构在改善生物医学影像任务的分割性能方面的潜力。

基于上述研究, 本文针对无人机视角下的小目标检测任务, 设计了一个基于 SSM 的目标检测算法 DE-SSM。具体工作如下:

1) 设计了基于滑动窗口扫描机制的状态空间模型 SSMFormer, 能够有效对图像全局建模的同时保留小目标的信息。

2) 设计了空间信息聚合模块(spatial information aggregation module, SIAM), 同时捕捉图像全局和局部空间信息。

3) 设计了基于辅助边界框的 Inner-Shape-IoU 损失函数, 在边界框回归 (bounding box regression, BBR) 过程中关注边界框自身的形状与尺度, 提高小目标检测的精确度。

1　本文算法

针对目前无人机航拍图像中的小目标检测性能低、漏检、遮挡等问题, 本文基于 RT-DETR 模型进行改进, 提出 DE-SSM, 探索 SSM 在目标检测中的应用, 并且 DE-SSM 在无人机遥感图像目标检测任务中表现出更高的性能和鲁棒性。该模型主要由特征提取主干网络, 混合高效编码器和基于可变形注意力的 Transformer 解码器组成。

模型中的混合高效编码器包括SSMFormer、SIAM和基于CNN的跨尺度特征融合模块(cross-scale convolutional fusion module, CCFM),改进后的模型结构如图1所示。

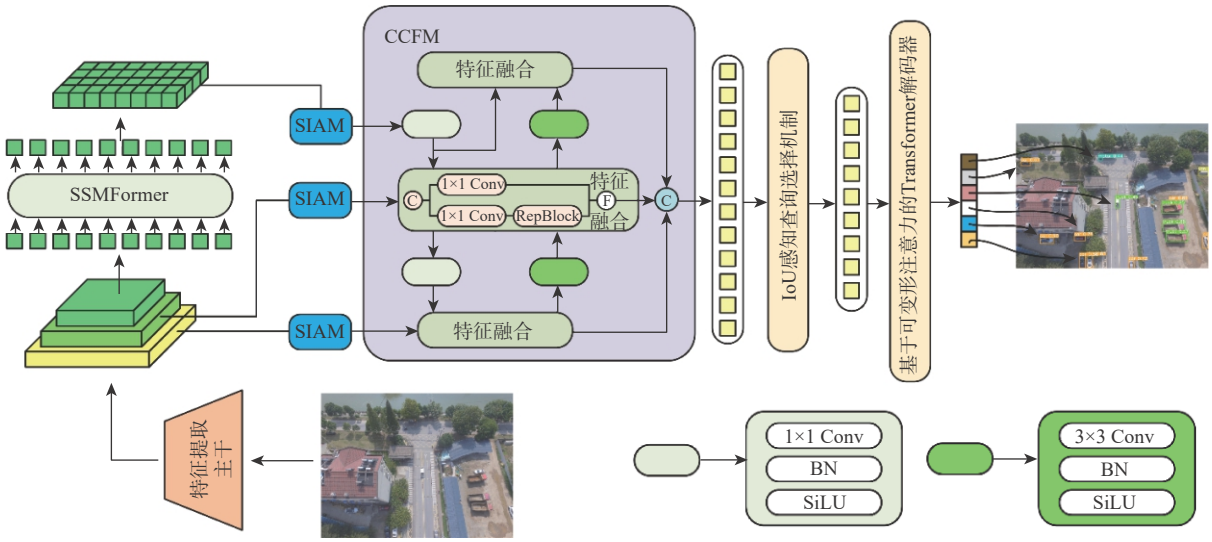


图1 DE-SSM结构

Fig. 1 DE-SSM structure

1.1 基于滑动窗口扫描机制的状态空间模型

Transformer在计算机视觉任务中表现出巨大的潜力,普遍的观念认为基于注意力的令牌混合器对Transformer的贡献最大,Yu等[26]从Transformer中抽象出一般架构MetaFormer,认为这种架构才是导致Transformer类视觉模型取得优越性能的关键。

MetaFormer架构如图2(a)所示,基于这种架构,提出SSMfromer,其结构如图2(b)所示,将滑动窗口扫描机制作为MetaFormer的令牌混合器。

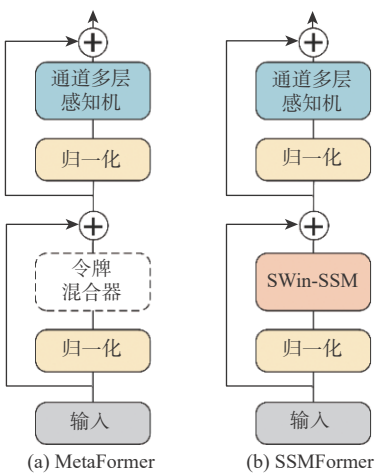


图2 SSMFormer和MetaFormer模型对比

Fig. 2 Comparison of SSMFormer and MetaFormer models

1.1.1 结构化状态空间模型

结构化SSM依赖于经典的连续系统,该系统通过中间隐藏状态$\boldsymbol{h}(t)\in\mathbf{R}^N$将一维序列$\boldsymbol{x}(t)\in\mathbf{R}$映射到$\boldsymbol{y}(t)\in\mathbf{R}$,上述过程可以表示为线性常微分方程:

$$\begin{cases}\boldsymbol{h}'(t)=\boldsymbol{A}\boldsymbol{h}(t)+\boldsymbol{B}\boldsymbol{x}(t)\\ \boldsymbol{y}(t)=\boldsymbol{C}\boldsymbol{h}(t)\end{cases}\tag{1}$$

式中:$\boldsymbol{A}\in\mathbf{R}^{N\times N}$为状态矩阵;$\boldsymbol{B}\in\mathbf{R}^{N\times 1}$、$\boldsymbol{C}\in\mathbf{R}^{1\times N}$为投影参数。

S4是线性时间不变的结构化SSM,通过将该连续系统离散化,使其更适合深度学习场景。具体来说,引入时间尺度参数θ将连续参数$\boldsymbol{A}$、$\boldsymbol{B}$转换为离散参数$\overline{\boldsymbol{A}}$、$\overline{\boldsymbol{B}}$,常用的变换方式是零阶保持(Zero-Order Hold, ZOH),其定义如下:

$$\begin{cases}\overline{\boldsymbol{A}}=\exp(\Delta\boldsymbol{A})\\ \overline{\boldsymbol{B}}=(\Delta\boldsymbol{A})^{-1}(\exp(\Delta\boldsymbol{A})-\boldsymbol{I})\cdot\Delta\boldsymbol{B}\end{cases}\tag{2}$$

式中:Δ为步长;$\boldsymbol{I}$为单位矩阵。

在参数离散化后,式(1)可以重写为

$$\begin{cases}\boldsymbol{h}_t=\overline{\boldsymbol{A}}\boldsymbol{h}_{t-1}+\overline{\boldsymbol{B}}\boldsymbol{x}_t\\ \boldsymbol{y}_t=\boldsymbol{C}\boldsymbol{h}_t\end{cases}\tag{3}$$

模型通过SSM卷积核同时计算合成整个序列的输出,从而提高计算效率与可扩展性:

$$\begin{cases}\boldsymbol{K}=\left(\boldsymbol{C}\overline{\boldsymbol{B}},\boldsymbol{C}\overline{\boldsymbol{A}}\,\overline{\boldsymbol{B}},\cdots,\boldsymbol{C}\overline{\boldsymbol{A}}^{M-1}\overline{\boldsymbol{B}}\right)\\ \boldsymbol{y}=\boldsymbol{x}*\overline{\boldsymbol{K}}\end{cases}\tag{4}$$

式中:M为输入序列$\boldsymbol{x}$的长度;$\boldsymbol{K}\in\mathbf{R}^M$为长度为$M$的权重向量;*为卷积操作。

1.1.2 选择性扫描机制

S4模型实现了线性时间复杂度,但其捕获序列上下文的能力也受到了静态参数化的限制。为解

决这一限制, Mamba 通过将选择性扫描机制 S6 作为核心 SSM 算子与其他 SSM 区分开来, S6 致力于保留轻量级且有用的状态信息, 兼顾性能和效率, 其通过有选择地将数据压缩到状态中来实现这一点。在计算机视觉任务中, 通过扫描将二维图形转换为一维序列后送入 S6 中进行状态选择, 其结构如图 3 所示。在 S6 中, 从输入数据 $\boldsymbol{x}\in\mathbf{R}^{B\times L\times D}$ 计算矩阵 $\boldsymbol{B}\in\mathbf{R}^{B\times L\times N}$, $\boldsymbol{C}\in\mathbf{R}^{B\times L\times N}$ 和 $\nabla\in\mathbf{R}^{B\times L\times D}$, B 为批大小, L 为输入序列长度, D 为输入特征维度, N 为隐状态维度。利用选择性扫描机制, Mamba 不仅在序列长度上实现了线性可扩展性, 而且在长序列上下文建模任务中表现出有竞争力的性能。

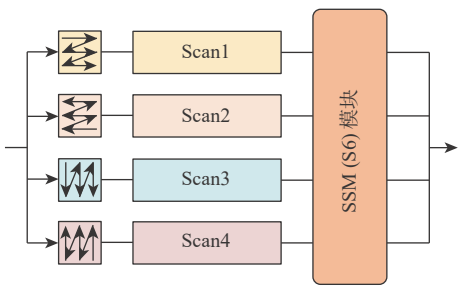


图 3　选择性扫描机制示意图

Fig. 3　Schematic diagram of selective scanning mechanism

1.1.3　滑动窗口扫描机制

选择性扫描机制 S6 在处理一维因果序列数据上表现出卓越的性能。这种机制有效地捕获扫描片段中的重要信息, 类似于语言建模, 其中, 理解顺序序列之间的依赖关系至关重要。然而, 将二维图像展开为一维序列会破坏局部二维依赖关系的完整性, 从而降低模型有效识别空间关系的能力。如图 3 所示, ViM[20] 中使用的序列化方式破坏了这些局部依赖, 水平扫描时显著增加了垂直相邻令牌之间的距离, 垂直扫描时又显著增加了水平相邻令牌之间的距离, 并阻碍了模型捕捉局部细微差异的能力。VMamba[22] 试图通过在水平和垂直方向上扫描图像来解决该问题, 但其仍然无法在单次扫描中全面处理空间区域。为解决该问题, 本文提出一种滑动窗口扫描机制, 将图像划分为多个不同的局部窗口, 在每个窗口中进行线性扫描, 确保图像相邻令牌排列更加紧密, 增强对局部依赖的捕获。如图 4 所示, 以窗口尺寸大小设置为 3、滑动步数设置为 2 的正向水平扫描为例, 在沿水平方向扫描时拉近了垂直方向相邻令牌之间的距离, 最终在 4 个方向上集成滑动窗口扫描机制, 在图像局部细节和全局视角之间取得平衡。

1.2　空间信息聚合模块

注意力机制可以强化与检测目标相关的信息, 抑制无关信息。本文设计了 SIAM以同时捕捉全局

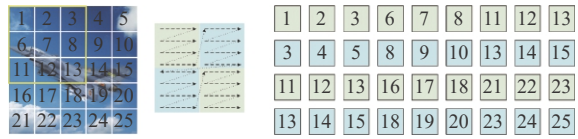


图 4　滑动窗口扫描机制示意图

Fig. 4　Schematic diagram of scanning mechanism of sliding window

与局部空间特征, 其包含 2 个独立的局部和全局注意力单元。如图 5 所示, 这种双分支路径设计有效地保留了局部细节信息和全局建模信息。此外, 使用分离的通道维度来平衡检测精度和计算资源。具体地, 将主干网络提取的特征图 $\boldsymbol{F}_i$ 沿着通道维度平均拆分成 2 个特征图 $\boldsymbol{F}_i^1$ 和 $\boldsymbol{F}_i^2$, 并分别送入全局注意力模块和局部注意力模块。最后, 将这 2 个注意力单元的输出连接起来, 再加上一个 1×1的卷积层。该过程可以公式化为

$$\begin{cases}\boldsymbol{F}_i^1,\boldsymbol{F}_i^2=\mathrm{Split}(\boldsymbol{F}_i)\\ \boldsymbol{F}_i'=\mathrm{pwConv}\left(\mathrm{Concat}\left(G_{\mathrm{sa}}\left(\boldsymbol{F}_i^1\right),L_{\mathrm{sa}}\left(\boldsymbol{F}_i^2\right)\right)\right)\end{cases}\tag{5}$$

式中: pwConv 为 1×1 逐点卷积层; G_{sa} 为全局空间注意力(global spatial attention, GSA); L_{sa} 为局部空间注意力(local spatial attention, LSA); Split 为分割成 2 个矩阵; Concat 为拼接。

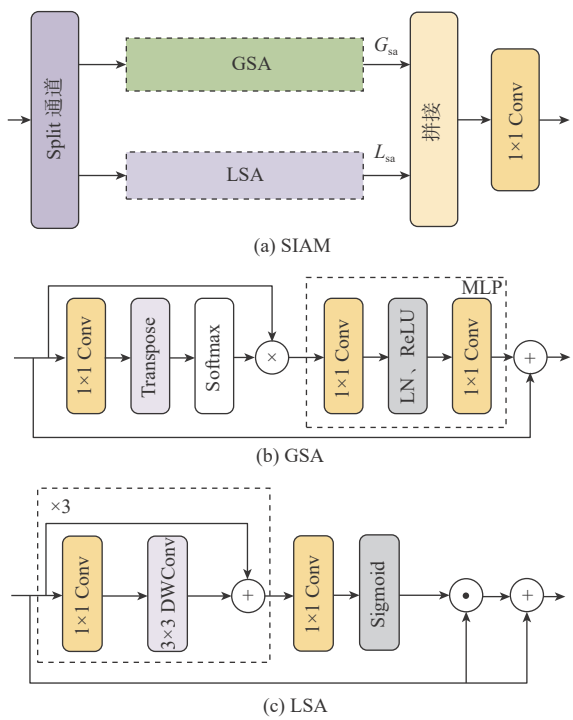


图 5　空间信息聚合模块结构

Fig. 5　Spatial information aggregation module structure

全局空间注意力关注各个像素在空间中的远程关系, 可以与局部空间注意力进行互补。长距离依赖关系可以使特征表示更强大, 使用 $\boldsymbol{F}_i^1$ 作为输入, 生成全局空间注意力过程如下:

$$\begin{cases} \text{Att-G}\left(\boldsymbol{F}_i^1\right)=\phi\left(\left(\text{pwConv}(\boldsymbol{F}_i^1)\right)^{\text{T}}\right) \\ G_{\text{sa}}\left(\boldsymbol{F}_i^1\right)=\text{MLP}\left(\text{Att-G}\left(\boldsymbol{F}_i^1\right)\otimes\boldsymbol{F}_i^1\right)+\boldsymbol{F}_i^1 \end{cases} \tag{6}$$

式中：Att-G为全局注意力算子；⊗表示矩阵乘法；$\phi(\cdot)$表示Softmax函数；MLP由2个具有ReLU非线性激活函数和归一化层的全连接层组成，MLP的第1层将输入变换到高维空间，第2层将其维度恢复为与输入相同。

局部空间注意力模块能够在给定特征图的空间维度上提取感兴趣区域的局部特征。使用$\boldsymbol{F}_i^2$作为输入，计算局部空间注意力如下：

$$\begin{cases} \text{Att-L}\left(\boldsymbol{F}_i^2\right)=\sigma\left(\text{pwConv}\left(F_{\text{c}}\left(\boldsymbol{F}_i^2\right)+\boldsymbol{F}_i^2\right)\right) \\ L_{\text{sa}}\left(\boldsymbol{F}_i^1\right)=\text{Att-L}\left(\boldsymbol{F}_i^2\right)\odot\boldsymbol{F}_i^2+\boldsymbol{F}_i^2 \end{cases} \tag{7}$$

式中：F_{c}表示堆叠的3个1×1卷积层和3×3深度可分离卷积层；$\sigma(\cdot)$表示Sigmoid激活函数；Att-L为局部注意力算子；⊙为矩阵逐元素乘法。这种结构设计可以用更少的参数有效地聚焦局部空间信息。

特征经过空间信息聚合后送入基于CNN的CCFM中，CCFM的作用是将相邻层特征进行融合，其结构如图1所示。融合块包含2个1×1卷积和1个重参数块，2条路径的输出通过逐元素相加进行融合，最后，将特征展开为一维序列。

1.3 损失函数

BBR是目标检测任务的重要分支任务，现有的BBR方法通常考虑真实框与预测框之间的几何关系，通过使用边框间的相互位置与相对形状计算损失，而忽略了边界框自身的形状与尺度等固有属性对BBR的影响。Shape-IoU[27]可以通过关注边界框自身的形状和尺度来计算损失，从而使边界框预测更加准确。Inner-IoU[28]通过辅助边界框计算损失加速BBR过程，与IoU损失相比，当比例小于1且辅助边界框尺寸小于实际边界框时，回归的有效范围小于IoU损失，但梯度的绝对值大于从IoU损失获得的梯度，可以加速高IoU样本的收敛。相反，当比例大于1时，较大尺度的辅助边界框扩大了回归的有效范围，对低IoU样本的回归具有增强效果。

引入Inner-IoU思想使用辅助边界框加速模型收敛，结合Shape-IoU，本文提出基于辅助边界框的Inner-Shape-IoU，在考虑边界框自身形状的同时使用辅助边界框加速模型收敛。如图6所示，虚线框与点线框均为辅助边界框，Inner-Shape-IoU的计算过程如下：

$$I^{\text{inner}}=\frac{(\alpha Z)\cap(\alpha Z^{\text{gt}})}{(\alpha Z)\cup(\alpha Z^{\text{gt}})} \tag{8}$$

$$w_w=\frac{2(w^{\text{gt}})^\beta}{(w^{\text{gt}})^\beta+(h^{\text{gt}})^\beta} \tag{9}$$

$$h_h=\frac{2(h^{\text{gt}})^\beta}{(w^{\text{gt}})^\beta+(h^{\text{gt}})^\beta} \tag{10}$$

$$d^{\text{shape}}=h_h(x_c-x_c^{\text{gt}})^2/c^2+w_w(y_c-y_c^{\text{gt}})^2/c^2 \tag{11}$$

$$\Omega^{\text{shape}}=\sum_{t=w,h}(1-\text{e}^{-w_t})^\tau \qquad \tau=4 \tag{12}$$

$$\begin{cases} w_w=\dfrac{h_h|w-w^{\text{gt}}|}{\max(w,w^{\text{gt}})} \\ h_h=\dfrac{w_w|h-h^{\text{gt}}|}{\max(h,h^{\text{gt}})} \end{cases} \tag{13}$$

式中：I^{inner}为使用辅助框计算出的IoU；α为放缩因子，与预测框和真实框的IoU有关；Z为边界框；上标gt表示真实值；β为尺度因子，与数据集中目标的尺度有关；w_w和h_h分别为水平方向和垂直方向的权重系数，其值与真实框的形状相关；c为归一化因子；w和h分别为预测框的宽度和高度；d^{shape}为形状距离；Ω^{shape}为形状损失，用τ控制对形状损失的关注程度。其对应的BBR损失如下：

$$L_{\text{inner-shape-iou}}=1-I^{\text{inner}}+d^{\text{shape}}+0.5\Omega^{\text{shape}} \tag{14}$$

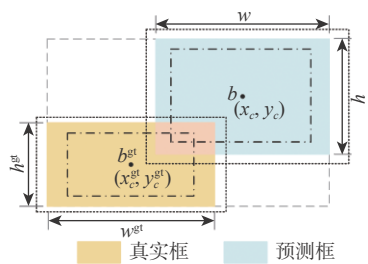


图6 Inner-Shape-IoU计算示意图

Fig. 6 Inner-Shape-IoU calculation diagram

2 实 验

2.1 数据集与评价指标

本文在VisDrone2019数据集上进行实验。VisDrone2019数据集是由天津大学AISKYEYE团队获取的一个大规模无人机视角的数据集，涵盖多种场景、不同无人机平台、天气和光照条件，共有8 629张图像，其中，训练集6 471张，验证集548张，测试集1 610张，包含10个类别：行人、人、汽车、面包车、巴士、卡车、摩托车、自行车、三轮车和带棚三轮车。

在目标检测任务中，评价模型性能的指标主要有精度P、召回率R、平均精度A_{P}、均值平均精度m_{AP}，各指标的具体计算式如下：

$$P=\frac{T_{\text{P}}}{T_{\text{P}}+F_{\text{P}}} \tag{15}$$

$$R = \frac{T_P}{T_P + F_N} \tag{16}$$

$$A_P = \int_0^1 P(R)\mathrm{d}R \tag{17}$$

$$m_{AP} = \frac{1}{N}\sum_{i=0}^{1} A_{Pi} \tag{18}$$

式中: T_P为真正例; F_P为假正例; F_N为假负例;

在轻量化与性能平衡的考虑中, 模型的参数量和浮点运算量是至关重要的考量因素。参数量指模型中所有参数的总数量, 包括权重和偏置等。浮点运算量的大小用来衡量模型在前向传播时的计算负荷。

本文实验采用 mAP0.5 和 mAP0.5∶0.95、参数量和浮点运算量作为模型性能评价指标。mAP0.5 表示 IoU 阈值为 0.5 时的 m_{AP}, mAP0.5∶0.95 则为 IoU 从 50% 开始, 以步长为 0.05 上升到 95% 时的平均 m_{AP}, mAP0.5 和 mAP0.5∶0.95 越大, 则模型的整体精度就越高。

2.2　实验环境

本文实验在 Linux 操作系统上进行, 操作系统为 Ubuntu 18.04-LTS, CPU 为 IntelGold 5118, 运行内存为 32 GB, GPU 为 2 块 NVIDIATeslaV100-16 GB, Python 解释器版本为 3.9, CUDA 版本为 11.7, Pytorch 版本为 2.0.1。网络未使用预训练模型参数权重, 设置训练轮次为 150, 批处理大小为 4, 网络初始学习率为 0.01, 输入图像尺寸大小统一缩放为 640 像素×640 像素。

2.3　消融实验

模型结构框架的改进基于 RT-DETR 模型, 为验证各改进算法的有效性, 在 VisDrone2019 数据集上进行消融实验, 在测试集上的实验结果如表 1 所示, 表中加黑数值为最优结果。图 7 为训练过程中模型在验证集上的各评价指标变化曲线。可以看出, DE-SSM 算法相较于基线模型其各项性能指标均有提升。表 1 依次对各个模块改进前、后的实验效果进行对比。可以看出, 加入 SSMFormer 后, 在仅增加少量参数量和浮点运算量的情况下, 各个评价指标均有提升, mAP0.5 和 mAP0.5∶0.95 分别提升了 0.84% 和 0.45%, 同时精度提高了 2.34%。这是因为基于滑动窗口扫描机制的 SSMFormer 有效拉近了不同扫描方式下相邻令牌之间的距离, 以获得更聚焦的局部特征表示, 有利于后续定位与分类任务。加入 SIAM 后, 参数量增加了 0.208×10^7, 浮点运算量增加了 6.7×10^9 次, 性能也同样得到提升, mAP0.5 和 mAP0.5∶0.95 分别提升了 0.78% 和 1.23%。原因在于 SIAM 可以过滤空间位置信息, 抑制无关背景噪声的干扰。Inner-Shape-IoU 在不增加参数量和浮点运算量的情况下, mAP0.5 和 mAP0.5∶0.95 分别提升了 1.08% 和 1.36%, 可以看出, Inner-Shape-IoU 是比 IoU 更适合小目标检测任务的衡量标准。

表 1　消融实验结果

Table 1　Ablation experiment results

SSMFormer	SIAM	Inner-Shape-IoU	输入图像尺寸/(像素×像素)	*P*/%	*R*/%	mAP0.5/%	mAP0.5∶0.95/%	参数量	浮点运算量/10^9次
			640×640	59.55	44.30	46.11	27.68	1.988×10^7	**57.0**
√			640×640	**61.89**	44.70	46.95	28.13	2.018×10^7	57.3
	√		640×640	61.15	44.77	46.89	28.91	2.196×10^7	63.7
		√	640×640	61.63	45.08	47.19	29.04	**1.988×10^7**	57.0
√	√		640×640	61.42	45.66	47.69	29.27	2.227×10^7	64.0
√		√	640×640	61.10	**45.67**	47.31	29.14	2.018×10^7	57.3
	√	√	640×640	60.68	45.27	47.50	29.36	2.196×10^7	63.7
√	√	√	640×640	61.07	45.37	**47.71**	**29.57**	2.227×10^7	64.0
√	√	√	960×960	66.60	52.66	54.71	34.81	2.227×10^7	64.0

将各模块进行组合以验证其兼容性。在仅加入 SSMFormer 的情况下, 精度最高, 达到了 61.89%。在同时加入 SSMFormer 和 Inner-Shape-IoU 的情况下, 召回率最高达到了 45.67%。将所有改进加入模型中得到的最终改进算法的 mAP0.5和 mAP0.5∶0.95 均达到了最高, 分别为 47.71% 和 29.57%。最后, 使用不同的输入尺寸进行对比, 使用 960 像素×960 像素大小的图像作为输入, 相较于 640 像素×640 像素的图像输入, mAP0.5 和 mAP0.5∶0.95 分别提升了 7.0% 和 5.24%。通过实验结果可以看出, 本文算法在含有众多小目标及密集目标的 VisDrone2019 数据集上有良好的检测效果。

2.4　对比实验

为证明 DE-SSM 算法的先进性, 本节在

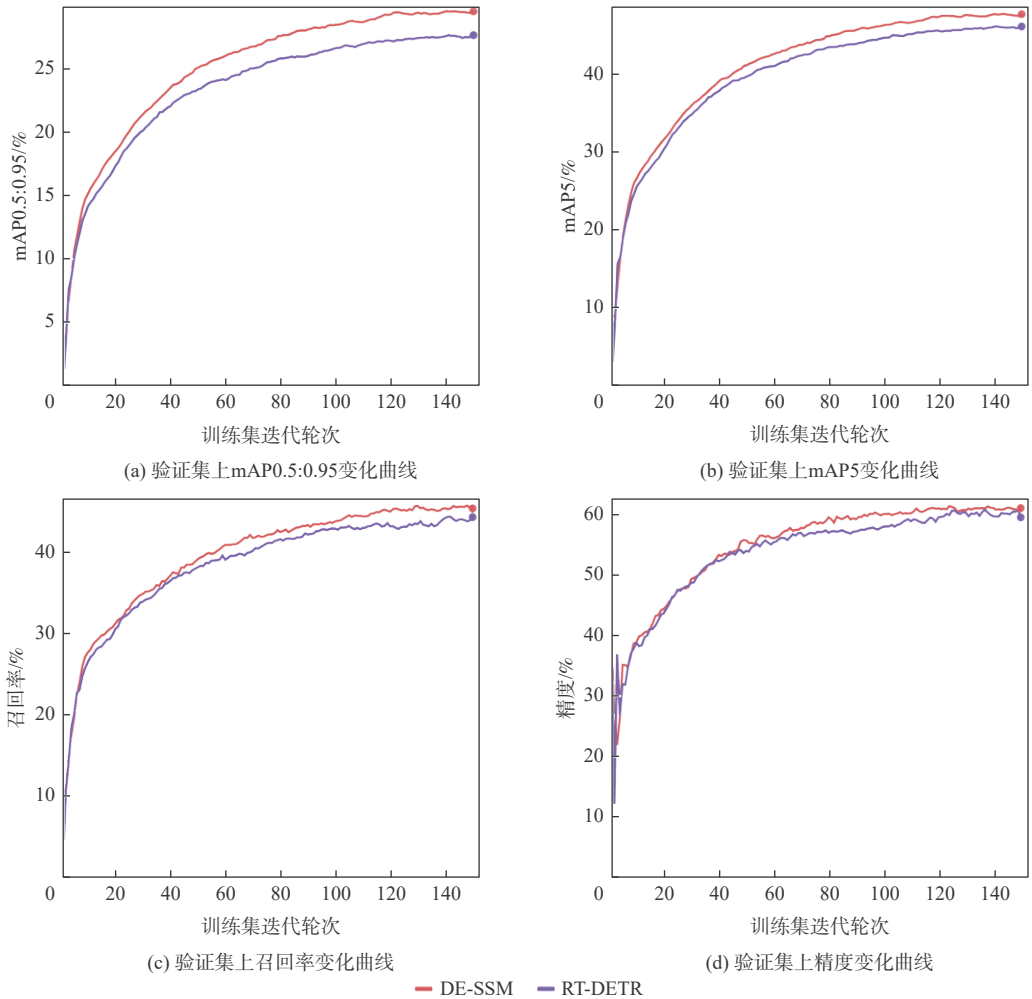


图 7 训练过程中评价指标变化曲线

Fig. 7 Change curves of evaluation index during training process

VisDrone2019测试集上与各种目标检测算法进行对比分析。表2为近几年较为流行的算法在VisDrone2019测试集中的检测结果，选用mAP0.5和mAP0.5∶0.95中的检测作为评价指标，表中加黑数值为最优结果。可以看出，DE-SSM模型在这2个指标上均优于其他算法。

表 2 对比实验结果

Table 2 Contrast experiment results

算法	mAP0.5∶0.95/%	mAP0.5/%	浮点运算量/10^9次
IterDet[29]	20.40	36.80	173
Swin Transformer[24]	23.10	42.50	226
Cascade R-CNN[30]	16.10	31.90	236
Deformable DETR[9]	24.80	42.70	193
Light-headR-CNN[31]	16.50	32.80	94
PP-YOLOE[32]	24.60	39.60	110
YOLOX-X[33]	25.80	43.20	281
RT-DETR[13]	27.68	46.11	**57**
TPH-YOLOv5[34]	26.10	44.10	261
本文算法	**29.57**	**47.71**	64

DE-SSM通过SSMFormer建模全局信息，使用SIAM过滤无关信息，加入Inner-Shape-IoU针对边界框自身的形状和尺度来计算损失，显著提高了检测性能。

VisDrone2019数据集中的图像具有检测目标密集、部分目标过小、数据分布不同和目标遮挡严

重的特点。根据 DE-SSM 模型在 VisDrone2019 数据集上的性能表现可以得出, 相较于其他模型, DE-SSM 更注重图像中的局部细节信息, 在小目标检测任务上具有较大的优势。

2.5　检测结果可视化

为更直观展示改进模型的检测效果, 对检测结果进行可视化, 如图 8 所示。在原图中对差异部分进行了标注, 图 8(a) 中的黄色边框是对检测差异部分进行等比例放大后的图像。如图 8(a)所示, 1 处是 1 个行人被重复框选; 2 处是被错误识别为 1 个行人; 3 处是把 1 把椅子识别成 1 辆卡车; 4 处是 1 个拐角的阶梯被错误识别为行人; 5 处是 1 辆巴士和 1 个补给站被识别成了 2 辆面包车。而这些物体均被 DE-SSM 算法正确识别。



(a) 原图　(b) RT-DETR检测结果　(c) DE-SSM检测结果

图 8　检测结果可视化效果

Fig. 8　Visualization of the detection result

3　结　论

针对无人机视角下的航拍图像小目标检测任务, 本文提出一种基于状态空间模型的小目标检测模型 DE-SSM。

1) 为减轻 Transformer 序列长度的二次计算复杂度, 引入状态空间模型, 同时设计了滑动窗口扫描机制以将二维图像转换为一维序列, 滑动窗口扫描机制可以更好地聚合图像周围的特征, 更适合于小目标检测任务。

2) 设计了空间信息聚合模块, 通过 2 个独立的注意力单元分别捕捉全局特征和局部特征, 可以强化与检测目标相关的信息。

3) 对传统交并比损失函数进行改进, 通过关注边界框的形状和尺度来计算损失, 从而使边界框预测更加精确, 并且加入辅助框来帮助模型更好地收敛。

在 VisDrone2019 数据集上进行充分的实验, mAP0.5 和 mAP0.5∶0.95 分别达到了 47.71% 和 29.57%, 优于现有主流模型。DE-SSM 能够有效检测出无人机航拍图像中的小目标, 为小目标检测提供了一种切实可行的解决方案。

参考文献 (References)

[1] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2014: 580-587.

[2] Girshick R. Fast R-CNN[C]//Proceedings of the IEEE International Conference on Computer Vision. New York: ACM, 2015: 1440-1448.

[3] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.

[4] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 779-788.

[5] Liu W, Anguelov D, Erhan D, et al. SSD: single shot multibox detector[C]//Proceedings of the Computer Vision-ECCV 2016. Berlin: Springer, 2016: 21-37.

[6] Lin T Y, Goyal P, Girshick R, et al. Focal loss for dense object detection[C]//Proceedings of the IEEE International Conference on

Computer Vision. Piscataway: IEEE Press, 2017: 2999-3007.

[7] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [C]//Proceedings of the Advances in Neural Information Processing Systems 30. Red Hook: Curran Associates, Inc. , 2017: 6000-6010.

[8] Carion N, Massa F, Synnaeve G, et al. End-to-end object detection with Transformers[C]//Proceedings of the Computer Vision-ECCV 2020. Berlin: Springer, 2020: 213-229.

[9] Zhu X Z, Su W J, Lu L W, et al. Deformable DETR: deformable Transformers for end-to-end object detection[EB/OL]. (2021-03-18)[2024-06-15]. https://arxiv.org/abs/2010.04159.

[10] Gao P, Zheng M H, Wang X G, et al. Fast convergence of DETR with spatially modulated co-attention[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2022: 3601-3610.

[11] Chen Z, Zhang J, Tao D C. Recurrent glimpse-based decoder for detection with Transformer[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2022: 5250-5259.

[12] Zhang H, Li F, Liu S L, et al. DINO: DETR with improved denoising anchor boxes for end-to-end object detection[EB/OL]. (2022-07-11)[2024-06-15]. https://arxiv.org/abs/2203.03605.

[13] Zhao Y A, Lv W Y, Xu S L, et al. DETRs beat YOLOs on real-time object detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2024: 16965-16974.

[14] Kim J, Cho H, Kim J, et al. SDDGR: stable diffusion-based deep generative replay for class incremental object detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2024: 28772-28781.

[15] Hou X Q, Liu M Q, Zhang S L, et al. Salience DETR: enhancing detection Transformer with hierarchical salience filtering refinement[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2024: 17574-17583.

[16] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16×16 words: Transformers for image recognition at scale[EB/OL]. (2021-06-03)[2024-06-15]. https://arxiv.org/abs/2010.11929.

[17] Gu A, Dao T. Mamba: linear-time sequence modeling with selective state spaces[EB/OL]. (2024-05-31)[2024-06-15]. https://arxiv.org/abs/2312.00752.

[18] Baccus S, Dao T, Downs G, et al. S4ND: modeling images and videos as multidimensional signals with state spaces[C]//Proceedings of the Advances in Neural Information Processing Systems 35. Red Hook: Curran Associates, Inc. , 2022: 2846-2861.

[19] Smith J T H, Warrington A, Linderman S W. Simplified state space layers for sequence modeling[EB/OL]. (2023-03-03)[2024-06-15]. https://arxiv.org/abs/2208.04933.

[20] Zhu L H, Liao B C, Zhang Q, et al. Vision Mamba: efficient visual representation learning with bidirectional state space model[EB/OL]. (2024-01-17)[2024-06-15]. https://arxiv.org/abs/2401.09417.

[21] Touvron H, Cord M, Douze M, et al. Training data-efficient image Transformers & distillation through attention[EB/OL]. (2021-01-15)[2024-06-15]. https://arxiv.org/abs/2012.12877.

[22] Liu Y, Tian Y J, Zhao Y Z, et al. VMamba: visual state space model [EB/OL]. (2024-01-18)[2024-06-15]. https://arxiv.org/abs/2401.10166.

[23] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 770-778.

[24] Liu Z, Lin Y T, Cao Y, et al. Swin Transformer: hierarchical vision Transformer using shifted windows[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2022: 9992-10002.

[25] Ma J, Li F F, Wang B. U-Mamba: enhancing long-range dependency for biomedical image segmentation[EB/OL]. (2024-01-09)[2024-06-15]. https://arxiv.org/abs/2401.04722.

[26] Yu W H, Luo M, Zhou P, et al. MetaFormer is actually what you need for vision[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2022: 10809-10819.

[27] Zhang H, Zhang S J. Shape-IoU: more accurate metric considering bounding box shape and scale[EB/OL]. (2024-01-12)[2024-06-15]. https://arxiv.org/abs/2312.17663.

[28] Zhang H, Xu C, Zhang S J. Inner-IoU: more effective intersection over union loss with auxiliary bounding box[EB/OL]. (2023-11-14)[2024-06-15]. https://arxiv.org/abs/2311.02877.

[29] Rukhovich D, Sofiiuk K, Galeev D, et al. IterDet: iterative scheme for object detection in crowded environments[C]//Proceedings of the Structural, Syntactic, and Statistical Pattern Recognition. Berlin: Springer, 2021: 344-354.

[30] Cai Z W, Vasconcelos N. Cascade R-CNN: delving into high quality object detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 6154-6162.

[31] Li Z M, Peng C, Yu G, et al. Light-head R-CNN: in defense of two-stage object detector[EB/OL]. (2017-11-23)[2024-06-15]. https://arxiv.org/abs/1711.07264.

[32] Xu S L, Wang X X, Lv W Y, et al. PP-YOLOE: an evolved version of YOLO[EB/OL]. (2022-12-12)[2024-06-15]. https://arxiv.org/abs/2203.16250.

[33] Ge Z, Liu S T, Wang F, et al. YOLOX: exceeding YOLO series in 2021[EB/OL]. (2021-08-06)[2024-06-15]. https://arxiv.org/abs/2107.08430.

[34] Zhu X K, Lyu S C, Wang X, et al. TPH-YOLOv5: improved YOLOv5 based on Transformer prediction head for object detection on drone-captured scenarios[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops. Piscataway: IEEE Press, 2021: 2778-2788.

Aerial image small object detection algorithm based on state space model

TENG Shangzhi*，GONG Xi，LI Baoan，LYU Xueqiang

(Key Laboratory of Internet Culture and Digital Dissemination Research，Beijing Information Science and Technology University，Beijing 100192，China)

Abstract：Small object detection aims to solve the difficulties of traditional target detection algorithms in dealing with tiny objects. Small object detection needs to overcome the problems of small object size, few pixels, and a small difference between the target and background, which makes it difficult to detect. It puts higher requirements on the robustness and accuracy of object detection algorithms. A small object detection algorithm based on a state space model is designed to explore the application of the state space model in the field of object detection. A sliding window scanning mechanism is designed to convert two-dimensional images into one-dimensional sequences, which is more suitable for small object detection tasks. In order to suppress irrelevant background information, a dual-branch structure is used in a spatial information aggregation module to calculate global and local attention, respectively. Improvements are made to the traditional IoU loss, focusing on the influence of bounding box shape and scale on detection performance, and auxiliary boxes are used to accelerate model convergence. Sufficient experiments are carried out on the public dataset VisDrone2019 to demonstrate the effectiveness of the proposed method.

Keywords：small object detection; state space model; spatial information aggregation; attention mechanism; auxiliary bounding box

Received：2024-07-23；**Accepted**：2024-09-14；**Published Online**：2024-10-14 16：19

URL：link.cnki.net/urlid/11.2625.V.20241014.1513.003

Foundation items：National Natural Science Foundation of China (62202061); Beijing Municipal Natural Science Foundation (4232025) ; Scientific Research Program of Beijing Municipal Commission of Education (KM202311232002)

* **Corresponding author**. E-mail：tengshangzhi@bistu.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0542

基于 Swin Transformer 的模分语义图像传输

彭艺[1,2]，孙畅[1,2]，杨青青[2,*]，李辉[2]，王健明[2]

(1. 昆明理工大学 信息工程与自动化学院，昆明 650031；2. 昆明理工大学 云南省计算机技术应用重点实验室，昆明 650500)

摘 要：语义通信作为下一代通信系统的新范式，极大提高了通信效率。然而，此前的语义图像传输工作大多是建立在卷积神经网络 (CNN) 上进行的，传统的 CNN 模型通常难以全面挖掘图像中的语义信息。为解决该问题，采用 Swin Transformer 作为骨干网络来提取语义信息。在此基础上，提出基于模分的语义图像传输新方法，通过特征分离实现公共特征和个性特征的独立传输。在输入的图像经过联合信源信道编码 (JSCC) 后，对所编码后的语义特征进行公共特征与个性特征的区分并分别进行传输，通过对公共特征的资源共享，有效降低了带宽需求，从而提升了传输效率。为评估模型性能，在公开的 CIFAR10 数据集上，将所提方法与传统方法进行对比，实验结果表明：所提方法有效提高了图像传输质量，并在传输效率和带宽节省方面取得了良好的性能。

关 键 词：语义通信；图像传输；模分多址；图像重建；Swin Transformer

中图分类号：TN929.5; TP391.41; TP18

文献标志码：A **文章编号**：1001-5965(2026)11-3842-10

随着通信技术的进步，传统通信系统在信息压缩、传输和处理上遇到瓶颈，迫切需要创新[1]。新兴应用(如自动驾驶和物联网)对通信提出更高要求，不仅需准确传输比特，还要支持智能决策和人机交互[2]，促使从业者深入探讨全新设计思路。语义通信因其与人工智能的紧密结合[3]及在提高通信效率方面的巨大潜力，成为研究热点[4]。

与经典香农信息论不同，语义通信关注信息的语义特征，并通过相应机制进行传输，能够在带宽受限的情况下超越香农容量极限，从而突破香农极限及冯诺依曼架构的限制[5]。香农在 1948 年提出的经典信息论关注的是符号的可靠传输，而未考虑更高层次的语义层面设计。香农的忽视源自当时的工程需求，但并不意味着应忽略信息的意义[6]。

得益于人工智能在算法、算力、数据方面的巨大进步，最近涌现了大量端到端语义通信系统模型，包括面向文本的语义通信[7]、面向图像的语义通信[8]及面向语音的语义通信[9]。这些语义通信系统类似于自动编码器，通过压缩和重构信号来优化传输并保留其语义信息。但其区别于去噪自编码器，在去噪自编码器中原始图像已经包含伪影，而在语义通信系统中则是将扰动添加到已经压缩的潜在特征上。这些扰动可以理解为在信号传输过程中由于无线信道所造成的干扰，如瑞利衰落或加性高斯白噪声(additive white Gaussian noise, AWGN)[10]。

近年来，深度学习模型在分析文本和图像等高维数据时展现了出色的能力。基于深度学习的联合信源信道编码(deep joint source-channel coding, Deep JSCC)[11]及其衍生版本[12-13]主要采用卷积神经网络(convolutional neural networks, CNN)作为骨干网络，直接将图像像素映射到信道输入符号，从而提升无线图像传输的效率和性能，超越了传统分离式方法(如 JPEG/BPG)。文献 [14] 提出一种基于注意

收稿日期：2024-07-18；**录用日期**：2024-12-20；**网络出版时间**：2025-01-16 13:40
网络出版地址：link.cnki.net/urlid/11.2625.V.20250115.1641.001
基金项目：国家自然科学基金 (62461030)；云南省基础研究计划重点项目 (202401AS070105)
* **通信作者**. E-mail：12309214@kust.edu.cn

引用格式：彭艺，孙畅，杨青青，等. 基于 Swin Transformer 的模分语义图像传输 [J]. 北京航空航天大学学报，2026，52（11）：3842-3851.
Peng Y，Sun C，Yang Q Q，et al. Swin Transformer-based semantic image transmission with model division multiplexing[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：3842-3851 （in Chinese）.

力机制的深度学习联合信源信道编码(attention-based deep joint source-channel coding, ADJSCC)方法, 通过信道级软注意力机制动态调整特征缩放, 解决了不同信噪比(signal-to-noise ratio, SNR)条件下的适应性和鲁棒性问题。

然而, 传统 CNN 模型通常受到局部感受野和层级限制的影响, 使其难以全面挖掘图像中的语义信息。国内外研究者受到 Vision Transformer (ViT)在计算机视觉领域中最新进展的启发, 开始将其作为骨干网络应用于语义通信领域[15-17]。相比于传统 CNN 模型, Swin Transformer 的窗口注意力机制通过减少全局计算的开销提升了计算效率。另外, 与 ViT 相比, Swin Transformer 采用局部窗口注意力机制, 使其计算复杂度与图像大小呈线性关系, 而传统 ViT 模型则表现出二次复杂度[15]。文献 [16] 以 Swin Transformer 作为骨干网络进行信息提取, 并在此基础上提出了空间调制模块提升信道适应性, 与 ADJSCC 方法相比, 高效的窗口注意力机制将浮点运算次数成本降低了 2.5 倍, 尽管模型较大, 但提供了更优的性能和更快的速度。文献 [17] 提出一种基于 Swin Transformer 的多用户语义通信系统, 通过自适应调整传输信号长度提升图像重建质量并避免网络拥堵。文献 [18] 结合传统 CNN 和现代视觉模型的优势, 引入一种基于 ConvNext 的新型语义通信结构, 降低了计算开销, 提升了整体的传输效率。但现有基于 Swin Transformer 的语义图像传输系统研究主要集中在语义信息提取、信道适应性提升及数据压缩等方面。尽管这些方法有效提升了图像传输的性能, 但大多侧重于提升传输的鲁棒性或压缩比, 未能充分考虑如何优化带宽需求。

为应对高维信息空间所带来的挑战, 引入了简化信息传输的方法, 旨在通过优化信息原语层面减少冗余, 提高无线网络的处理效率。根据文献 [19-20], 从相同语义通信模型中提取的语义特征包含一些共性的语义信息, 这些信息被称为公共特征, 其余部分则被称为个性特征。受此启发, 本文在图像传输系统中加入公共特征提取器, 来对提取出来的语义特征进行区分, 从而达到减少传输过程中的冗余信息、提高传输效率的目的。

基于此, 本文提出一种面向图像传输的语义通信系统框架。通过引入 Swin Transformer 网络架构及公共特征提取器, 克服了传统通信系统的技术瓶颈, 减少了传输过程中的冗余信息, 并有效节约了带宽资源, 从而提升了端到端传输性能。

1　语义通信系统

近年来, 随着深度学习的快速发展和广泛应用, 基于深度学习的语义编解码技术成为一个非常有潜力的重要发展方向。在语义通信系统中运用深度学习算法, 可以打破语义提取缺乏显式数学表达的障碍, 使系统更加灵活。

图 1 展示了一个传统的数字通信系统。在该系统中, 信源通过压缩和编码模块生成比特流, 并通过无线信道进行传输。接收端根据解码过程恢复数据, 并重构原始信息。

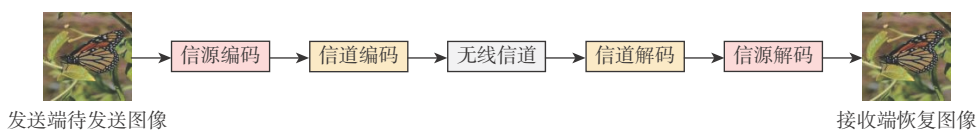


图 1　传统数字通信系统

Fig. 1　Traditional digital communication system

图 2 和图 3 展示了目前最常见的 2 种基于神经网络的语义通信系统。图 2 是一种较典型的神经网络语义通信系统, 对于现有通信系统改变是最小的, 其首先利用语义提取神经网络对原始数据进行预处理, 随后将提取出来的语义信息分别通过信源编码和信道编码。而图 3 是另一种基于神经网络的语义通信系统, 其利用神经网络对语义提取、信源编码及信道编码进行联合设计, 实现端到端的系统框架。其优点在于, 利用了在码长有限长的情况下联合信源信道编码(joint source-channel coding, JSCC)优于分离编码这一特点。

香农分离定理表明, 在传输无限长比特时, 独立的信源和信道编码可以提供最佳性能, 但这一假设在实际中难以实现。因为信源编码和信道编码会相互影响接收到的信息, 导致这种理想化模型不完全适用。因此, JSCC 在语义通信中逐渐受到重视。随着深度学习技术的发展, Deep JSCC 方法的引入使联合编码和解码变得更加高效和可行。

端到端 JSCC 相比传统分离式编码的最大突破在于通过深度学习将编码器、解码器和无线信道一起端到端训练。以往模型需在特定 SNR 下训练, 并在预测阶段保持相似 SNR, 否则性能下降。近年来, 引入注意力机制并根据 SNR 调整信源语义特征权重的研究, 使单一模型能适应不同信道条件,

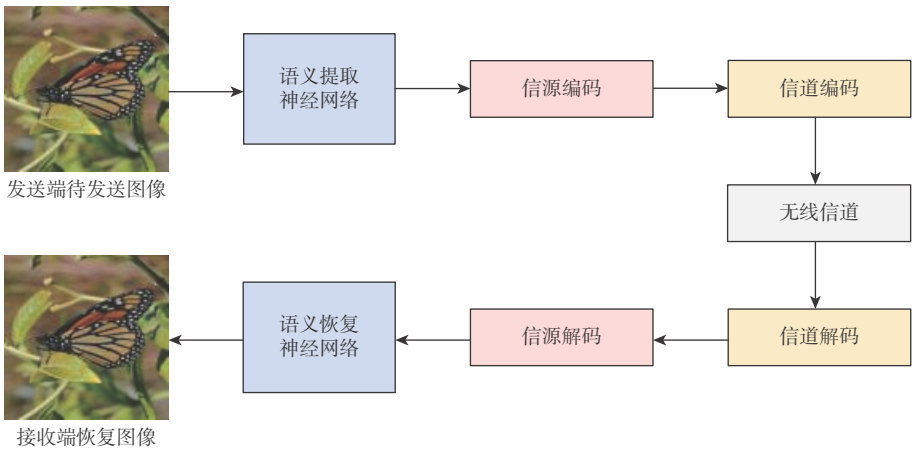


图 2 基于神经网络的语义通信系统 1

Fig. 2 Neural network-based semantic communication system 1



图 3 基于神经网络的语义通信系统 2

Fig. 3 Neural network-based semantic communication system 2

避免了多次训练。

2 模分图像语义传输方法

2.1 系统架构

图 4 展示了基于 Swin Transformer 的模分语义图像传输系统模型，其主要由发送端、通信信道和接收端 3 个部分组成。在发送端，将信源样本表示为 $\boldsymbol{I}\in\mathbf{R}^N$，其中，$N$为向量的长度，可以通过样本高度×样本宽度×样本通道数来进行计算。从$\boldsymbol{I}$中提取的语义特征向量表示为

$$\boldsymbol{S}_I = E_\alpha(\boldsymbol{I}) \tag{1}$$

式中：$E_\alpha(\cdot)$为语义编码器，用于提取信源样本的深层语义特征；α为语义特征提取函数中的可训练参数。

提取出来的语义特征向量输入信道自适应缩放模块中，根据通道状态将其进行重新缩放，从而增强在无线环境中传输符号的抗噪声和抗干扰能力。信道自适应缩放模块由多个全连接层和 SNR 调制（SNR modulation, SM）模块交替组成[16]，其可以根据信道状态对语义特征进行调制，以适应不同的信道状态。编码过程可以被表示为

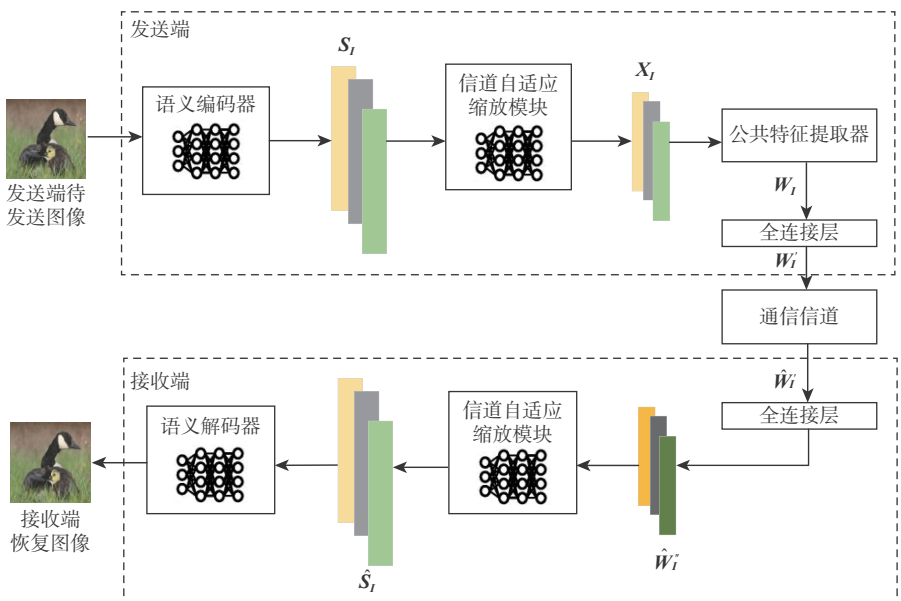


图 4 模分语义图像传输系统模型

Fig. 4 Semantic image transmission system model with model division multiplexing

$$\boldsymbol{X}_I = C_\beta(\boldsymbol{S}_I) \in \mathbf{R}^k \tag{2}$$

式中: $C_\beta(\cdot)$为具有参数β的信源信道编码函数; k为信道编码后的语义特征$\boldsymbol{X}_I$的长度。

信源信息经过语义编码、信道编码后, 送入公共特征提取器中, 公共特征提取器可以对其进行区分, 具体来说, 公共特征提取器将这些语义特征区分为公共特征$\boldsymbol{W}_{Ic}$与个性特征$\boldsymbol{W}_{Ii}$, 该过程可以表述为

$$\boldsymbol{W}_I = f_c(\boldsymbol{X}_I) = \{\boldsymbol{W}_{Ii}, \boldsymbol{W}_{Ic}\} \tag{3}$$

式中: $f_c(\cdot)$为提取公共特征的函数; $\boldsymbol{W}_I$为经过公共特征提取器后的总语义特征。

而后经历一个全连接层$M_f(\cdot)$将语义特征压缩变成C维语义特征$\boldsymbol{W}_I'$。信道带宽比(channel bandwidth ratio, CBR)定义为信道输入维度与信源维度的比值, 其直接影响图像信息的保留程度, 从而决定重建图像的质量。峰值信噪比(peak signal-to-noise ratio, PSNR)用于评估图像重建质量, 由于其值与重建误差成反比, 因此, CBR 的减小则导致信息丢失, 重建误差增加, 会显著降低 PSNR 性能。

经过公共特征提取器区分与压缩后的语义特征$\boldsymbol{W}_I'$通过无线信道进行传输, 此处考虑 AWGN 信道, 并将信道建模为一个不可训练的神经网络层[11]。在传输信号$\boldsymbol{W}_I'$过程中, AWGN 对信号产生干扰, 接收到的信号$\hat{\boldsymbol{W}}_I'$由接收器获取, 可表示为

$$\hat{\boldsymbol{W}}_I' = G\left(\boldsymbol{W}_I'; \sigma^2\right) = \boldsymbol{W}_I' + \boldsymbol{n} \tag{4}$$

式中: $G(\cdot)$为信道传输函数; 噪声分量$\boldsymbol{n}$服从高斯分布, $\boldsymbol{n} \sim N\left(0, \sigma^2\right)$; σ^2为噪声功率。

接收端主要包含信道自适应缩放模块及语义解码器, 两者分别对应发送端的自适应缩放过程和语义编码过程的逆过程。当接收端接收到信号$\hat{\boldsymbol{W}}_I'$, 先经过一个全连接层$M_f^{-1}(\cdot)$恢复为原维度语义特征$\hat{\boldsymbol{W}}_I''$, 随后采用信道解码函数$C_\phi^{-1}(\cdot)$解码出语义特征$\hat{\boldsymbol{S}}_I$, 再利用语义解码器$\boldsymbol{E}_\eta^{-1}(\cdot)$恢复出信源信息$\hat{\boldsymbol{I}}$。整个传输过程可表示为$\boldsymbol{I} \xrightarrow{E_\alpha(\cdot)} \boldsymbol{S}_I \xrightarrow{C_\beta(\cdot)} \boldsymbol{X}_I \xrightarrow{f_c(\cdot)} \boldsymbol{W}_I \xrightarrow{M_f(\cdot)} \boldsymbol{W}_I' \xrightarrow{G(\cdot)} \hat{\boldsymbol{W}}_I' \xrightarrow{M_f^{-1}(\cdot)} \hat{\boldsymbol{W}}_I'' \xrightarrow{C_\phi^{-1}(\cdot)} \hat{\boldsymbol{S}}_I \xrightarrow{E_\eta^{-1}(\cdot)} \hat{\boldsymbol{I}}$。

在此, 语义特征编、解码函数使用 Swin Transformer 构建, 整个系统能更快速地从带噪声信号中重建原始图像。该系统的训练损失函数为

$$\min_{\boldsymbol{\psi},\boldsymbol{\gamma}} E_{\boldsymbol{I}\sim P_{\boldsymbol{I}}} E_{\hat{\boldsymbol{W}}_I'\sim P_{\hat{\boldsymbol{W}}_I'|\boldsymbol{I}}}[d(\boldsymbol{I}, \hat{\boldsymbol{I}})] \tag{5}$$

式中: $\boldsymbol{\psi}$、$\boldsymbol{\gamma}$分别为编码器、解码器中所有的网络参数; $\boldsymbol{P}_I$为与信源样本$\boldsymbol{I}$相关的概率分布; $\boldsymbol{P}_{\hat{\boldsymbol{W}}_I'|\boldsymbol{I}}$为给定信源样本$\boldsymbol{I}$时, 关于接收符号序列$\hat{\boldsymbol{W}}_I'$的条件概率分布; d为原始图像与重建图像之间的差异。

2.2　语义编、解码部分

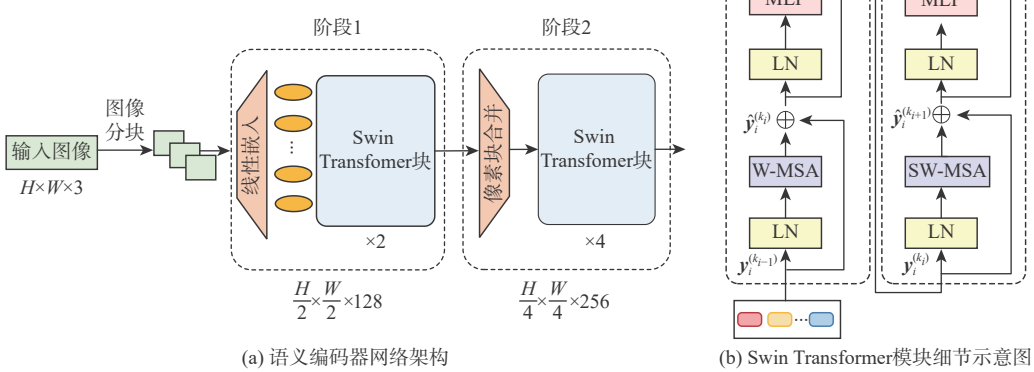
语义编码器的网络架构如图 5(a)所示, 采用 Swin Transformer 提取图像语义特征, 构成语义编码器的核心单元, 实现信源语义信息的处理。先将图像分割为若干不重叠的图像块, 经过线性嵌入后, 通过 2 个 Swin Transformer 块对这些图像块进行处理(阶段 1)。再将这些图像块送到阶段 2, 该阶段由像素块合并层及 4 个 Swin Transformer 块构成。语义解码器采用与语义编码器对称的结构。

如图 5(b)所示, Swin Transformer 块通过将多头自注意力(multi-head self-attention, MSA)模块替换为移位窗口模块, 实现了窗口分区的移动, 增强了全局信息提取能力, 并提高了特征提取效率。使用移动窗口分组方法后, 在第i个阶段中连续的 Swin Transformer 块k_i和k_{i+1}可以进行如下计算:

$$\hat{\boldsymbol{y}}_i^{(k_i)} = \text{W-MSA}\left(\text{LN}\left(\boldsymbol{y}_i^{(k_{i-1})}\right)\right) + \boldsymbol{y}_i^{(k_{i-1})} \tag{6}$$

$$\boldsymbol{y}_i^{(k_i)} = \text{MLP}\left(\text{LN}\left(\hat{\boldsymbol{y}}_i^{(k_i)}\right)\right) + \hat{\boldsymbol{y}}_i^{(k_i)} \tag{7}$$

$$\hat{\boldsymbol{y}}_i^{(k_{i+1})} = \text{SW-MSA}\left(\text{LN}\left(\boldsymbol{y}_i^{(k_{i+1})}\right)\right) + \boldsymbol{y}_i^{(k_{i+1})} \tag{8}$$



(a) 语义编码器网络架构　　(b) Swin Transformer模块细节示意图

图 5　语义编码器网络架构及 Swin Transformer 模块细节示意图[15]

Fig. 5　Semantic encoder architecture and Swin Transformer module details diagram[15]

$$\boldsymbol{y}_i^{(k_{i+1})} = \mathrm{MLP}\left(\mathrm{LN}\left(\hat{\boldsymbol{y}}_i^{(k_{i+1})}\right)\right) + \hat{\boldsymbol{y}}_i^{(k_i)} \tag{9}$$

式中：$\hat{\boldsymbol{y}}_i^{(k_i)}$和$\boldsymbol{y}_i^{(k_i)}$分别为第$i$个阶段的块$k_i$中(S)W-MSA模块和MLP模块的输出特征；W-MSA和SW-MSA为Swin Transformer中的MSA模块，具有常规和移动窗口配置；MLP为多层感知机，用于对特征作进一步映射和信息融合；LN表示层归一化操作。

随后，每个从语义编码器中输出的语义特征将根据信道状态通过信道编码器重新进行缩放。

2.3 信道自适应缩放模块

信道自适应缩放模块分别由具有不同全连接层的多层感知器构成，其可以根据不同的信道状态生成特定的调制策略，以适应信道的变化。图6展示了信道编码和解码网络架构，其由8个全连接层和7个SM模块交替组成。每个SM模块包含3层全连接网络，根据输入的信号S_m，将其映射为m维的向量$\boldsymbol{s}_m$，以调整隐性特征各通道之间的比例信息。SM模块通过动态调整隐性特征的比例，提升网络对不同SNR条件下的适应性和鲁棒性，从而优化编、解码性能。具体映射过程为

$$\boldsymbol{s}_m^{(1)} = \mathrm{ReLU}(\boldsymbol{A}^{(1)}S_m + \boldsymbol{b}^{(1)}) \tag{10}$$

$$\boldsymbol{s}_m^{(2)} = \mathrm{ReLU}(\boldsymbol{A}^{(2)}\boldsymbol{s}_m^{(1)} + \boldsymbol{b}^{(2)}) \tag{11}$$

$$\boldsymbol{s}_m = \mathrm{ReLU}(\boldsymbol{A}^{(3)}\boldsymbol{s}_m^{(2)} + \boldsymbol{b}^{(3)}) \tag{12}$$

式中：ReLU为激活函数；$\boldsymbol{A}^{(\cdot)}$和$\boldsymbol{b}^{(\cdot)}$分别为仿射函数的参数及其对应的偏移量。

此后，级联多个相同的SM模块，再经过一个Sigmod激活函数输出[0, 1]之间的权重值，以缩放Swin Transformer模块的输出特征向量。

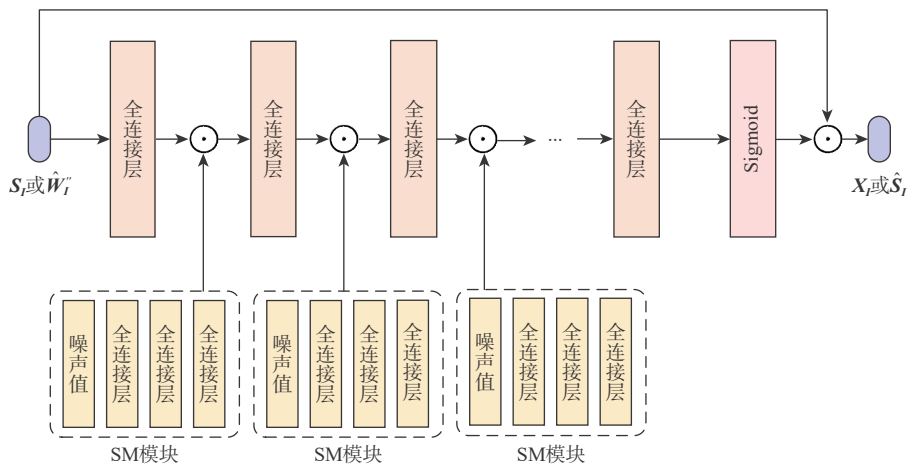


图6 信道自适应缩放模块网络架构[16]

Fig. 6 Channel adaptive scaling module network architecture[16]

2.4 公共特征提取方法

受到模分多址技术的启发，本文工作的目标是在2.1～2.3节所述通信系统模型的基础上，识别、分析、提取语义信息中所代表的共性和个性化信息，对携带共性信息的信号进行复用，以进一步降低传输带宽。根据文献[19]，从相同数据集的不同图像提取出来的语义信号非常相似，可以从高维语义空间中挖掘不同图像所传输语义信息的共性和个性信息，从而充分利用从高维语义空间中挖掘出来的共性信息，降低由冗余传输而造成的带宽消耗。

利用以上方法对CIFAR10数据集中同类别的任意2张图像提取语义信息。如图7所示，其表示从同类别图像中提取出的相关语义信息集合。可以看出，虽然是从不同图像中提取出的信号图像，但其语义信息集非常相似。

在公共特征提取器中，对提取出来的不同语义向量每个维度的方差进行计算。通过分析每个维度的方差，可以评估特征在不同维度上的离散程度。方差小的特征维度表示该维度的信息在多个样本中变化较小；相反，方差大的特征维度表示该维度的信息在样本之间变化较大。每个特征维度的方差可表示为

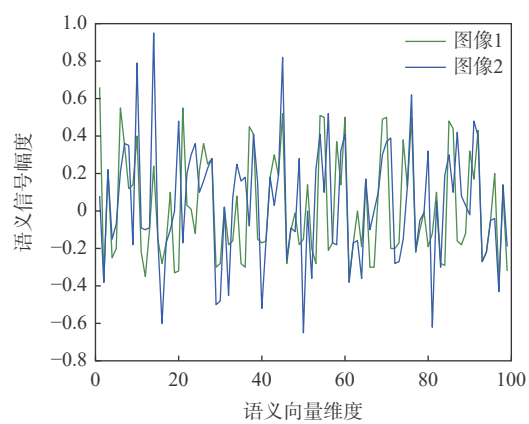


图7 语义特征变化趋势

Fig. 7 Trend of semantic feature variation

$$V_{\mathrm{ar}}(x_{i'}) = \frac{1}{N'}\sum_{j=1}^{N'}\left(x_{i'j}-\mu_{i'}\right)^2 \tag{13}$$

式中: $x_{i'j}$为第i'个特征维度在第j个样本中的值; $\mu_{i'}$为第i'个维度的均值; N'为样本数量。

为将提取出的语义特征区分为公共特征和个性特征, 设定阈值θ, 当某一特征维度的方差小于或等于θ时, 则被认为是公共特征; 当方差大于θ时, 则被认为是个性特征[19]。因此, θ越高, 更多特征会被判定为公共特征, 从而提高带宽效率, 这是因为较高的θ将允许变化较小的特征被视为图像间的共性, 但这可能导致忽略部分个性特征, 进而影响图像的质量。θ的选取可以通过实验调优, 以确保特征的有效分类。

从公共特征提取器中区分出的特征都会经过一个全连接层进行压缩, 将语义特征进行压缩, 进入通信信道中。全连接层的主要作用是对语义特征进行降维, 从而减少传输过程中所需的带宽, 同时, 保留关键的语义信息, 确保高质量的图像传输。具体来说, 假设输入的语义特征维度为M, 全连接层的输出为C维, 该压缩过程可表示为

$$\boldsymbol{y} = \boldsymbol{W}\boldsymbol{x} + \boldsymbol{b} \tag{14}$$

式中: $\boldsymbol{W}\in\mathbf{R}^{C\times M}$为全连接层的权重矩阵; $\boldsymbol{b}\in\mathbf{R}^{C}$为偏置项; $\boldsymbol{x}$为输入的语义特征; $\boldsymbol{y}$为经过压缩后的输出特征。

压缩后的公共特征$\boldsymbol{W}'_{I\mathrm{c}}$被映射到一个共享的信道子集$\boldsymbol{H}_{\mathrm{c}}$, 复用相同的时频资源。映射函数可以定义为

$$\boldsymbol{y}_{\mathrm{c}} = \boldsymbol{H}_{\mathrm{c}}\boldsymbol{P}_{\mathrm{c}}\boldsymbol{W}'_{I\mathrm{c}} + \boldsymbol{n}_{\mathrm{c}} \tag{15}$$

式中: $\boldsymbol{H}_{\mathrm{c}}$为公共特征对应的信道矩阵; $\boldsymbol{P}_{\mathrm{c}}$为功率分配矩阵; $\boldsymbol{n}_{\mathrm{c}}$为共享信道中的高斯噪声, $\boldsymbol{n}_{\mathrm{c}}\sim N(0,\sigma^2)$; $\boldsymbol{y}_{\mathrm{c}}$为经过压缩后的公共输出特征。

压缩后的个性特征$\boldsymbol{W}'_{I\mathrm{i}}$被分配到独立的信道子集$H_{I\mathrm{i}}=\{\boldsymbol{H}_1,\boldsymbol{H}_2,\cdots,\boldsymbol{H}_K\}$, K为个性特征的总个数, 每个个性特征通过独立的时频资源进行传输, 该过程表示为

$$\boldsymbol{y}_{k'} = \boldsymbol{H}_{k'}\boldsymbol{P}_{k'}\boldsymbol{W}'_{k'} + \boldsymbol{n}_{k'} \tag{16}$$

式中: $\boldsymbol{H}_{k'}$为第k'个个性特征的信道矩阵; $\boldsymbol{P}_{k'}$为独立的功率分配矩阵; $\boldsymbol{n}_{k'}$为对应信道的高斯噪声, $\boldsymbol{n}_{k'}\sim N(0,\sigma^2)$; $\boldsymbol{y}_{k'}$为经过压缩后第k'个个性输出特征。

根据上述分析, 不同的图像中存在大量公共特征, 因此, 在传输这些图像时, 所使用的带宽资源是可以重叠的。假设共有N'张图像需要进行传输, 不同图像$n'(1\leqslant n'\leqslant N')$在传输过程中占用的带宽资源表示为$b_{n'}$, 其对应的带宽开销为$B_{n'}=|b_{n'}|$。为进一步衡量传输过程中图像在频域的重复利用率, 定义语义信息重用率S_{or}对其进行度量[18], 表示为

$$S_{\mathrm{or}} = \frac{|b_1\cap b_2\cap\cdots\cap b_{N'}|}{|b_1|+|b_2|+\cdots+|b_{N'}|} \tag{17}$$

其反映了图像传输过程中共性特征的资源重用程度和带宽效率。

3　实验结果与分析

3.1　实验设置

为验证以 Swin Transformer 为骨干网络基于特征划分传输的无线图像传输系统的端到端传输性能, 对该系统与几个基准测试进行比较。

由于语义编、解码仅采用 2 个阶段的 Swin Transformer, 因此, 属于低计算度语义编、解码器, 在此选择低分辨率图像以降低计算负担并提高处理效率。本节的所有结果均使用 CIFAR10 数据集中尺寸为 32×32×3(高度×宽度×通道)的图像训练和评价的模型获得。训练和测试集由完全不同的图像组成, 分别包含 50 000 和 10 000 张图像。批处理大小为 128, 从中随机配对 64 对进行传输, 所有绘制结果都是从评估数据集上每个图像通道的 10 次实现中获得的平均值。

在训练阶段, 使用学习率为1×10^{-4}的 Adam 优化器。所有模型训练与部署均以 Pytorch 为架构实现, 模型使用单块 RTX 3090 GPU 训练。对于 CIFAR10 数据集, 在语义特征提取部分, 采用 2 个阶段, 并将窗口大小设置为 2。特别注意, 由于低分辨率图像本身包含较少的细节信息, 较小的窗口能够集中捕捉局部区域的关键特征, 因此, 选择较小的窗口有助于在低分辨率图像上高效提取局部特征[15]。

而端到端的图像传输包括信源信道编码和无线信道传输 2 个主要模块。因此, 对比方法包括: 基于 Swin Transformer 的无线图像传输方法 (记作 WITT)[16]; 基于 CNN 的 Deep JSCC 方法(记作 Deep JSCC)[11]; 经典分离式信源信道编码 BPG 方法(H.265 视频编码标准的帧内图像编码方法)[21], 并结合实际应用的 5G 标准低密度奇偶校验码 (low-density parity-check, LDPC) 信道编码[22](记为 BPG+LDPC)。在此, 采用块长度为 6 144 bit 的 5G LDPC 码, 支持不同的编码速率和正交幅度调制(quadrature amplitude modulation, QAM)。本文考虑了在 AWGN 信道和瑞利衰落信道下的性能测试。为确保实验设置的一致性和公平性, 信道输入的每 2 个连续实符号被合并为一个复信道输入符号, 并在信道中加入复高斯噪声。

本文研究的是非任务驱动的语义图像传输方

法，旨在优化图像传输质量和提高传输效率。实验使用广泛应用的像素级度量指标PSNR和结构相似性指数(structural similarity index measure, SSIM)对本文模型和其他端到端传输模型进行性能评估，并利用语义信息重用率对传输过程中图像在频域的重复利用率进行度量。

PSNR对应于像素级的L2欧氏距离，因此，当评估模型在PSNR上的表现时，将失真d设置为信源图像$\boldsymbol{I}$和重构图像$\hat{\boldsymbol{I}}$间的均方误差(mean squared error, MSE)：

$$R_{\mathrm{PSNR}}=10\lg\left(\frac{X_{\mathrm{MAX}}^2}{E_{\mathrm{MSE}}}\right) \tag{18}$$

式中：R_{PSNR}为峰值信噪比；E_{MSE}为均方误差；X_{MAX}为图像像素的最大可能值[11]，对于在单个颜色通道中具有8位像素的图像，X_{MAX}值为255。因此，最小化MSE导致最大化PSNR。

SSIM描述了接收端的重建图像与发送端的原始图像之间的相似性：

$$I_{\mathrm{SSIM}}(\boldsymbol{X},\hat{\boldsymbol{X}})=\frac{(2\mu_X\mu_{\hat{X}}+C_1)(2\sigma_{X\hat{X}}+C_2)}{(\mu_X^2+\mu_{\hat{X}}^2+C_1)(\sigma_X^2+\sigma_{\hat{X}}^2+C_2)} \tag{19}$$

式中：$\boldsymbol{X}$和$\hat{\boldsymbol{X}}$分别为原始图像和重建图像的局部区域；μ_X和σ_X^2分别为$\boldsymbol{X}$的均值和方差；$\sigma_{X\hat{X}}$为$\boldsymbol{X}$与$\hat{\boldsymbol{X}}$之间的协方差；C_1、C_2是为避免分母为0而引入的常数。

3.2 仿真结果分析

如图8所示，随着阈值增大，语义信息重用率逐渐上升。这表明，随着阈值的增大，更多的公共特征被提取，从而提高了带宽的重用效率。从图8可以看出，在较低阈值时，语义信息重用率提高近40%，说明阈值较低时，公共特征的提取数量较多，有效提升带宽利用率。而在较高阈值下，语义信息重用率的增长趋于平缓，仅提升约20%，这表明在较高阈值下，增加公共特征数量对带宽利用率的提升效果有限。因此，阈值的合理选择对于优化带宽利用和图像恢复质量至关重要，过高的阈值可能导致公共特征的过度重用，影响传输质量。

图9展示了在AWGN信道下的图像传输质量。可知在不同的语义信息重用率下本文方法的图像传输质量。黑色线条表示带宽占用率，即在传输语义信息过程中所需要的实际带宽与原始带宽之间的比例。可以看出，随着语义信息重用率的增加，带宽占用率逐步降低。当传输相同的语义信息量时，带宽占用量仅为原始带宽占用量的一半。红色线条展示了本文方法在不同语义信息重用率下的性能变化情况。可以观察到，当语义信息重用率达到0.3时，图像传输质量接近于语义信息重用率为0时的图像传输质量，说明此时能够节省大约15%的带宽资源。然而，当语义信息重用率超过0.3时，尽管带宽节省更多，但恢复性能开始逐步下降。这表明重用语义信息在提升带宽效率的同时，也对图像恢复质量产生一定的影响。

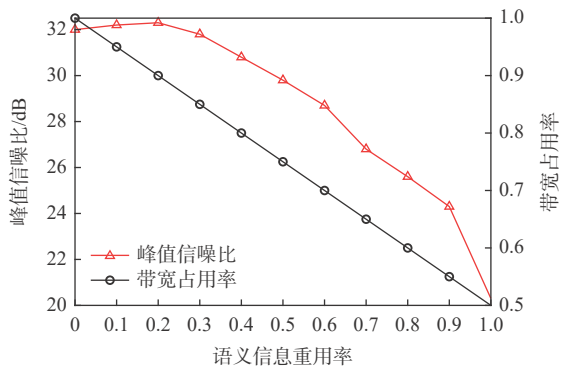


图9 图像传输质量随语义信息重用率的变化

Fig. 9 Variation of image transmission quality with semantic information reuse rate

图10展示了在AWGN信道下CBR=1/3时的图像传输质量。可知，在不同SNR条件下，不同的传输方法表现出了不同的图像传输质量。本文方法(语义信息重用率为0.3)与基于CNN的Deep JSCC方法相比，展现出了更好的性能表现，不仅节省了带宽，而且在不同SNR条件下都能够实现较

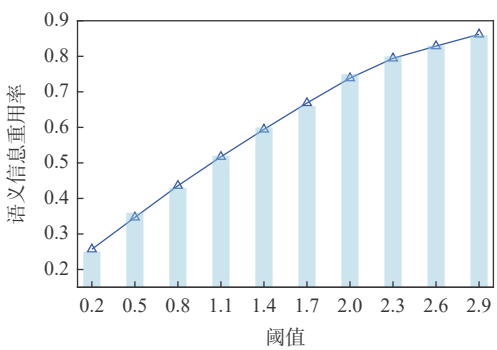


图8 语义信息重用率随阈值的变化

Fig. 8 Variation of semantic information reuse rate with threshold

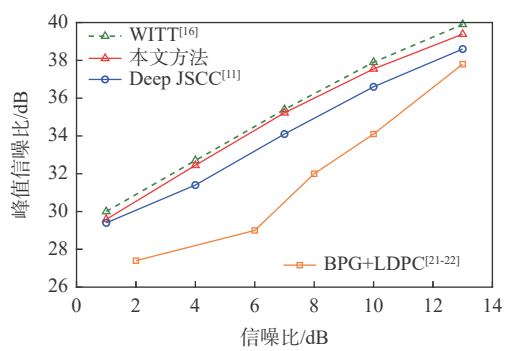


图10 AWGN信道下CBR=1/3时的图像传输质量

Fig. 10 Image transmission quality at CBR=1/3 over AWGN channel

高的 PSNR 值。此外, 本文方法表现性能较 WITT 方法有所下降, 其原因在于本文方法共性特征通过相同的时频资源进行传输, 可能导致信息丢失或传输不足, 特别是在信道质量较差时。相比之下, 不区分传输时, 共性和个性特征都能通过多次传输得到更多冗余, 增强了系统的鲁棒性, 避免了信息丢失。

图 11 展示了在 AWGN 信道下当 SNR=10 dB 时 PSNR 与 CBR 之间的关系。可以看出, 随着 CBR 值增加, 各方法的图像质量逐渐上升。此外, 本文方法(语义信息重用率为 0.3)在低 CBR 条件下, 相较于基于 CNN 的 Deep JSCC 方法及 BPG+LDPC 方法, 仍能保持较高的 PSNR 值, 表现出了较强的鲁棒性和适应性, 能够在低带宽环境下有效维持图像质量。尽管相较 WITT 方法, 本文方法在性能上有小幅度下降, 但本文方法通过在特征传输上进行有效区分, 减少了传输中的冗余信息, 从而节约了带宽资源。此外, 在 CBR = 0.5 时, Deep JSCC 方法和 BPG+LDPC 方法的 PSNR 值相交, 这是因为随着 CBR 的提高, Deep JSCC 方法的联合信源信道编码优势逐渐减弱, 而 BPG+LDPC 方法在较高压缩比时能更好地利用信道容量进行图像恢复。

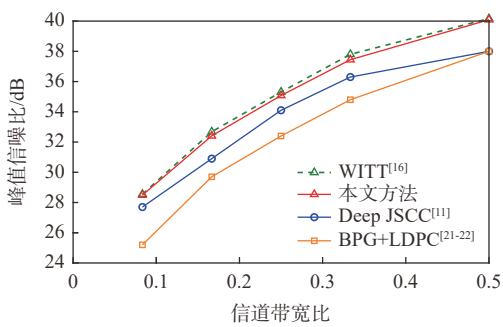


图 11　AWGN 信道下 SNR=10 dB 时的图像传输质量

Fig. 11　Image transmission quality at SNR=10 dB over AWGN channel

由图 12 可以看出, 在瑞利衰落信道下, 当 CBR=1/3 时, 不同 SNR 条件下的图像传输质量随 SNR 的提升而逐渐改善, 表现为 PSNR 值随着 SNR 的增加而上升, 即图像传输质量稳步提高。尽管本文方法(语义信息重用率为 0.3)相比 WITT 方法的传输质量略有下降, 但仍比 Deep JSCC 方法和 BPG+LDPC 方法表现出更佳的图像质量, 具有明显的相对优势。在较低 SNR 条件下, 由于噪声较大, 共性信息和个性信息可能会部分丢失或受到损坏, 进而对传输质量产生一定影响。不过总体而言, 本文方法在各类 SNR 环境下均能保持良好的图像质量, 从而提升了传输效果的稳定性。此外, 在 SNR = 11 dB 时, BPG+LDPC 方法与 Deep JSCC 方法的 PSNR 值接近, 这是由于 BPG+LDPC 方法在较高 SNR 下能更

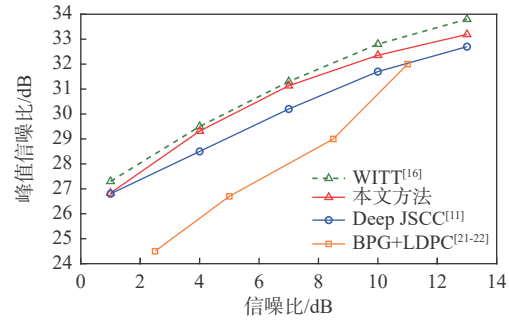


图 12　瑞利衰落信道下 CBR=1/3 时的图像传输质量

Fig. 12　Image transmission quality at CBR=1/3 over Rayleigh channel

好地发挥其信道编码的纠错能力, 导致其性能接近于 Deep JSCC 方法。

图 13 展示了在瑞利衰落信道下 SNR=3 dB 时 PSNR 与 CBR 的关系。可以看出, 本文方法(语义信息重用率为 0.3)对比 Deep JSCC 方法及 BPG+LDPC 方法, 都展示出了更好的性能表现。另外, 值得注意的是, 当 CBR 较大时, 本文方法对比 WITT 方法, 传输质量也非常接近, 这是由于在信道带宽较大的情况下, 系统的传输能力增强, 能够同时处理更多数据, 因此, 分开传输特征的方式对性能的影响变得较小。

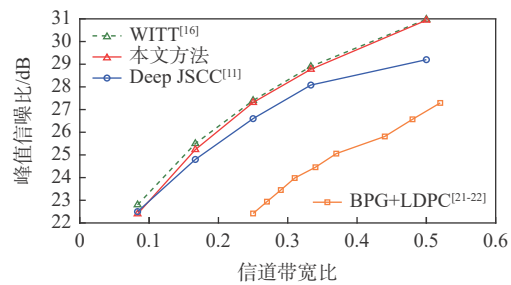


图 13　瑞利衰落信道下 SNR=3 dB 时的图像传输质量

Fig. 13　Image transmission quality at SNR=3 dB over Rayleigh channel

为更全面地评估本文方法的性能, 进一步通过 SSIM 对实验结果进行了分析。SSIM 作为一种衡量图像质量的感知度量, 能够较好地反映图像的结构相似性、亮度和对比度等感知特性。图 14 展示了在瑞利衰落信道下 CBR=1/3 时 SSIM 与 SNR 之间的关系。实验结果显示, 随着 SNR 的提升, 所有方法的 SSIM 值均呈现增长趋势, 本文方法(语义信息重用率为 0.3)在各 SNR 条件下的 SSIM 值始终优于 Deep JSCC 方法和 BPG+LDPC 方法。结合图 12 中的 PSNR 结果表明, 相比传统图像传输方法, Deep JSCC 方法在图像质量上表现更佳。这是因为传统方法优化 MSE, 而深度学习方法通过学习驱动, 更有效地保留和恢复图像细节, 提升了图像质量。

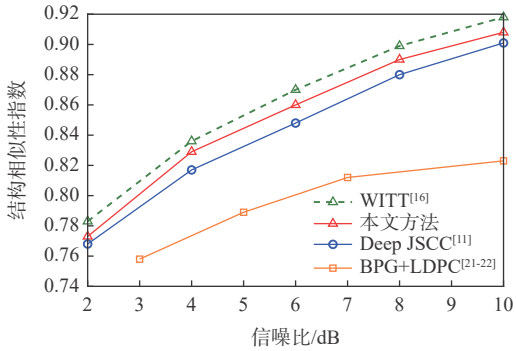


图 14 瑞利衰落信道下 CBR=1/3 时的 SSIM 性能

Fig. 14 SSIM performance at CBR=1/3 over Rayleigh channel

4 结 论

1）采用 Swin Transformer 作为网络架构，相比传统的基于 CNN 的 Deep JSCC 方法，本文方法在各 SNR 条件下都实现了更高的 PSNR。

2）在低 SNR 条件下，通过优化图像特征的传输方式，本文方法在保证图像质量的同时，节省了带宽。

3）通过区分公共特征和个性特征，本文方法有效降低了带宽需求，能够显著提升通信系统的整体性能，并降低传输成本。

因此，本文提出的基于 Swin Transformer 的共性和个性信息传输策略为图像传输系统的优化和性能提升提供了一种有效的解决方案。在后续研究中，可以针对基于 Swin Transformer 的多用户的图像传输问题进行探讨。

参考文献（References）

[1] Dai J C, Zhang P, Niu K, et al. Communication beyond transmitting bits: semantics-guided source and channel coding[J]. IEEE Wireless Communications, 2023, 30(4): 170-177.

[2] 张振国, 杨倩倩, 贺诗波. 基于深度学习的图像语义通信系统[J]. 中兴通讯技术, 2023, 29(2): 54-61.
Zhang Z G, Yang Q Q, He S B. Image semantic communication system based on deep learning[J]. ZTE Technology Journal, 2023, 29(2): 54-61(in Chinese).

[3] Huang D L, Gao F F, Tao X M, et al. Toward semantic communications: deep learning-based image semantic coding[J]. IEEE Journal on Selected Areas in Communications, 2023, 41(1): 55-71.

[4] Xie H Q, Qin Z J, Li G Y, et al. Deep learning enabled semantic communication systems[J]. IEEE Transactions on Signal Processing, 2021, 69: 2663-2675.

[5] 刘传宏, 郭彩丽, 杨洋, 等. 面向智能任务的语义通信: 理论、技术和挑战[J]. 通信学报, 2022, 43(6): 41-57.
Liu C H, Guo C L, Yang Y, et al. Intelligent task-oriented semantic communications: theory, technology and challenges[J]. Journal on Communications, 2022, 43(6): 41-57(in Chinese).

[6] 张平, 戴金晟, 张育铭, 等. 面向语义通信的非线性变换编码[J]. 通信学报, 2023, 44(4): 1-14.
Zhang P, Dai J S, Zhang Y M, et al. Nonlinear transform coding for semantic communications[J]. Journal on Communications, 2023, 44(4): 1-14(in Chinese).

[7] Zhang Y C, Zhao H T, Wei J B, et al. Context-based semantic communication via dynamic programming[J]. IEEE Transactions on Cognitive Communications and Networking, 2022, 8(3): 1453-1467.

[8] 江沸菠, 彭于波, 董莉. 面向 6G 的深度图像语义通信模型[J]. 通信学报, 2023, 44(3): 198-208.
Jiang F B, Peng Y B, Dong L. Deep image semantic communication model for 6G[J]. Journal on Communications, 2023, 44(3): 198-208(in Chinese).

[9] Weng Z Z, Qin Z J. Semantic communication systems for speech transmission[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(8): 2434-2444.

[10] Yoo H, Dai L L, Kim S, et al. On the role of ViT and CNN in semantic communications: analysis and prototype validation[J]. IEEE Access, 2023, 11: 71528-71541.

[11] Bourtsoulatze E, Burth Kurka D, Gündüz D. Deep joint source-channel coding for wireless image transmission[J]. IEEE Transactions on Cognitive Communications and Networking, 2019, 5(3): 567-579.

[12] Kurka D B, Gündüz D. DeepJSCC-f: deep joint source-channel coding of images with feedback[J]. IEEE Journal on Selected Areas in Information Theory, 2020, 1(1): 178-193.

[13] Xu J L, Tung T Y, Ai B, et al. Deep joint source-channel coding for semantic communications[J]. IEEE Communications Magazine, 2023, 61(11): 42-48.

[14] Xu J L, Ai B, Chen W, et al. Wireless image transmission using deep source channel coding with attention modules[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2022, 32(4): 2315-2328.

[15] Liu Z, Lin Y T, Cao Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C]//Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2022: 9992-10002.

[16] Yang K, Wang S X, Dai J C, et al. WITT: a wireless image transmission transformer for semantic communications[C]//Proceedings of the 2023 IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE Press, 2023: 1-5.

[17] Nguyen L X, Tun Y L, Tun Y K, et al. Swin transformer-based dynamic semantic communication for multi-user with different computing capacity[J]. IEEE Transactions on Vehicular Technology, 2024, 73(6): 8957-8972.

[18] Chen G, Nan G S, Jiang Z H, et al. Lightweight and robust wireless semantic communications[J]. IEEE Communications Letters, 2024, 28(11): 2633-2637.

[19] Zhang P, Xu X D, Dong C, et al. Model division multiple access for semantic communications[J]. Frontiers of Information Technology & Electronic Engineering, 2023, 24(6): 801-812.

[20] Zhang P, Xu W J, Liu Y M, et al. Intellicise wireless networks from semantic communications: a survey, research issues, and challenges[J]. IEEE Communications Surveys & Tutorials, 2025, 27(3): 2051-2084.

[21] Albalawi U, Mohanty S P, Kougianos E. A hardware architecture for better portable graphics (BPG) compression encoder[C]//Proceedings of the 2015 IEEE International Symposium on Nanoelectronic and Information Systems. Piscataway: IEEE Press, 2015: 291-296.

[22] Richardson T, Kudekar S. Design of low-density parity check codes for 5G new radio[J]. IEEE Communications Magazine, 2018, 56(3): 28-34.

Swin Transformer-based semantic image transmission with model division multiplexing

PENG Yi[1, 2], SUN Chang[1, 2], YANG Qingqing[2, *], LI Hui[2], WANG Jianming[2]

(1. School of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650031, China;
2. Yunnan Key Laboratory of Computer Technology Application, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: Communication efficiency is greatly increased via semantic communication, a new paradigm for next-generation communication systems. However, previous works on semantic image transmission were mostly built upon convolutional neural networks (CNN). Traditional CNN-based models often struggle to comprehensively extract the semantic information embedded in images. To address this limitation, this paper adopts the Swin Transformer as the backbone network to effectively capture semantic information. Based on this, a novel semantic image transmission method leveraging model division is proposed. This method achieves the independent transmission of public and personalized features through feature separation. Specifically, after the input image undergoes joint source-channel coding (JSCC), the encoded semantic features are categorized into public features and personalized features, which are then transmitted separately. By enabling resource sharing for public features, the proposed method significantly reduces bandwidth requirements, thereby improving transmission efficiency. To evaluate the performance of the proposed model, experiments are conducted on the publicly available CIFAR10 dataset, comparing the proposed method with traditional approaches. The experimental results demonstrate that the proposed method effectively improves image transmission quality. Furthermore, it achieves superior performance in terms of transmission efficiency and bandwidth savings. In order to overcome bandwidth limitations in semantic picture transfer while preserving high-quality image reconstruction, this work offers a promising alternative.

Keywords: semantic communication; image transmission; model division multiple access; image reconstruction; Swin Transformer

Received: 2024-07-18; **Accepted**: 2024-12-20; **Published Online**: 2025-01-16 13:40

URL: link.cnki.net/urlid/11.2625.V.20250115.1641.001

Foundation items: National Natural Science Foundation of China (62461030); Key Program of the Yunnan Provincial Basic Research Plan (202401AS070105)

* **Corresponding author**. E-mail: 12309214@kust.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0557

基于多模态时空特征融合的终端区交通拥堵精细化预测

李善梅*，宋思霓，王红勇，王端阳，赵末
(中国民航大学 空中交通管理学院，天津 300300)

摘 要：为提升对终端区未来交通态势把握的准确性和精细化，提出一套基于多模态时空特征融合的交通拥堵预测方法。从航空器滞留和管制负荷角度，采用交通流聚类技术，提出一种考虑交通流异质性的交通拥堵指数计算方法；将终端区空域进行四维时空区块划分，以时空区块为节点，构建动态邻接网络和交通流网络，表征终端区多模态的动态空间相关特征；提出一种基于三维卷积神经网络(3DCNN)+图卷积网络(GCN)+门控循环单元(GRU)的终端区交通拥堵预测模型。采用北京终端区航迹数据进行模型验证，结果表明：所提模型优于经典基线模型，与45 min和60 min时间尺度相比，30 min预测效果最好，相较于历史平均(HA)模型、指数加权平均(EMA)模型、支持向量机回归(SVR)模型，均方根误差(RMSE)和平均绝对误差(MAE)分别下降了21%和57%、38%和72%、19%和51%；相较于只学习邻接空间特征、只学习交通流空间特征、改用长短时记忆(LSTM)学习时间特征，所提模型的RMSE和MAE分别下降了36%和40%、6%和8%、2%和2%。预测结果表明：航迹越复杂的区域，其预测误差越大，且随空域高度的上升，预测误差呈现出先增大后减小的变化规律。

关 键 词：航空运输；拥堵预测；深度学习；交通流网络；四维航迹
中图分类号：V355
文献标志码：A **文章编号**：1001-5965(2026)11-3852-12

近年来，随着中国民航业高速发展，航班量的快速增长加速了空中交通供需矛盾，导致空中交通拥堵现象愈演愈烈。终端区空域因其结构复杂、航班运行状态多样、飞行冲突多发、飞行受限多元、管制员工作负荷加大，成为空中交通拥堵最严重的空域，严重威胁交通运行安全与效率。因此，终端区交通拥堵状态的准确预测，有助于提高空中交通管理人员的态势感知能力，以便及时采取管控措施。

空中交通拥堵度量是拥堵预测的前提。目前，国内外关于拥堵度量方法的研究尚没有统一标准，主要分别从空中交通流的流动特性和航班群的复杂特性2个方面展开研究。交通流动特性方面，主要采用流量、速度、密度3个参数，对交通拥堵进行度量。比较有代表性的有：殷建棠等[1]将航段单位长度飞机平均飞行时间作为航段拥堵评估指标；李桂毅等[2]建立当量交通量、接近度、饱和度和交通密度4个扇区拥挤特征指标；Williams等[3]采用航班正常率、容流比和航班延误等指标度量交通拥堵。航班群复杂特性方面，主要采用飞行冲突数量、航班接近率等航空器相对位置的复杂特征对交通拥堵进行度量。比较有代表性的有：李善梅等[4]从复杂性的角度，构建了滞留度指标、汇聚度指标和当量交通量指标，进而度量交叉航路的交通拥堵态势；Tan等[5]以飞机为节点构建飞机网络，采用节

收稿日期：2024-07-21；录用日期：2024-08-23；网络出版时间：2024-09-05 10:38
网络出版地址：link.cnki.net/urlid/11.2625.V.20240904.1558.001
基金项目：国家自然科学基金(52672428,52202404)；天津市自然科学基金(24JCYBJC01170)；中国民航大学研究生科研创新项目(2025YJSKC03001)
*通信作者. E-mail：sm-li@cauc.edu.cn

引用格式：李善梅，宋思霓，王红勇，等. 基于多模态时空特征融合的终端区交通拥堵精细化预测[J]. 北京航空航天大学学报，2026，52(11)：3852-3863. Li S M，Song S N，Wang H Y，et al. Refined prediction of terminal area traffic congestion based on multimodal spatio-temporal feature fusion[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3852-3863 (in Chinese).

点数、边数、平均节点度、环路数、平均聚类系数、平均路径长度、平均节点强度等 7 个网络复杂度指标作为扇区拥塞的度量指标。

上述研究主要从空中交通拥堵特征出发, 构建拥堵度量指标。与地面交通不同, 航空器的运行主要是在管制员的指挥下完成, 拥堵状态下往往伴随管制员工作负荷的增加。因此, 空中交通拥堵度量不仅应能体现空中交通流的流动和复杂特征, 还应能在一定程度上反映管制负荷的高低, 这样度量出来的结果更易被管制员接受并采纳。

空中交通拥堵预测方面, 主要有模型驱动和数据驱动方法。模型驱动方法主要通过构建数学预测模型。Lin 等[6] 引入概率统计模型对整个飞行过程中的随机因子进行建模, 进而实现对飞行轨迹的预测。张军峰等[7] 采用航空器意图模型、航空器动力与运动学模型相结合的方法, 实现了航空器四维航迹预测模型。Saraf 等[8] 提出一种自适应欧拉模型, 用于预测扇区流量。上述研究大多基于理想化的假设条件, 尽管模型较为明确, 但对于空中交通系统这样一个高维非线性问题来说, 其建模复杂性相对较大、处理能力有限, 导致预测精度不高。数据驱动方法是以真实的航班运行数据为基础, 利用数据科学与机器学习等理论和方法, 通过样本数据的训练、学习、迭代、进化, 挖掘交通参数演化的内在规律, 进而对未来交通态势进行预测。毛利民等[9] 建立了基于随机森林的终端区小时起降容量预测模型。李桂毅等[10] 等基于集成学习算法构建了一种航路交通拥挤识别模型, 实现高精度路网航段拥挤识别。Khanmohammadi 等[11] 提出双模型预测人工神经网络(dual-model prediction artificial neural network, DMP-ANN), 用于预测机场航班延误。Cai 等[12] 提出一种基于时间注意力感知的二部图卷积网络(temporal attention aware dual-graph convolution network, TAaDGCN)模型, 用于预测空中交通流量。焦卫东等[13] 提出一种基于融合多尺度卷积网络和时空双重注意力的时间卷积网络模型, 实现高精度航迹预测。Wang 等[14] 提出基于注意力机制的一维卷积神经网络(one-dimensional convolutional neural network, 1DCNN)-长短时记忆(long short-term memory, LSTM)短期交通流预测模型。刘晓琳等[15] 提出一种基于注意力机制的自适应图卷积门控循环单元 (attention-based adaptive graph convolution-gated recurrent unit, AAGC-GRU) 的航班延误预测模型。现有基于深度学习的空中交通预测取得了较为不错的预测效果, 但大多将三维空域抽象为二维进行研究, 缺乏从四维时空角度对空中交通态势演化规律进行研究, 以及将深度学习技术应用于终端区四维时空拥堵预测问题。

综上所述, 现有终端区交通拥堵度量及预测研究存在如下不足:

1) 现有研究多是从交通流滞留和航班群复杂角度构建平均意义下的拥堵指标, 不能充分反映管制负荷的大小, 导致度量结果与管制员的拥堵感知存在偏差, 较难被其接受。

2) 现有研究主要针对扇区交通拥堵进行预测, 缺乏从四维时空角度对扇区内部拥堵态势的精细化预测, 而这正是未来基于航迹运行(trajectory-based operations, TBO)空管模式有效运行的基础和关键。

3) 终端区交通运行具有较强的时空相关性。现有研究多从交通流拥堵参数时间序列中对交通状态演化的时间特征进行挖掘, 而终端区交通拥堵具有较强的空间相关特征, 且不同模态网络下呈现出不同的空间特征。

针对上述不足, 本文以终端区交通为研究对象, 首先, 提出一种同时考虑交通流动特性和管制负荷的拥堵指数计算方法; 然后, 精细划分终端区时空区块, 计算各区块拥堵指数, 并分析交通拥堵的时空分布特征; 在此基础上, 构建一种基于三维卷积神经网络(three-dimensional convolutional neural network, 3DCCN)、图卷积网络(graph convolutional networks, GCN)和门控循环单元(gated recurrent unit, GRU)相结合的终端区交通拥堵精细化预测模型, 该模型不仅能学习终端区拥堵时间相关性, 还能同时学习邻接网络和交通流网络的空间相关性; 最后, 采用北京终端区的实际航迹数据, 对本文模型的有效性进行验证。与现有空中交通拥堵度量及其预测方法相比, 本文工作有助于提升空管人员对终端区交通拥堵程度掌握的精细化、科学性和准确性, 以便采取更有效的拥堵管理措施, 也为未来 TBO 空管模式的实现提供理论基础。

1　空中交通拥堵度量

1.1　空中交通拥堵定义及拥堵指数建立

目前, 空中交通拥堵的定义尚没有统一标准。本文参考前人研究成果, 将空中交通拥堵定义为: 在一定时间和空间范围内, 由于空域需求大于空域容量而造成的航空器滞留现象[16-17]。滞留现象具体表现为, 交通拥堵态势下管制员往往指挥航空器进行绕飞、盘旋等待、减速等行为, 导致航空器在空域内的飞行时间增长, 交通流在空域内的流动速度变慢, 管制员为航空器提供管制服务的时间增多、工作负荷增大等。

基于空中交通拥堵定义及拥堵态势下航空器飞行时间变长的特点, 采用飞行时间构建单架航空器的拥堵指数φ_j, 计算式为

$$\varphi_j=\begin{cases}0 & t_j<T\\ (t_j-T)/T & t_j\geqslant T\end{cases} \tag{1}$$

式中：t_j为第j架航空器的实际飞行时间；T为航空器的标准飞行时间。

本文采用第j架航空器所在交通流中所有航空器的平均飞行时间，即

$$T=\sum_{j=1}^{n}\frac{t_j}{n} \tag{2}$$

式中：n为航空器数量。

目前，地面交通拥堵度量方法较为成熟，一般只需计算交通流中所有车辆的平均速度、平均行程时间等，表征交通流拥堵程度。与地面交通不同，航空器飞行是在管制员指挥下完成的，空中交通拥堵度量不仅要能反映空中交通流动快慢，也要能反映管制员工作负荷大小。若不同时段交通流的平均拥堵指数相同，但航空器数量不同，则对于管制员来说数量多的时段更为拥堵。另外，空域中往往存在多条交通流，且各交通流所对应飞行路径长度和飞行时间不同。如图1所示，空域中存在2条交通流，交通流A和B的标准飞行时间分别为20 min和10 min，该空域总体的标准飞行时间为15 min。若2条交通流各有一架航空器，实际飞行时间分别为20 min和10 min。若不考虑交通流异质性，该空域拥堵指数为max((20−15)/15,0)+max((10−15)/15,0)=1/3，实际上，2架航空器的实际飞行时间均未超过其所属交通流的标准飞行时间，该空域并未发生交通拥堵，拥堵指数为0。另外，终端区航空器的飞行时间主要受三维飞行路径长短的影响，相同路径下不同机型的飞行时间差与不同路径引起的飞行时间差比起来要小很多，因此，这里忽略不同机型对航空器平均飞行时间的影响。因此，考虑交通流异质性，构建综合表征交通流动快慢和管制负荷的交通拥堵指数，计算式为

$$\begin{cases}\varphi=\displaystyle\sum_{i=1}^{m}\sum_{j=1}^{n_i}\varphi_{ij}\\ \varphi_{ij}=\begin{cases}0 & t_{ij}<T_i\\ (t_{ij}-T_i)/T_i & t_{ij}\geqslant T_i\end{cases}\end{cases} \tag{3}$$

式中：φ_{ij}为某时空区块内第i条交通流第j个航空器所飞航迹的拥堵指数；t_{ij}为第i条交通流第j个航空器所飞航迹的飞行时间；T_i为第i条交通流的标准飞行时间；m为交通流的条数；n_i为第i条交通流的航迹条数；φ为平均拥堵指数，其值越大说明该区块越拥堵，反之越畅通。

1.2 空中交通拥堵指数计算流程

基于式(1)～式(3)，设计空中交通拥堵指数计算流程如下。

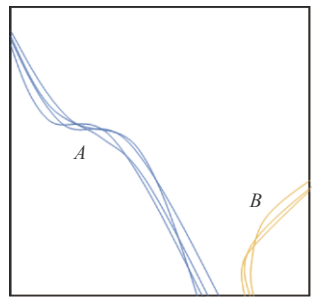


图1 不同交通流航迹

Fig. 1 Track of different traffic flows

步骤1 航迹数据预处理。受采集设备故障、恶劣天气等因素的影响，原始航迹数据中含有异常、缺失等问题。因此，首先对航迹数据进行预处理，主要包括：采用Z-score法进行异常值处理，通过线性插值将原航迹数据填充为1 s时间间隔的航迹点序列，以及对插值后航迹数据进行均匀重采样等工作，为后续计算做准备。

步骤2 交通流识别。为考虑交通流异质性，需要识别交通流。由于K-means聚类方法具有计算快速简单、对高维数据处理能力较强、参数设置简单等特点，使用基于欧氏距离的K-means聚类方法对重采样后的航迹进行聚类操作。

步骤3 目标空域区块划分。为精细化挖掘空中交通拥堵的时空演化特性，采用时空分解方法将目标空域划分成大小相等的四维时空区块。先将目标空域沿经度、纬度、高度方向划分为大小相同的三维网格，实现对目标空域的空间分解，进一步，将各网格的航迹数据按时间进行划分，获取四维时空区块划分结果。

步骤4 标准飞行时间计算。计算各时空区块中各航空器实际飞行时间及各条交通流的标准飞行时间T_i。

步骤5 航空器拥堵指数计算。基于式(1)计算各时空区块中各航空器拥堵指数φ_{ij}。

步骤6 时空区块拥堵指数计算。由φ_{ij}及式(3)计算各时空区块拥堵指数φ。

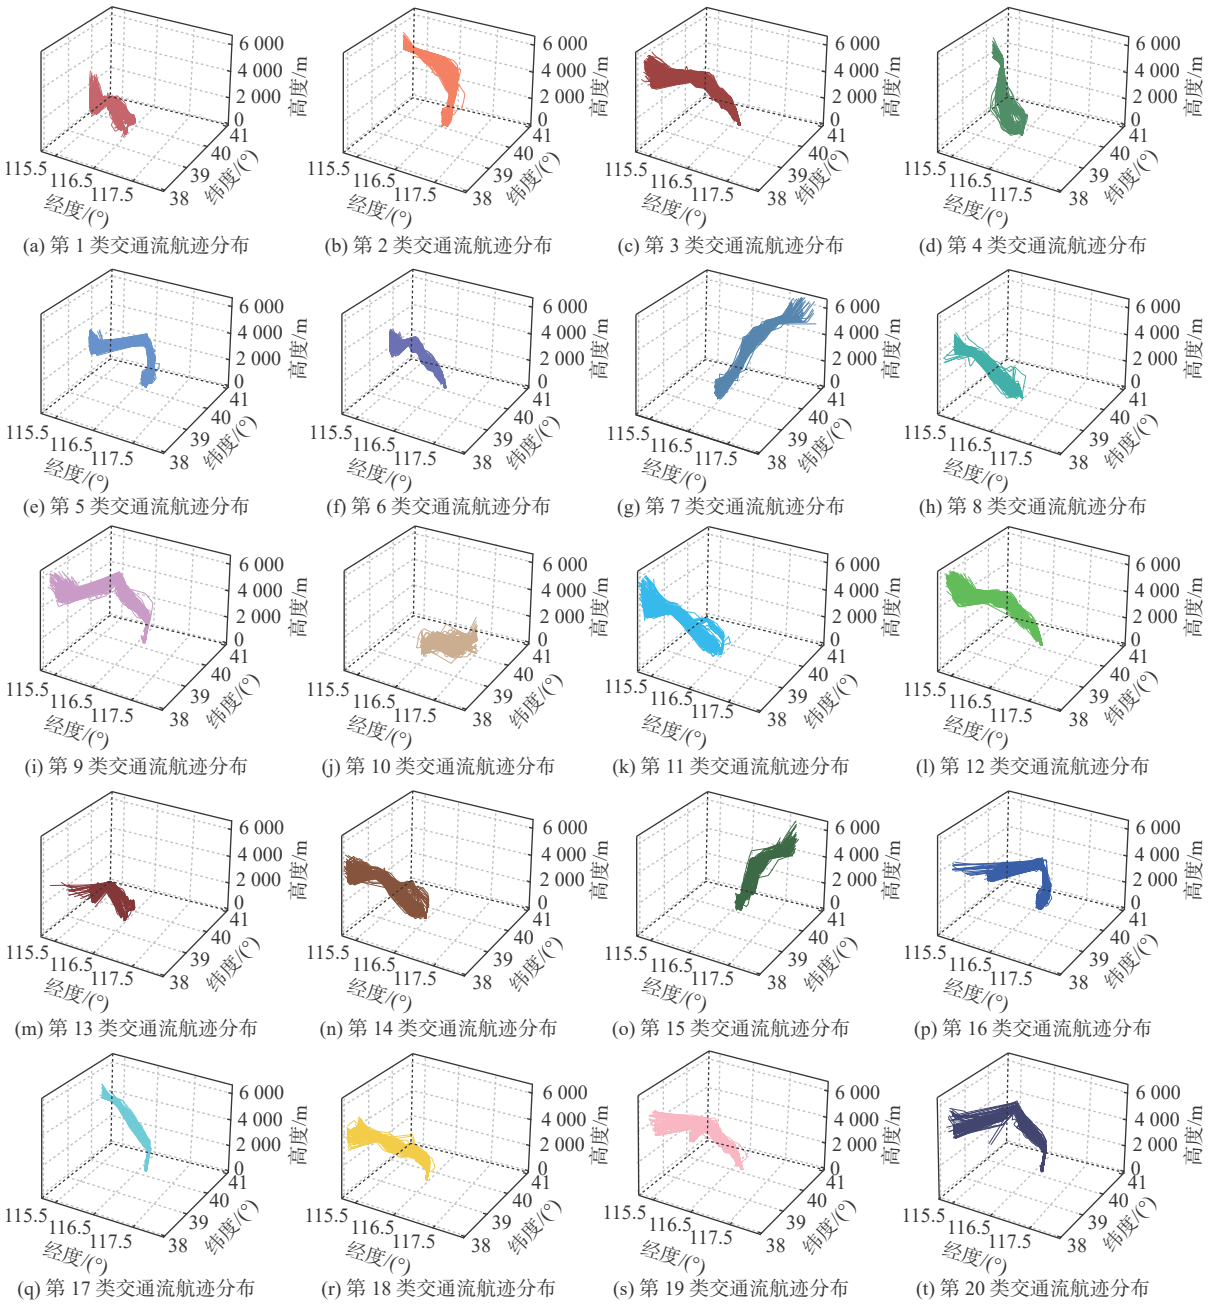
2 空中交通拥堵的时空特性分析

2.1 数据描述与拥堵指数计算

采用2023年7—9月北京终端区进场航迹数据对本文模型进行验证，包括首都机场、大兴机场及天津机场的实际进场飞行航迹各采样点的经度、纬度、速度、高度、时间等数据，共涉及99 346架航空器，约有183 472 682个航迹点。

首先，根据1.3节交通拥堵指数计算流程，对初

始航迹数据进行预处理工作, 共删除 237 个异常航迹点数据, 采用 1 s 时间间隔对航迹进行线性插值填充, 并对填充后的各条航迹进行均匀重采样操作, 使各条航迹的航迹点数均为 50 个, 便于后续航迹间相似度的计算。基于预处理后的航迹数据, 计算两两航迹之间的欧氏距离, 并采用 K-means 方法对航迹进行聚类, 从而识别终端区交通流, 识别结果如图 2 所示。



(a) 第 1 类交通流航迹分布　(b) 第 2 类交通流航迹分布　(c) 第 3 类交通流航迹分布　(d) 第 4 类交通流航迹分布

(e) 第 5 类交通流航迹分布　(f) 第 6 类交通流航迹分布　(g) 第 7 类交通流航迹分布　(h) 第 8 类交通流航迹分布

(i) 第 9 类交通流航迹分布　(j) 第 10 类交通流航迹分布　(k) 第 11 类交通流航迹分布　(l) 第 12 类交通流航迹分布

(m) 第 13 类交通流航迹分布　(n) 第 14 类交通流航迹分布　(o) 第 15 类交通流航迹分布　(p) 第 16 类交通流航迹分布

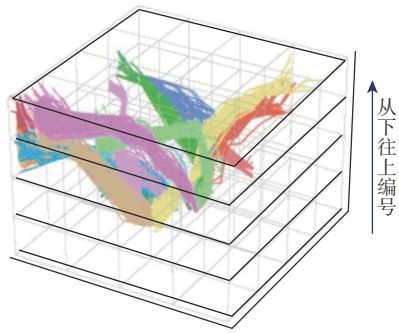
(q) 第 17 类交通流航迹分布　(r) 第 18 类交通流航迹分布　(s) 第 19 类交通流航迹分布　(t) 第 20 类交通流航迹分布

图 2　交通流识别结果

Fig. 2　Traffic flow recognition results

然后, 将北京终端区空域进行区块划分。由于北京终端区平面结构为不规则多边形, 为便于计算, 本文选取经度范围为东经 [115.2°, 118.2°], 纬度范围为北纬 [38°, 41°], 高度范围为 [0 m, 6 000 m] 的空间范围作为研究对象, 从而将北京终端区包含在内。为实现北京终端区的精细化拥堵预测, 将终端区进行三维区块划分。鉴于过小区块的交通态势信息会增大管制员对终端区运行态势掌控的复杂性, 且过大区块的交通态势信息对管制指挥意义不大, 因此, 通过咨询北京终端区一线管制员, 最终分别沿经度、纬度、高度 3 个方向, 将研究区域均匀划分为 4×4×4 个区块, 并对其进行编号, 如图 3 所示。在此基础上, 分别以 30 min、45 min、60 min 不同时间尺度对各时空区块进行时间划分, 从而将航迹数据划分到各时空区块上。

最后, 基于各时空区块的航迹数据, 按步骤 4～



(a) 空间网格划分

33	34	35	36	49	50	51	52
37	38	39	40	53	54	55	56
41	42	43	44	57	58	59	60
45	46	47	48	61	62	63	64
1	2	3	4	17	18	19	20
5	6	7	8	21	22	23	24
9	10	11	12	25	26	27	28
13	14	15	16	29	30	31	32

(b) 空间网格编号

图3 空间网格划分及编号

Fig. 3 Spatial grid partitioning and numbering

步骤6所述方法，计算各时空区块的拥堵指数。

2.2 空中交通拥堵的时空分布

基于30 min时间尺度拥堵指数计算结果，统计各时空区块的平均拥堵指数、平均飞行时长和平均交通量，限于篇幅限制，表1给出部分区块计算结果。经统计发现，27个时空区块处于拥堵指数在0～1×10^{-17}之间的畅通状态，其中，24个区块的平均交通量在1～2架之间，3个区块的平均交通量在2～2.2架之间，平均飞行时间为566.9 s；21个时空区块处于平均拥堵指数在1×10^{-17}～6×10^{-17}之间的稳定状态，其中，18个区块的平均交通量在2～5架之间，3个区块的平均交通量在1.6～1.9架之间，平均飞行时间为592.4 s；16个时空区块处于平均拥堵指数在6×10^{-17}～3×10^{-16}之间的拥堵状态，平均交通量均在5～16架之间，平均飞行时间为683.2 s。可见，时空区块的平均交通量越大，平均飞行时间越长，平均拥堵指数越高，交通拥堵越严重。

表1 交通拥堵计算结果

Table 1 Calculation results of traffic congestion

时空区块	平均拥堵指数	平均飞行时长/s	平均交通量/架
1	0	819.8	1.0
2	0	469.4	1.1
3	1.07×10^{-17}	468.2	1.9
⋮	⋮	⋮	⋮
60	3.03×10^{-18}	681.3	1.4
61	3.14×10^{-18}	651.4	1.7
62	3.33×10^{-18}	612.0	1.7
63	7.4×10^{-18}	712.3	2.0

2.3 空中交通拥堵的时间相关性

2.3.1 周期性

各区块交通拥堵指数的日变化具有一定的相似性。以时空区块6为例，选取2023年7月前3周该区块的拥堵指数数据，并绘制拥堵指数时变图，如图4所示。可以看出，时空区块6拥堵指数的日变化呈现出较为明显的宏观周期性，拥堵高峰期一般处于每天8:00—24:00的时段，拥堵低峰期一般处于夜间24:00—8:00，同时，相邻周之间也存在着潜在的相似关系。上述周期性主要是由航班计划具有较强稳定性造成的。

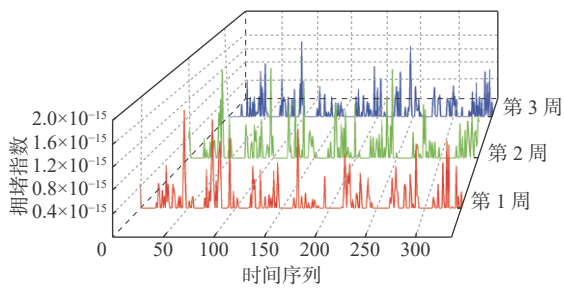


图4 连续3周的拥堵指数变化趋势(时间尺度为30 min)

Fig. 4 Congestion index has changed for three consecutive weeks (time scale is 30 min)

2.3.2 非线性

尽管有较为固定的航班计划约束空中交通行为，但由于空中交通系统是一个“人-机-环”构成的复杂开放系统，受人为因素、恶劣天气、设备故障等不确定因素的影响，使空中交通系统具有一定的非线性特征。空中交通拥堵指数表现出微观非线性的时变特征，给交通拥堵的准确预测带来较大挑战。

三阶自相关统计量R能够较好地检验出时间序列中的非线性特性，计算如下：

$$R(\tau_1,\tau_2)=\frac{\sum_{k=\max(\tau_1,\tau_2)+1}^{l}\left(x_k x_{k-\tau_1} x_{k-\tau_2}\right)^3}{l-\max(\tau_1,\tau_2)} \tag{4}$$

式中：τ_1、τ_2为时间延迟，一般取$\tau_2=2\tau_1$；x_k为时间序列第k个数值；l为时间序列长度。

进一步采用Sigma检验法对原数据和打乱原始序列元素顺序得到替代数据的检验统计量进行对比分析。假设原数据的三阶自相关统计量为T_0，其替代数据的三阶自相关统计量均值为T_S、均方差为σ_S，则Sigma检验量S计算如式(5)所示。根据Sigma检验原则，在显著性水平0.05下，当$S\geqslant1.96$时，拒绝原假设，说明原始序列具有非线性特征。

$$S=|T_0-T_S|/\sigma_S \tag{5}$$

选取拥堵多发的时空区块 6、时空区块 10、时空区块 22、时空区块 33 及时空区块 38 的拥堵指数时间序列, 基于上述方法检验非线性特性, S 值依次为 7.78、14.45、4.34、4.92 和 7.55, 5 个区块的 Sigma 检验量均大于 1.96, 说明拥堵指数时间序列具有非线性成分。

2.4　空中交通拥堵的空间相关性

为进一步分析不同区块之间的空间相关性, 计算两两区块拥堵指数的皮尔逊相关系数, 可视化如图 5 所示。可见, 对角线附近相关系数较大, 说明相邻区块之间的相关性较大, 例如, 时空区块 2 与时空区块 3、时空区块 6、时空区块 18、时空区块 21、时空区块 22 相邻, 其相关性系数均达到 0.7 以上。另外, 处于同一交通流上的时空区块之间的相关性较大, 例如, 时空区块 18 和时空区块 19、时空区块 21、时空区块 22 处于同一交通流上(见图 1), 其相关性系数虽然低于相邻区块的相关性系数, 但也均达到 0.5 以上, 相关性较大。

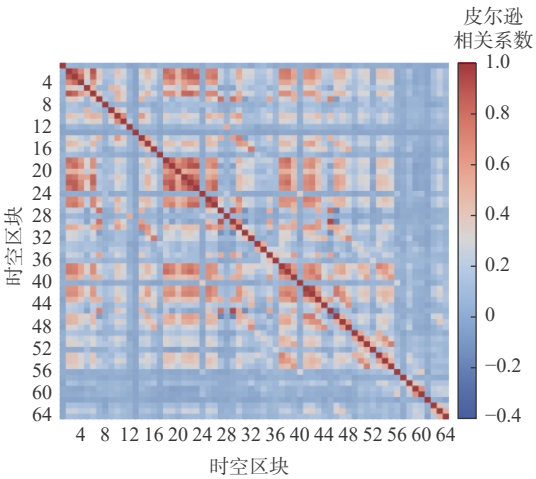


图 5　拥堵指数相关性系数

Fig. 5　Congestion index correlation coefficient plot

3　终端区交通拥堵预测模型的构建

3.1　问题描述

已知: 将终端区划分为N个时空区块, 整个终端区的拥堵指数表达为$\boldsymbol{V}=[\boldsymbol{V}_1,\boldsymbol{V}_2,\cdots,\boldsymbol{V}_l]$, l为时间序列长度, $\boldsymbol{V}_k=[\boldsymbol{V}_{k1},\boldsymbol{V}_{k2},\cdots,\boldsymbol{V}_{kN}]$表示$k$时段各时空区块的交通状态。

预测: 未来时段各时空区块的拥堵指数$\boldsymbol{V}_{t+L}$, L为预测步长。

由 2.4 节可知, 各时空区块交通拥堵不仅受周围区块的影响, 而且受同一交通流上其他区块的影响。为此, 基于各时空区块交通拥堵指数和区块间流量, 分别构建不同时段的三维网格G^1和交通流网络G^2; 对G^1进行三维卷积操作, 对G^2进行图卷积操作, 重构各时空区块之间空间特征; 将卷积后的空间特征, 利用 GRU 学习区块拥堵演化的时间相关性, 实现对各时空区块未来拥堵指数的预测。该拥堵预测问题可描述为

$$f([G^1,G^2];[\boldsymbol{V}_{t-l+1},\cdots,\boldsymbol{V}_{t-1},\boldsymbol{V}_t])\xrightarrow{\text{3DCNN}(\cdot)+\text{GCN}(\cdot)+\text{GRU}(\cdot)}\boldsymbol{V}_{t+L} \tag{6}$$

3.2　基于 3DCNN-GCN-GRU 的交通拥堵预测模型构建

基于 3.1 节问题描述, 构建基于 3DCNN+GCN+GRU 的交通拥堵预测模型。该模型主要由 3DCNN 特征重构部分、GCN 特征重构部分和 GRU 预测部分组成, 模型结构如图 6 所示, 其中, h 表示历史

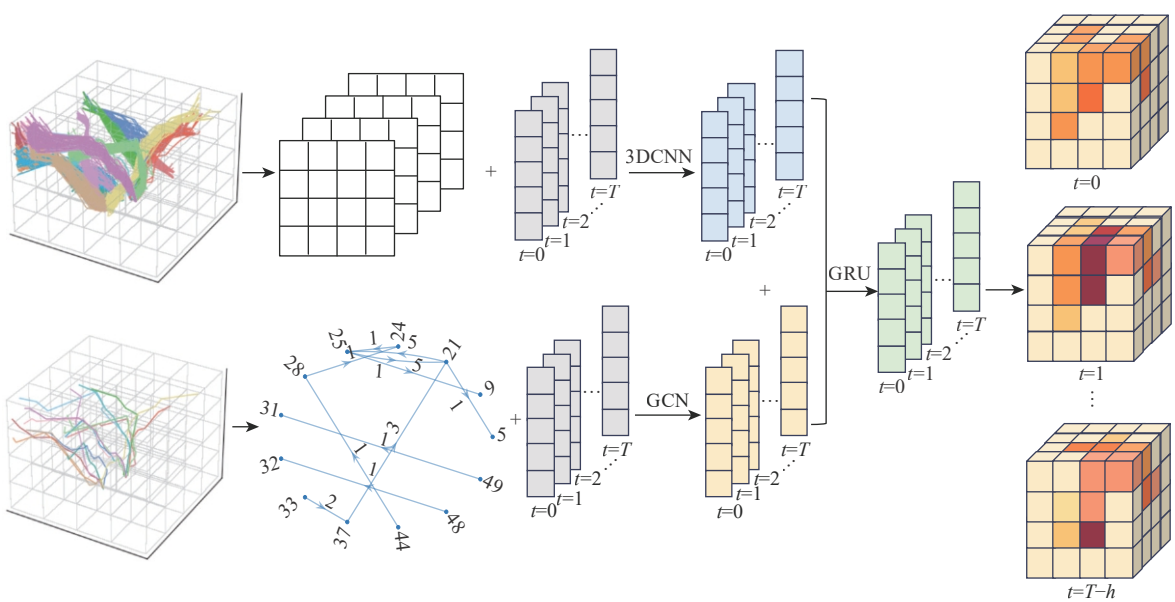


图 6　3DCNN-GCN-GRU 框架

Fig. 6　Frame of 3DCNN-GCN-GRU

h个时刻。首先,基于各时空区块拥堵指数数据,采用三维卷积重构终端区相邻时空区块间的空间相关性特征;接着,基于终端区交通流网络,采用图网络重构终端区交通流上各时空区块间的空间相关性特征;然后,将2类空间相关性特征进行拼接,并输入GRU模型,捕获各时空区块交通拥堵的时间相关性特征;最后,经过全连接层得到各时空区块交通拥堵指数的预测结果。

3.2.1 基于3DCNN的空域三维网格空间特征重构

三维卷积技术更适合空域的三维空间特征。针对不同时段各三维网格拥堵指数数据,采用3DCNN技术重构邻近区块之间的空间相关性特征,具体流程如下:

1)三维卷积核构造。较小的卷积核能够捕捉空域内交通拥堵的细节,而较大的卷积核则能提高捕获交通拥堵全局特征的能力。为构建合适大小的卷积核,分别将多个不同大小的卷积核放到预测模型中,选取预测精度最高时所对应的卷积核大小。

2)卷积操作。为从不同角度学习邻近时空区块之间的相关关系,构建经度、纬度和高度3个通道,即令三维卷积核在终端区三维网格空域内,分别沿经度、纬度和高度进行滑动卷积操作,从而获取交通拥堵邻近空间特征的三通道卷积的特征图信息。

卷积层采用激活函数为ReLU的卷积操作提取特征,增强空间信息,一定程度上可以防止过拟合现象的发生。采用窗口大小为$2\times2\times2$的最大池化函数来增加感受野,减小特征图的尺寸,降低计算复杂度。

3)多通道卷积特征的拼接。对上一步得到的三通道卷积特征进行拼接,得到一个总体的三维卷积特征,计算式为

$$Y(a,b,c)=F\left(\sum_{a'=0}^{A-1}\sum_{b'=0}^{B-1}\sum_{c'=0}^{C-1}X(a+a',b+b',c+c')\cdot\omega(a',b',c')+\varsigma\right) \tag{7}$$

式中:$F(\cdot)$为激活函数,本文使用ReLU激活函数,ReLU激活函数可以减少模型过拟合的风险,提高模型的训练速度;$Y(a,b,c)$为卷积层输出的某个特定位置的值,通常也被称作特征图中的某个像素;$X(a+a',b+b',c+c')$为输入数据的某个位置的值及前一个卷积层输出(也可称作特征图)的某个位置的值;$\omega(a',b',c')$为卷积核的权重参数;ς为偏置项;A、B、C为卷积核的尺寸,用于指定卷积核在3个维度上的大小。

3.2.2 基于GCN的动态交通流网络空间特征重构

GCN能够很好地学习非欧式结构数据中的空间特征。考虑到终端区内部交通流网络具有典型的非欧特征,基于1.1节终端区空域交通流识别、三维区块划分及各区块拥堵指数的计算结果,构建不同时段的动态交通流网络,并利用图卷积技术重构动态交通网络上各时空区块之间的空间相关性特征。

1)交通流量计算。基于1.1节交通流识别结果,统计不同时段各区块之间的交通流量。

2)交通流网络构建。以各时空区块为节点,时空区块间连通关系为边,若两时空区块处于一条交通流上且存在航班经过,则两时空区块为连通状态,否则没有连边。由2.2节可知,拥堵指数与交通流量有一定相关性,因此,将交通流量作为网络边的权重,构建不同时段交通流网络的加权动态有向图$\boldsymbol{G}^2=[\boldsymbol{G}_1^2,\boldsymbol{G}_2^2,\cdots,\boldsymbol{G}_P^2]$,$\boldsymbol{G}_p^2=\boldsymbol{G}_p^2(U_p,E_p,W_p)$,其中,$p$为第$p$个时间段,$p=1,2,\cdots,P$,$U_p$为第$p$个时间段空域区块集(即交通流网络的点集),$E_p$为第$p$时间段区块间交通流的连通情况(即交通流网络的边集),值为0或1,W_p为第p个时间段不同网格间交通流量(即交通流网络的边权集)。第p时间段网络图$\boldsymbol{G}_p$所对应的邻接矩阵为$\boldsymbol{\Lambda}_p\in\mathbf{R}^{N'\times N'}$。限于篇幅所限,图7给出了部分时段的动态交通流网络图,图中数字为时空区块编号。可见,终端区交通量越大,网络结构越复杂。

3)图卷积操作。对交通流网络图$\boldsymbol{G}^2$进行图卷积操作:

$$H=\sigma(\boldsymbol{AV\theta}) \tag{8}$$

式中:H为图卷积的输出特征;$\sigma(\cdot)$为激活函数;$\boldsymbol{A}$为$\boldsymbol{G}^2$的邻接矩阵;$\boldsymbol{\theta}$为图卷积的参数向量。

3.2.3 基于GRU的时间特征重构

本节采用GRU捕获交通时间序列中固有的动态时间依赖性。GRU模型的输入为三维卷积$\boldsymbol{Y}^{\mathrm{3DCNN}}$和图卷积输出的重构特征$\boldsymbol{H}^{\mathrm{GCN}}$,输出为各网格未来的交通状态$\boldsymbol{V}_k$,计算式为

$$\boldsymbol{V}_k=\mathrm{GRU}\left(\boldsymbol{H}_{k-1}^{\mathrm{GCN}},\boldsymbol{Y}_{k-1}^{\mathrm{3DCNN}},\boldsymbol{H}_{k-2}^{\mathrm{GCN}},\boldsymbol{Y}_{k-2}^{\mathrm{3DCNN}},\cdots,\boldsymbol{H}_{k-l}^{\mathrm{GCN}},\boldsymbol{Y}_{k-l}^{\mathrm{3DCNN}}\right) \tag{9}$$

式中:GCN和3DCNN分别表示图卷积和三维卷积的重构特征。

3.3 模型评价

采用均方根误差(root mean squared error, RMSE)和平均绝对误差(mean absolute error, MAE)2个指标评估模型的预测性能。

1)RMSE是预测值与真实值之间差异的平均

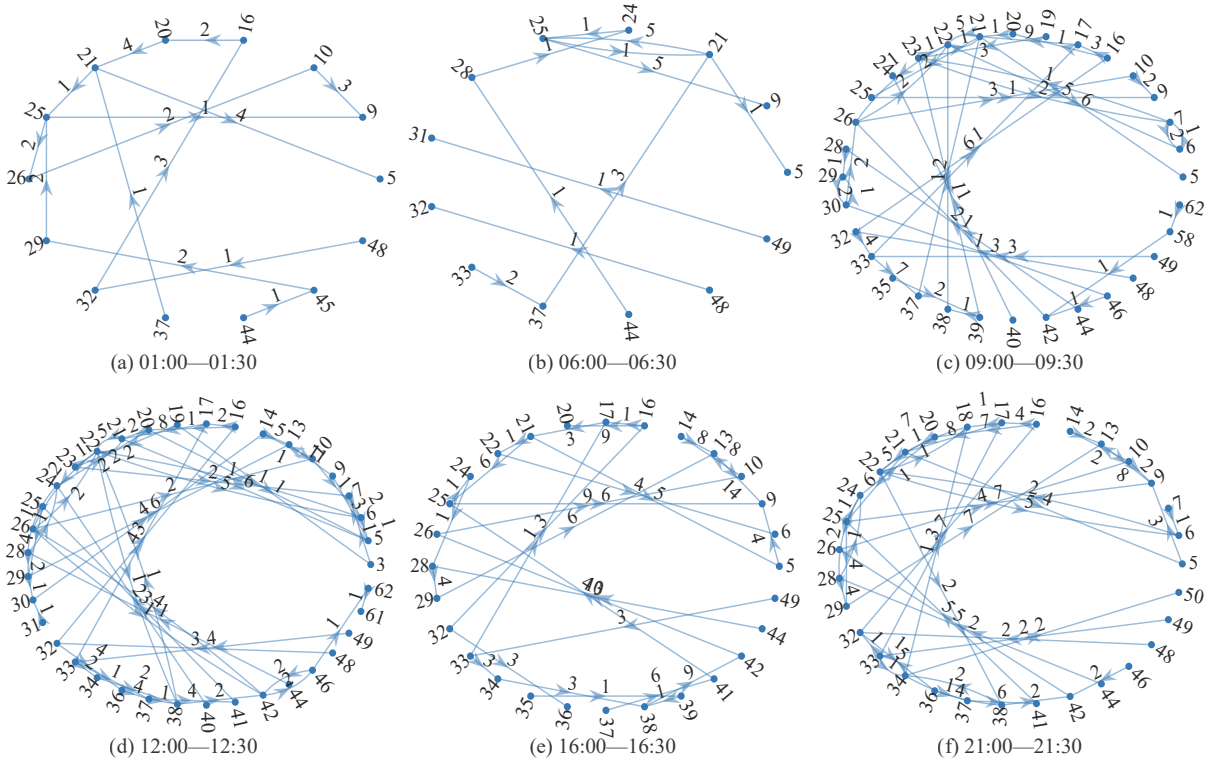


图 7　邻接网络

Fig. 7　Adjacency network

标准差, 计算式为

$$Q_{\mathrm{RMSE}}=\sqrt{\frac{1}{n'}\sum_{i'=1}^{n'}\left(y_{i'}-\hat{y}_{i'}\right)^2} \tag{10}$$

式中: $\hat{y}_{i'}$ 和 $y_{i'}$ 分别为第 i' 个样本的预测值和真实值; n' 为样本总数。

2) MAE 是预测值与真实值之间差异的平均绝对值, 计算式为

$$Q_{\mathrm{MAE}}=\frac{1}{n'}\sum_{i'=1}^{n'}\left|y_{i'}-\hat{y}_{i'}\right| \tag{11}$$

4　算例分析

4.1　实验设置

本文预测模型使用 Python 语言, 基于 Tensorflow 搭建。通过试算, 确定卷积核大小为 3×3×3, 模型使用 Adam 优化器进行优化, 学习率设置为 0.001, 激活函数为 ReLU, 以 MAE 作为目标函数, 并采用 L_2 正则化操作, 减少模型过拟合风险。在训练过程中, 以 128 个样本为一个训练批次, 共训练 100 轮, 通过 split 函数指定 20% 的数据作为验证集, 输入序列长度为 6, 预测序列长度分别为 1。为避免预测模型产生严重的过拟合, 采用早停策略用于在验证集损失不再改善时停止训练, 并恢复到在验证集上得到最佳性能时的权重。

实验过程中本文模型历史数据输入序列长度主要通过试算获得。例如, 对于 30 min 时间尺度, 分别采用输入序列长度为 4、5、6、7、8 进行对比实验, 其 MAE 对比如图 8 所示。可知, 当输入序列长度为 6 时, 模型训练误差值最小。对于 3DCNN+GCN+GRU 预测模型来说, 太小的输入序列长度不能获得足够的历史信息, 导致模型无法学习足够的时间依赖特征来支持终端区交通拥堵预测任务, 导致模型误差较大; 当输入序列长度过大时, 预测模型在学习时空数据相关性时会弱化靠前序列的比

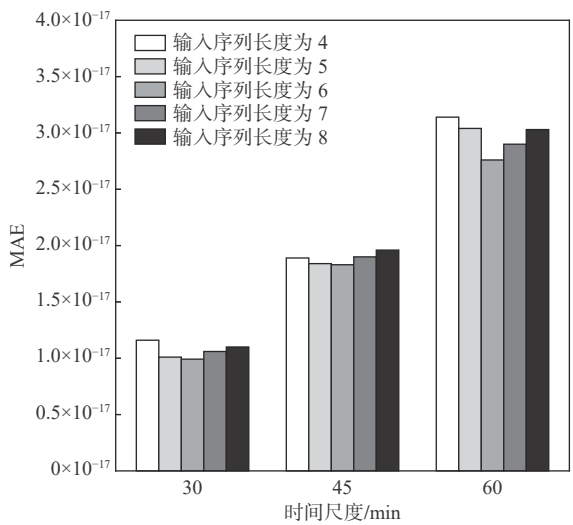


图 8　不同输入序列长度下各模型预测误差对比

Fig. 8　Comparison of prediction errors of various models under different input sequence steps

重。更严重的是,较长的输入序列会使模型参数数量激增,使模型性能下降。由图 8 可知,MAE 先随着输入序列长度的增加而减小,此时说明模型捕捉时空数据的相关性较好。当序列达到一定长度时,再增加序列长度时,MAE 又会逐渐增大。

4.2 结果分析

4.2.1 不同模型预测结果对比

为检验本文模型的优越性,将本文模型与历史平均 (history average, HA) 模型、指数加权平均 (exponential moving average, EMA) 模型、支持向量机回归 (support vector regression, SVR) 模型等经典模型,以及 CNN+GRU 模型、GCN+GRU 模型、CNN+GCN+LSTM 模型等变体模型进行对比试验,结果如表 2 和图 9 所示。可以看出,所有模型随着时间尺度的增加,预测准确率均下降,30 min 时间尺度下预测效果最好,且 CNN+GCN+GRU 模型在所有模型中都是表现最好的。相较于 HA 模型、EMA 模型、SVR 模型,CNN+GCN+GRU 模型的 RMSE 和 MAE 分别下降 21% 和 57%、38% 和 72%、19% 和 51%;相较于只学习邻接空间特征、只学习交通流空间特征、改用 LSTM 学习时间特征,CNN+GCN+GRU 模型的 RMSE 和 MAE 分别下降 36% 和 40%、6% 和 8%、2% 和 2%。相较于 30 min 时间尺度,45 min 和 60 min 时间尺度预测结果的 MAE 和 RMSE 分别增加了 84% 和 48%、178% 和 118%。说明较短的时间尺度允许模型更好地捕捉数据中的时空相关性,从而提高预测准确性。图 9 给出终端区时空区块 22 不同尺度下 CNN+GCN+GRU 模型预测值与真实值的对比。可以看出,本文模型能够较好地学习到真实值的变化趋势。

表 2 模型误差对比

Table 2 Comparison of model errors

模型	MAE			RMSE		
	时间尺度为30 min	时间尺度为45 min	时间尺度为60 min	时间尺度为30 min	时间尺度为45 min	时间尺度为60 min
HA	2.32×10^{-17}	3.91×10^{-17}	5.70×10^{-17}	5.60×10^{-17}	8.38×10^{-17}	1.11×10^{-16}
EMA	3.56×10^{-17}	3.25×10^{-17}	4.72×10^{-17}	7.17×10^{-17}	6.49×10^{-17}	8.58×10^{-17}
SVR	2.02×10^{-17}	3.45×10^{-17}	5.02×10^{-17}	5.47×10^{-17}	8.20×10^{-17}	1.09×10^{-16}
CNN+GRU	1.08×10^{-17}	1.85×10^{-17}	2.95×10^{-17}	4.74×10^{-17}	8.02×10^{-17}	1.11×10^{-16}
GCN+GRU	1.64×10^{-17}	2.84×10^{-17}	4.32×10^{-17}	6.93×10^{-17}	1.03×10^{-16}	1.41×10^{-16}
CNN+GCN+LSTM	1.02×10^{-17}	1.98×10^{-17}	3.24×10^{-17}	4.52×10^{-17}	7.36×10^{-17}	1.02×10^{-16}
CNN+GCN+GRU	9.92×10^{-18}	1.83×10^{-17}	2.76×10^{-17}	4.41×10^{-17}	6.51×10^{-17}	9.61×10^{-17}

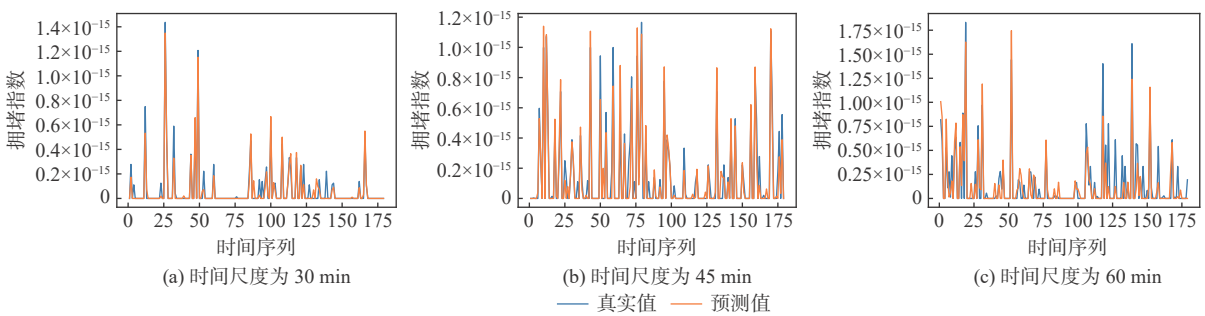


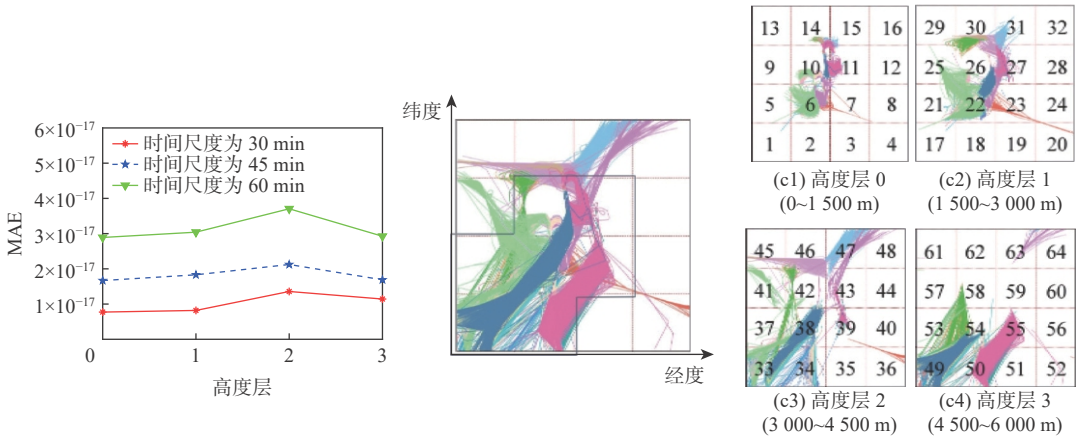
图 9 模型预测结果

Fig. 9 Model predicts results

另外,对比 CNN+GRU 模型和 GCN+GRU 模型这 2 个模型的预测结果可以看出,相比同一交通流的区域,邻接区域的交通状态对目标区域影响较大。因此,当某区域发生交通拥堵时,管制员应首先关注其对周围区域的影响,其次关注与拥堵区域在同一交通流的其他区域。

4.2.2 不同高度层预测结果对比

由于本文将空域划分为4×4×4的网格,在高度上将空域划分为 4 个高度层。基于本文模型得到各网格拥堵指数预测结果,分别统计不同时间尺度下各高度层上所有网格 MAE 均值,如图 10 所示,其中,图 10(b)中数字为水平区块编号。以 30 min 时间尺度为例,可发现低高度层(0~1 500 m)的预测准确性最高,MAE 达到 7.72×10^{-18},其原因可能由于靠近机场的低高度层空域通常会有较多的固定航线,飞行路径相对固定,导致拥堵情况的出现具有较强规律性,因此,拥堵预测的准确性也会提高。中高度层(1 500~4 500 m)MAE 有所增大,达到



(a) 高度层误差折线图　(b) 水平航迹 (不考虑高度)　(c) 水平航迹 (考虑高度)

图 10　不同高度层误差及水平航迹

Fig. 10　Error of different altitude layers and horizontal track

1.14×10^{-17}, 高高度层(4 500～6 000 m)MAE 又有所降低, 达到 1.36×10^{-17}。

对比图 10(c) 可见, 由于高高度层航空器刚进入终端区时, 汇聚现象较弱, 以及低高度层航空器基本已完成落地排序, 航空器之间间隔已具备, 因此, 在这些高度范围内, 管制员对航空器实施减速、雷达引导等行为较少。而在中高度层, 航空器冲突态势较为严重, 管制员通常会对航空器实施较多的雷达引导等操作, 导致航迹分布较为复杂, 交通态势演变的规律特征有所减弱, 因此, 在中高度层, 拥堵预测的准确性最差。而当高度上升到一定程度后, 预测误差又随着高度的上升而减小, 其原因在于在该高度飞行的航空器大多刚刚完成移交, 航空器之间存在移交间隔, 航空器运行规律性较强, 预测误差变小。因此, 中高度层交通态势演化较为复杂, 终端区管制员在指挥飞机时, 尤其要关注中高度层上的交通态势情况。

4.2.3　不同水平区块预测结果对比

忽略高度的影响, 基于本文模型得到各网格拥堵指数预测结果, 以 30 min 时间尺度为例, 统计各水平区块上所有高度网格 MAE 的均值, 结果如表 3 所示, 同时, 绘制如图 10(b) 所示的航迹图。对比表 3 和图 10(b) 可以发现, 航迹越复杂的时空区块, 其拥堵预测的误差越大, 如水平区块 1、水平区块 2、水平区块 6 及水平区块 7 的 MAE 均值分别为 2.54×10^{-17}、1.74×10^{-17}、2.56×10^{-17} 及 2.08×10^{-17}, MAE 标准差较大; 有较少或没有航迹穿越的时空区块, 预测误差较低, 如水平区块 3、水平区块 4、水平区块 12 及水平区块 16 的 MAE 均值分别为 1.05×10^{-18}、5.33×10^{-18}、6.60×10^{-18} 及 5.56×10^{-20}, MAE 标准差较小。因此, 航迹复杂区域的交通拥堵演化较为复杂, 终端区管制员在指挥飞机时, 尤其要关注水平区块 1、水平区块 2、水平区块 6、水平区块 7 等航迹复杂区域的交通拥堵态势。

表 3　水平区块误差

Table 3　Horizontal block error

水平区块	MAE均值	MAE标准差
1	2.54×10^{-17}	8.63×10^{-17}
2	1.74×10^{-17}	8.80×10^{-17}
3	1.05×10^{-18}	1.44×10^{-17}
4	5.33×10^{-18}	4.32×10^{-17}
5	1.48×10^{-17}	6.84×10^{-17}
6	2.56×10^{-17}	5.99×10^{-17}
7	2.08×10^{-17}	7.69×10^{-17}
8	1.07×10^{-17}	6.02×10^{-17}
9	5.17×10^{-19}	1.46×10^{-17}
10	1.39×10^{-17}	6.45×10^{-17}
11	1.34×10^{-17}	6.15×10^{-17}
12	6.60×10^{-18}	4.67×10^{-17}
13	1.40×10^{-18}	2.07×10^{-17}
14	2.01×10^{-18}	2.66×10^{-17}
15	1.14×10^{-19}	1.23×10^{-17}
16	5.56×10^{-20}	3.29×10^{-18}

可见, 基于水平区域的拥堵预测的准确性较高, 可提醒管制员提前关注即将拥堵的区域, 通过雷达引导、减速等行为限制未来某时段内进入该区域的航空器数量, 降低该区域航空器飞行路径的复杂性。同时, 综合考虑各区块的拥堵态势, 也有利于管制员较为精细地规划航空器在终端区的飞行路径。

5　结　论

本文研究了一种新的考虑多模态时空相关性的终端区交通拥堵预测方法, 并选择北京终端区为

例，构造了终端区交通拥堵指数数据集对所用方法进行了验证，主要结论如下：

1）综合考虑空中交通拥堵状态下，航空器的滞留特性、管制负荷增加及交通流异质性等特点，提出终端区交通拥堵指数及其计算方法，使拥堵度量结果更符合管制员的认知，对管制工作更有指导作用。

2）充分挖掘终端区邻接区域之间，以及同一交通流上不同区域之间的动态空间相关性，构建基于3DCNN+GCN+GRU的终端区交通拥堵精细化预测模型，实现对终端区内部不同三维区域的拥堵预测，有助于提升空管人员对终端区交通拥堵程度掌握的精细化、科学性和准确性，也为未来TBO空管模式的实现提供了理论基础。

3）实例验证结果表明，邻接特征较交通流特征对拥堵预测准确性提升更为明显；随高度的上升，预测误差呈现出先增大后减小的变化趋势；航迹复杂区域预测准确性较低。说明中高度区域和航迹复杂区域交通拥堵演化较为复杂，管制员应重点关注这些区域的交通运行情况。

本文主要研究常发性拥堵的预测问题，终端区交通较易受恶劣天气的影响，未来可挖掘恶劣天气气象要素与交通拥堵的相互作用特征，将天气信息考虑到预测模型中，提高恶劣天气下交通拥堵预测的准确性。

参考文献（References）

[1] 殷建棠, 刘继新, 田文, 等. 基于时空图卷积的航段拥挤态势预测[J]. 北京航空航天大学学报, 2025, 51(11): 3906-3915.
Yin J T, Liu J X, Tian W, et al. Segment congestion situation prediction based on spatiotemporal graph convolution[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(11): 3906-3915(in Chinese).

[2] 李桂毅, 胡明华, 张洪海. 基于FCM-SVM方法的时空航路网交通状态识别研究[J]. 武汉理工大学学报 (交通科学与工程版), 2018, 42(4): 569-573.
Li G Y, Hu M H, Zhang H H. Research on traffic state identification of spatio-temporal air route network based on FCM-SVM method[J]. Journal of Wuhan University of Technology (Transportation Science & Engineering), 2018, 42(4): 569-573(in Chinese).

[3] Williams K, Reichmuth J. An assessment of air traffic management in Europe during the calendar year 2004[EB/OL]. (2005-04-13)[2024-07-01]. https://www.eurocontrol.int/publication/performance-review-report-prr-2004.

[4] 李善梅, 徐肖豪, 王超, 等. 基于灰色聚类的交叉航路拥挤识别方法[J]. 西南交通大学学报, 2015, 50(1): 189-197.
Li S M, Xu X H, Wang C, et al. Congestion identification of crossing air routes based on gray clustering method[J]. Journal of Southwest Jiaotong University, 2015, 50(1): 189-197(in Chinese).

[5] Tan X H, Sun Y S, Zeng W L, et al. Congestion recognition of the air traffic control sector based on deep active learning[J]. Aerospace, 2022, 9(6): 302.

[6] Lin Y, Zhang J W, Liu H. An algorithm for trajectory prediction of flight plan based on relative motion between positions[J]. Frontiers of Information Technology & Electronic Engineering, 2018, 19(7): 905-916.

[7] 张军峰, 蒋海行, 武晓光, 等. 基于BADA及航空器意图的四维航迹预测[J]. 西南交通大学学报, 2014, 49(3): 553-558.
Zhang J F, Jiang H X, Wu X G, et al. 4D trajectory prediction based on BADA and aircraft intent[J]. Journal of Southwest Jiaotong University, 2014, 49(3): 553-558(in Chinese).

[8] Saraf A P, Slater G L. Adaptive eulerian modeling for air traffic flow management[J]. Journal of Aircraft, 2008, 45(5): 1585-1600.

[9] 毛利民, 彭瑛, 李杰, 等. 基于随机森林的对流天气下终端区容量预测[J]. 系统工程理论与实践, 2021, 41(8): 2125-2136.
Mao L M, Peng Y, Li J, et al. Random-forest based terminal capacity prediction under convective weather[J]. Systems Engineering-Theory & Practice, 2021, 41(8): 2125-2136(in Chinese).

[10] 李桂毅, 郭铭宇, 罗一帆. 基于集成学习算法的航路网络航段交通拥挤识别方法研究[J]. 交通运输系统工程与信息, 2020, 20(2): 166-173.
Li G Y, Guo M Y, Luo Y F. Traffic congestion identification of air route network segment based on ensemble learning algorithms[J]. Journal of Transportation Systems Engineering and Information Technology, 2020, 20(2): 166-173(in Chinese).

[11] Khanmohammadi S, Tutun S, Kucuk Y. A new multilevel input layer artificial neural network for predicting flight delays at JFK airport[J]. Procedia Computer Science, 2016, 95: 237-244.

[12] Cai K Q, Shen Z Q, Luo X Y, et al. Temporal attention aware dual-graph convolution network for air traffic flow prediction[J]. Journal of Air Transport Management, 2023, 106: 102301.

[13] 焦卫东, 杨蓓. 一种融合MSC和时空双重注意力的TCN航迹预测方法[J]. 北京航空航天大学学报, 2026, 52(1): 15-27.
Jiao W D, Yang B. A TCN trajectory prediction method fusing MSC and spatio-temporal dual attention[J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(1): 15-27(in Chinese).

[14] Wang K, Ma C X, Qiao Y H, et al. A hybrid deep learning model with 1DCNN-LSTM-Attention networks for short-term traffic flow prediction[J]. Physica A: Statistical Mechanics and its Applications, 2021, 583: 126293.

[15] 刘晓琳, 郭梦娇, 李卓. 基于AAGC-GRU的航班延误组合预测方法[J]. 北京航空航天大学学报, 2025, 51(1): 30-42.
Liu X L, Guo M J, Li Z. Combined prediction method of flight delay based on attention-based adaptive graph convolution-gated recurrentunit[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(1): 30-42(in Chinese).

[16] Cao M M, Li V O K, Shuai Q Q. DeepGAL: intelligent vehicle control for traffic congestion alleviation at intersections[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(7): 6836-6848.

[17] Sun F R, Xu X J, Zhang H M, et al. Evolution mechanism and optimisation of traffic congestion[J]. The Aeronautical Journal, 2024, 128(1321): 598-630.

Refined prediction of terminal area traffic congestion based on multimodal spatio-temporal feature fusion

LI Shanmei*, SONG Sini, WANG Hongyong, WANG Duanyang, ZHAO Mo

(College of Air Traffic Management, Civil Aviation University of China, Tianjin 300300, China)

Abstract: In order to enhance the accuracy and refinement of grasping the future traffic dynamics in the terminal area, a set of traffic congestion prediction methods based on the fusion of multimodal spatio-temporal features is proposed. First, from the standpoint of aircraft detention and control load, a traffic flow clustering technique is used to provide a traffic congestion index calculation method that takes traffic flow heterogeneity into account. Further, the airspace of the terminal area is divided into four-dimensional spatio-temporal blocks, and the spatio-temporal blocks are used as the nodes for constructing the dynamic adjacency network and the traffic flow network, which characterize the spatial correlation of the terminal area in a multimodal way. Finally, a three-dimensional convolutional neural network (3DCNN)+graph convolutional network (GCN)+gated recurrent unit (GRU)-based traffic congestion prediction model for terminal areas is proposed. The model validation was performed using Beijing terminal area trajectory data, and the results show that the method of this paper is superior to the classical baseline model, with the best prediction effect at 30 min compared to 45 min and 60 min time scales, and the root mean squared error (RMSE) and mean absolute error (MAE) compared to the history average (HA) model, exponential moving average (EMA) model, and support vector regression (SVR) regression model and MAE decreased by 21% and 57%, 38% and 72%, and 19% and 51%, respectively. The RMSE and MAE of this paper's model fall by 36% and 40%, 6% and 8%, and 2% and 2%, respectively, as compared to learning only neighbor space features, learning only traffic flow space features, and transitioning to long short-term memory (LSTM) to learn temporal characteristics. At the same time, the prediction results show that the more complex the trajectory is, the greater its prediction error is, and with the rise in the altitude of the airspace, the prediction error shows an increase and then a decrease. Meanwhile, the prediction results show that the more complicated the trajectory is, the larger the prediction error is, and with the increase of airspace altitude, the prediction error shows an increase and then decrease.

Keywords: air transportation; congestion prediction; deep learning; traffic flow network; four-dimensional trajectory

Received: 2024-07-21; **Accepted**: 2024-08-23; **Published Online**: 2024-09-05 10:38

URL: link.cnki.net/urlid/11.2625.V.20240904.1558.001

Foundation items: National Natural Science Foundation of China (52672428,52202404); Tianjin Natural Science Foundation (24JCYBJC01170); Graduate Research Innovation Project of Civil Aviation University of China (2025YJSKC03001)

* **Corresponding author**. E-mail: sm-li@cauc.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0795

融合双通道注意力和时间编码的图神经网络推荐算法

白鹤，李钰*，郝明，徐婷婷
(辽宁理工学院 信息工程学院，锦州 121000)

摘　　要：针对多数图神经网络推荐算法未结合时间信息导致信息浪费和推荐结果不准确的问题，提出融合双通道注意力和时间编码的图神经网络推荐算法GUITRec。该模型充分利用数据集中信息，将用户自身特征、物品信息及用户与物品交互行为建为图结构，通过图神经网络进行数据聚合以形成用户和物品表征行为，从而更全面地捕捉两者特征及关系。引入双通道注意力机制卷积块注意力模块(CBAM)为用户和物品表征行为赋予不同权重，使模型依据权重进行深度学习，更加关注重要特征信息。引入时间编码器模型对用户与物品交互时间及用户位置编码，新增日、周、月周期编码和位置编码，充分挖掘时间和位置信息，为推荐提供更丰富的上下文。在Ciao数据集上进行实验，在平均绝对误差(MAE)、均方误差(MSE)、均方根误差(RMSE)这3个评价指标上，GUITRec均优于基线模型。

关 键 词：双通道注意力机制；图神经网络；时间编码；位置编码；推荐算法
中图分类号：TN911.1; TP301.6
文献标志码：A　　**文章编号**：1001-5965(2026)11-3864-15

随着5G时代的到来，社交媒体平台的迅速崛起进一步推动了信息和数据的爆炸性增长，频繁的互联网使用使人们面临着海量信息的冲击。其中夹杂着大量并不能直接满足用户需求或兴趣的冗余内容，增加了用户处理信息的负担。面对复杂多变的互联网信息，用户常常难以快速筛选并提取出真正需要的内容。同时，信息的更新速度远远超过了用户的处理能力，导致用户难以跟上信息发展的节奏。这种信息处理能力与信息更新速度之间的错位，直接造成了信息使用效率的下降，这种现象被称为“信息过载”。Goldberg等[1]于1992年提出推荐系统的概念，该概念的出现有效弥补了搜索引擎的缺陷，有效利用用户和物品的信息为用户带来个性化的推荐，从而过滤冗余信息，提升了用户的体验感。

整体上看，推荐系统主要经过3个发展阶段：浅层模型、神经网络模型、基于图神经网络的模型。传统的推荐模型[2]在关于协同过滤效果的分析方面，主要基于用户与物品相似性而实现，但在获取用户与物品特征信息方面存在不足。基于此，有学者基于浅层模型[3]提出协同过滤方法，即以用户和物品的表示学习呈现推荐任务，如矩阵分解[4]与因子分解机[5]，但在用户行为信息较为复杂的情况下，浅层方法很难充分发挥预期作用，无法从用户行为数据中获取大量信息[6]。在此背景下，有学者基于神经网络提出推荐模型，通过深度学习来增强推荐系统的表达能力，例如，将多层感知机与矩阵分解相结合，或采用深度因子分解机来提升推荐效果，如有机结合矩阵分解与多层感知，或借助深度因子分解机等模型。尽管如此，该类模型未将用

收稿日期：2024-11-06；**录用日期**：2025-01-03；**网络出版时间**：2025-01-08 15:39
网络出版地址：link.cnki.net/urlid/11.2625.V.20250108.1414.001
基金项目：2023年度辽宁省教育厅基本科研项目
*通信作者. E-mail：1531281593@qq.com

引用格式：白鹤，李钰，郝明，等. 融合双通道注意力和时间编码的图神经网络推荐算法[J]. 北京航空航天大学学报，2026，52(11)：3864-3878. Bai H，Li Y，Hao M，et al. Graph neural network recommendation algorithm fused with dual-channel attention and time encoding[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3864-3878 (in Chinese).

户与物品的交互数据中的图结构信息、高阶结构信息用于预测与训练中。图神经网络是近几年兴起的一种推荐算法[7], 带来了全新的解决方案, 其消息传递机制与图结构有聚合高阶邻域特征信息的作用, 从而更精准地捕捉节点之间的关系和特征相互作用。这使图神经网络逐渐成为推荐系统中最具潜力的方法之一[7]。闫阳等[8]提出融合语义信息与注意力的图神经网络推荐算法; 潘润超等[9]提出一种基于深度图神经网络的协同过滤推荐算法, 通过在图神经网络中加入初始残差连接和恒等映射, 显著提高了推荐系统的召回率和归一化折损累计增益。冯兴杰等[10]针对传统推荐算法未能充分利用用户和商品评论数据的缺陷, 提出了通过图神经网络提取关联关系及深度学习提取评论内容的优势, 结合用户和商品偏好进行特征融合, 从而提高推荐效果。Zhong 等[11]在图卷积网络(graph convolutional network, GCN)中融合了多头注意力机制。此外, Scarselli 等[12]对图神经网络模型进行了详细分析, 而 Li 等[13]通过使用门控递归单元(gated recurrent unit, GRU)提升了图神经网络的表达能力。Zhao 等[14]进一步将 GRU 与 GCN 相结合, 提出了时间图卷积网络(temporal graph convolutional network, T-GCN)模型。Ma 等[15]基于概率矩阵分解(probabilistic matrix factorization, PMF)模型, 引入了用户社交关系矩阵, 提出了社交推荐(social recommendation, SoRec)模型, 从而有效缓解了冷启动问题; 邬硕等[16]利用图神经网络进行短期偏好学习, 利用双向长短时记忆(long short-term memory, LSTM)进行长期偏好兴趣学习, 获得用户长期偏好表示, 提高推荐算法的准确率; 于健等[17]提出一种基于高阶和时序特征的图神经网络社会化推荐算法模型, 利用 GRU 对用户的近期动态偏好, 采用注意力机制获取用户表征。然而, 大多数现有的图神经网络仅侧重于用户与项目之间的图结构关系, 忽视了时间上的特性, 即周期性。因此, 本文提出一种结合双通道注意力机制和时间编码的图神经网络推荐模型, 构建了用户-物品图和物品-物品图 2 个图结构, 分别通过图神经网络学习用户表示和物品表示, 并引入时间编码器建模用户与物品交互的时序信息, 同时, 利用双通道注意力机制为不同特征赋予权重, 最终通过残差网络融合各特征以生成最终的预测结果。本文创新如下:

1) 充分利用数据集中的信息, 将用户的自身特征、物品的信息及用户与物品的交互行为建立为图结构, 并通过图神经网络对上述图结构进行聚合, 形成用户表征行为和物品表征行为, 同时, 引入双通道注意力机制卷积块注意力模块(convolutional block attention module, CBAM)对用户和物品的表征行为赋予不同的权重, 以便后续模型根据权重进行深度学习。在该过程中, CBAM 的引入对于提升推荐效果具有重要作用。CBAM 结合了通道注意力和空间注意力, 分别对特征图的全局语义信息和局部空间信息进行动态加权, 有效突出关键特征。通过通道注意力机制, CBAM 捕捉用户全局兴趣特征和物品全局属性的重要性; 通过空间注意力机制, 聚焦用户与物品交互行为中重要模式。这种动态加权过程不仅增强了用户和物品表征的精准度, 而且使模型能够更精细地建模用户与物品之间的交互相关性。

2) 本文模型中引入了时间编码器模型, 对数据集中用户与物品交互的时间及用户所处的位置(即邮编)进行编码, 新增了日周期编码、周周期编码、月周期编码和位置编码, 充分对数据中的时间和位置等信息进行挖掘。时间编码模型通过捕捉用户在特定时间段的偏好和周期性行为规律, 可以更准确地预测用户在未来时间的偏好; 结合位置编码, 模型能够识别地域性的行为特征差异, 如不同地区用户的消费习惯, 从而为推荐提供更个性化的支持; 此外, 日、周、月等多粒度时间编码的引入, 使模型能够在不同时间尺度上建模用户的动态偏好变化, 提升推荐的时效性和精准度。

3) 在 Ciao 公共数据集上进行了充分实验, 以验证上述创新点的有效性, 并选择平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)和均方误差(mean squared error, MSE)作为评价指标, 选取经典的推荐算法作为基准模型。实验结果显示, 本文模型在 MAE、MSE 和 RMSE 上的表现均优于基准模型。此外, 本文还进行了消融实验和分析, 深入探讨了各部分对模型性能的影响。

1　相关工作

1.1　图神经网络推荐算法

图结构是一种常见且重要的数据结构, 能够有效对节点和边进行建模。其在推荐系统中具有广泛应用, 例如, 用户和项目的交互信息可以用节点来表示, 边则体现了用户与项目之间的关联关系[18]。但传统的深度学习模型很难充分利用这些多元化的数据结构, 从而导致部分信息的丢失或浪费, 进而影响推荐系统的整体性能。伴随着社交网络和知识图谱等众多图形数据的出现, 如何有效处理和挖掘这些复杂结构中的信息成为提升推荐系统性

能的关键挑战。随着社交网络、知识图谱等大量图形数据的涌现，如何有效处理这些数据成为关键问题。因此，图神经网络应运而生，以更好地应对这些挑战。图神经网络是一种基于递归神经网络(recurrent neural network, RNN)和卷积神经网络(convolutional neural network, CNN)发展而来的新型深度学习模型，特别适用于处理非欧几里得空间的数据。在推荐系统中，图神经网络的基本框架如图1所示。

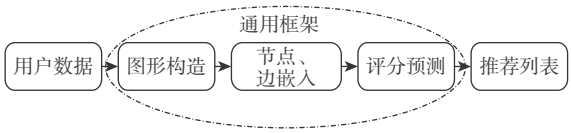


图1 图神经网络推荐算法框架

Fig. 1 Graph neural network recommendation algorithm framework

1.2 融合时间的推荐算法

在信息爆炸的当下，推荐算法至关重要，而时间因素对其准确性意义重大。时间影响着用户兴趣和行为，用户偏好随时间变化，新兴趣不断出现，旧喜好可能淡化。推荐算法若能捕捉时间信息，分析不同时间段用户行为模式和兴趣动态，就能更精准推荐符合当下需求的内容[19]。如在购物领域，不同季节和节日用户消费需求不同，推荐算法考虑时间因素可提高推荐准确性和用户购物体验；在影视娱乐方面，时间变化会使热门题材和风格演变，结合时间维度能推送当下流行作品满足用户娱乐需求，因此，研究人员开始将时间信息引入到推荐算法的研究中。Azri等[20]提出Auto TimeSVD++模型，引入了时间维度作为评分预测的关键因素，通过对用户偏好和物品流行度随时间的变化进行建模，实现了对时间敏感的个性化推荐；He等[21]提出动态可扩展图卷积(dynamically expandable graph convolution, DEGC)算法，将用户时间偏好模型作为用户嵌入初始化，以更好地捕捉个体层面的偏好变化。

1.3 通道卷积注意力机制 CBAM

通道卷积注意力机制[22]CBAM的核心思想是对输入特征图进行两阶段的提炼：①通道注意力模块，即借助通道注意力模块确定重要通道；②空间注意力模块，即通过空间注意力模块明确富含信息的部分。这样的双重注意力机制使CBAM可以全方位地捕捉特征中的关键信息。图2展示了CBAM注意力机制的构造。

1.3.1 通道注意力模块

通道注意力模块的原理主要是关注输入的特征图中具有意义的内容。分别采用平均池化层与

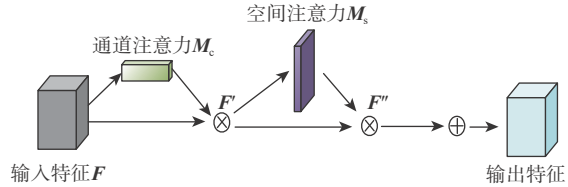


图2 CBAM框架

Fig. 2 CBAM framework

最大池化层对输入特征图的空间维度进行压缩处理，将其前向传递至一个共享的多层感知机网络。将2个输入进行相加，并经过一个激活函数，从而产生通道注意力，如式(1)和式(2)所示。图3为通道注意力的结构。

$$\boldsymbol{M}_{\mathrm{c}}(\boldsymbol{F})=\sigma(\mathrm{MLP}(\mathrm{AvgPool}(\boldsymbol{F}))+\mathrm{MLP}(\mathrm{MaxPool}(\boldsymbol{F})))=\sigma(\boldsymbol{W}_1(\boldsymbol{W}_0(\boldsymbol{F}^{\mathrm{c}}_{\mathrm{avg}}))+\boldsymbol{W}_1(\boldsymbol{W}_0(\boldsymbol{F}^{\mathrm{c}}_{\mathrm{max}}))) \tag{1}$$

$$\boldsymbol{M}_{\mathrm{c}}(\boldsymbol{F})=\sigma(\mathrm{MLP}(\mathrm{AvgPool}(\boldsymbol{F}))+\mathrm{MLP}(\mathrm{MaxPool}(\boldsymbol{F})))=\sigma(\boldsymbol{W}_1(\boldsymbol{W}_0(\boldsymbol{F}^{\mathrm{c}}_{\mathrm{avg}}))+\boldsymbol{W}_1(\boldsymbol{W}_0(\boldsymbol{F}^{\mathrm{c}}_{\mathrm{max}}))) \tag{2}$$

式中：σ为sigmod激活函数；MLP()为全连接层；AvgPool()为平均池化层；$\boldsymbol{W}_0$、$\boldsymbol{W}_1$为各级权重；MaxPool()为最大池化层；$\boldsymbol{F}$为输入特征图；$\boldsymbol{F}^{\mathrm{c}}_{\mathrm{avg}}$和$\boldsymbol{F}^{\mathrm{c}}_{\mathrm{max}}$分别为通道平均池化和最大池化后的特征图。

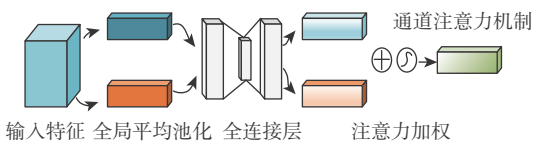


图3 通道注意力结构

Fig. 3 Channel attention structure

1.3.2 空间注意力模块

空间注意力模块与通道注意力有所不同，其聚焦于具有信息性的部分，与通道注意力形成互补。具体步骤为：首先，沿着通道轴分别进行平均池化和最大池化操作，提取出不同的全局特征表示；然后，将这2种池化操作的结果连接起来，产生2个图；最后，利用一个卷积操作后再串联一个激活函数，从而得到空间注意力$\boldsymbol{M}_{\mathrm{s}}$，如式(3)所示。图4为空间注意力机制的结构。

$$\boldsymbol{M}_{\mathrm{s}}(\boldsymbol{F})=\sigma(f_{\mathrm{c}}^{k\times k}([\mathrm{AvgPool}(\boldsymbol{F});\mathrm{MaxPool}(\boldsymbol{F})]))=\sigma(f_{\mathrm{c}}^{k\times k}([\boldsymbol{F}^{\mathrm{s}}_{\mathrm{avg}};\boldsymbol{F}^{\mathrm{s}}_{\mathrm{max}}])) \tag{3}$$

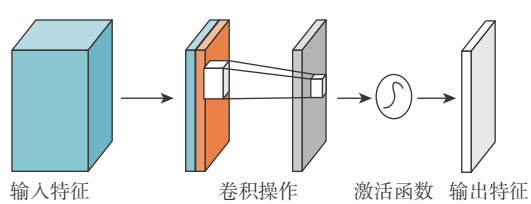


图4 空间注意力机制结构

Fig. 4 Structure of spatial attention mechanisms

式中: f_c为卷积操作; k为卷积核大小; $\boldsymbol{F}^{\mathrm{s}}_{\mathrm{avg}}$和$\boldsymbol{F}^{\mathrm{s}}_{\mathrm{max}}$分别为空间平均池化和最大池化后的特征图。

1.4　SENet 注意力机制

压缩与激励网络 (squeeze-and-excitation networks, SENet) 是一种专注于通道注意力的机制, 通过 Squeeze-and-Excitation 操作提升网络对重要通道特征的关注。其核心思想是通过全局平均池化 (global average pooling, GAP)来获取通道全局特征, 通过权重重新分配, 强化重要特征, 图 5 展示了 SENet 的主要结构。SENet 的详细操作步骤如下。

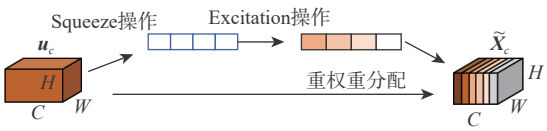


图 5　SENet 网络结构

Fig. 5　SENet network structure

1) Squeeze 阶段。该阶段主要通过 GAP 将输入的特征图在空间维度上压缩, 提取每个通道的全局特征。具体来说, 对于每个通道, 计算所有位置的平均值, 生成一个包含所有通道全局统计信息的特征向量z_c, 用以表示每个通道的整体重要性:

$$z_c = F_{\mathrm{sq}}(\boldsymbol{u}_c) = \frac{1}{HW}\sum_{i=1}^{H}\sum_{j=1}^{W}\boldsymbol{u}_c(i,j) \tag{4}$$

式中: H和W分别为特征图的高和宽; $\boldsymbol{u}_c(i,j)$为通道c上特定位置的特征值; F_{sq}为 Squeeze 函数。

在该阶段会输出一个大小为$1\times1\times C$的特征向量$\boldsymbol{z}=[z_1,z_2,\cdots,z_c]$, 其包含了每个通道的全局语义信息。

2) Excitation 阶段。在该阶段, SENet 利用一个轻量级的 2 层全连接网络对 Squeeze 阶段提取的通道特征向量进行建模。共分为 2 个阶段: 第 1 层全连接将通道数降维到一个较小的维度C_r, 通过压缩比r减少计算复杂度:

$$\boldsymbol{f}_1 = \mathrm{ReLU}(\boldsymbol{W}_1\boldsymbol{z}+\boldsymbol{b}_1) \tag{5}$$

式中: $\boldsymbol{f}_1$为降维后的通道特征向量; $\boldsymbol{W}_1$为权重矩阵; $\boldsymbol{b}_1$为偏置项。

第 2 层全连接还原到原始通道维度C, 通过 sigmoid 激活函数生成每个通道的权重(注意力分数)。这些权重表示每个通道在特征图中的重要性:

$$\boldsymbol{s} = \sigma(\boldsymbol{W}_2\boldsymbol{f}_1+\boldsymbol{b}_2) \tag{6}$$

式中: $\boldsymbol{s}$为每个通道的权重, 元素范围在 0～1 之间; $\boldsymbol{W}_2$为权重矩阵; $\boldsymbol{b}_2$为偏置项。

该阶段会输出大小为$1\times1\times C$的注意力向量$\boldsymbol{s}$, 表示每个通道的权重。

3) 重权重分配。SENet 将 Excitation 阶段生成的通道权重应用到原始特征图上, 通过逐通道的加权操作重新调整每个通道的特征强度。权重高的通道被强化, 而权重低的通道被抑制, 从而提升对关键特征的关注, 优化模型对输入特征的表达能力:

$$\tilde{\boldsymbol{X}}_c = \boldsymbol{s}_c\boldsymbol{X}_c \tag{7}$$

式中: $\boldsymbol{s}_c$为通道c的权重; $\boldsymbol{X}_c$为通道c的特征图。

在该阶段会输出大小为$H\times W\times C$的特征图$\tilde{\boldsymbol{X}}_c$, 其中, 每个通道已经按照重要性重新加权。

1.5　Transformers 注意力机制

Transformers 的核心是其强大的注意力机制, 尤其是自注意力机制, 其使 Transformers 能够捕捉序列中任意位置的全局依赖关系。

自注意力机制能够更有效地学习结构化和非结构化数据的特征。实质是通过 key-value 的键值对注意力权重进行优化, 从而自动学习注意力权重。模型会从大量特征中学习到有用的特征, 并从特征之间构建注意力关系, 以便将关键特征更准确地抽取出来。在推荐算法中通过使用 query、key、value 来建立语义关系, 从而帮助推荐系统对用户偏好进行识别和学习。具体步骤如下:

将输入的信息$\boldsymbol{X}$线性投影到 3 个不同的空间, 得到 3 个不同的向量: 查询向量$\boldsymbol{Q}$、键向量$\boldsymbol{K}$、值向量$\boldsymbol{V}$:

$$\boldsymbol{Q} = \boldsymbol{W}_{\boldsymbol{Q}}\boldsymbol{X} \tag{8}$$

$$\boldsymbol{K} = \boldsymbol{W}_{\boldsymbol{K}}\boldsymbol{X} \tag{9}$$

$$\boldsymbol{V} = \boldsymbol{W}_{\boldsymbol{V}}\boldsymbol{X} \tag{10}$$

式中: $\boldsymbol{W}_{\boldsymbol{Q}}$、$\boldsymbol{W}_{\boldsymbol{K}}$、$\boldsymbol{W}_{\boldsymbol{V}}$为可学习参数。

根据键值对注意力机制来计算最后的输出:

$$\mathrm{attention}(\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V}) = \mathrm{softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\mathrm{T}}}{\sqrt{d_k}}\right)\cdot\boldsymbol{V} \tag{11}$$

式中: attention() 为注意力机制的封装函数; softmax() 为归一化函数; d_k为 key 中的向量维度, 能够减小 key 维度变化对结果的影响, 使梯度更加稳定。

表 1 总结了 CBAM、SENet 和 Transfromers 的优势与不足。

综上所述, CBAM 相较于 SENet 和 Transformers 的主要优势在于轻量化设计和通道+空间注意力的结合, 既能高效捕获局部与全局特征, 又具备较强的多模态适应性。此外, CBAM 计算成本低, 适合大规模推荐系统, 且模块化设计便于集成, 比 SENet 更全面, 比 Transformers 更高效。

表 1 CBAM、SENet 和 Transformers 的优势与不足

Table 1 Advantages and disadvantages of CBAM, SENet, and Transformers

特征	主要关注点	结构	复杂度	处理能力	对稀疏特征的处理能力	计算资源	优点
CBAM	通道和空间注意力	2个子模块: 通道注意力 + 空间注意力	轻量级, 计算成本低	捕获局部与全局信息(通道和空间层次)	较强, 可以捕捉到物品或用户行为特征的空间依赖	较低, 适合大规模应用	轻量级、灵活、多模态融合能力强
SENet	通道注意力	压缩与激励	较轻量, 计算成本较低	主要捕获通道级别的全局信息	较强, 但主要针对通道特征	较低, 适合资源有限的应用	高效、轻量、适合处理高维稀疏特征
Transformers	自注意力	自注意力层	计算复杂度高	捕获长序列中的全局依赖, 适合长序列推荐	对长序列的稀疏特征建模效果好, 但计算开销较大	高, 需要较强的硬件支持(尤其是内存和计算力)	强大的全局依赖建模能力, 适合复杂数据处理

2 模型框架

2.1 模型概述

针对传统的图神经网络使用简单的注意力机制提取图结构中的信息, 没有更加细致准确地挖掘图结构中深层次的信息, 而且忽略了数据集中用户与物品交互的时间及地点等信息, 不仅造成了信息的浪费, 而且未准确地对用户进行个性化推荐的问题。本文提出融合双通道注意力和时间编码的图神经网络推荐算法 GUITRec, 其具体结构如图 6 所示, 模型一共分为 3 部分, 分别是物品建模、用户建模和时间建模。

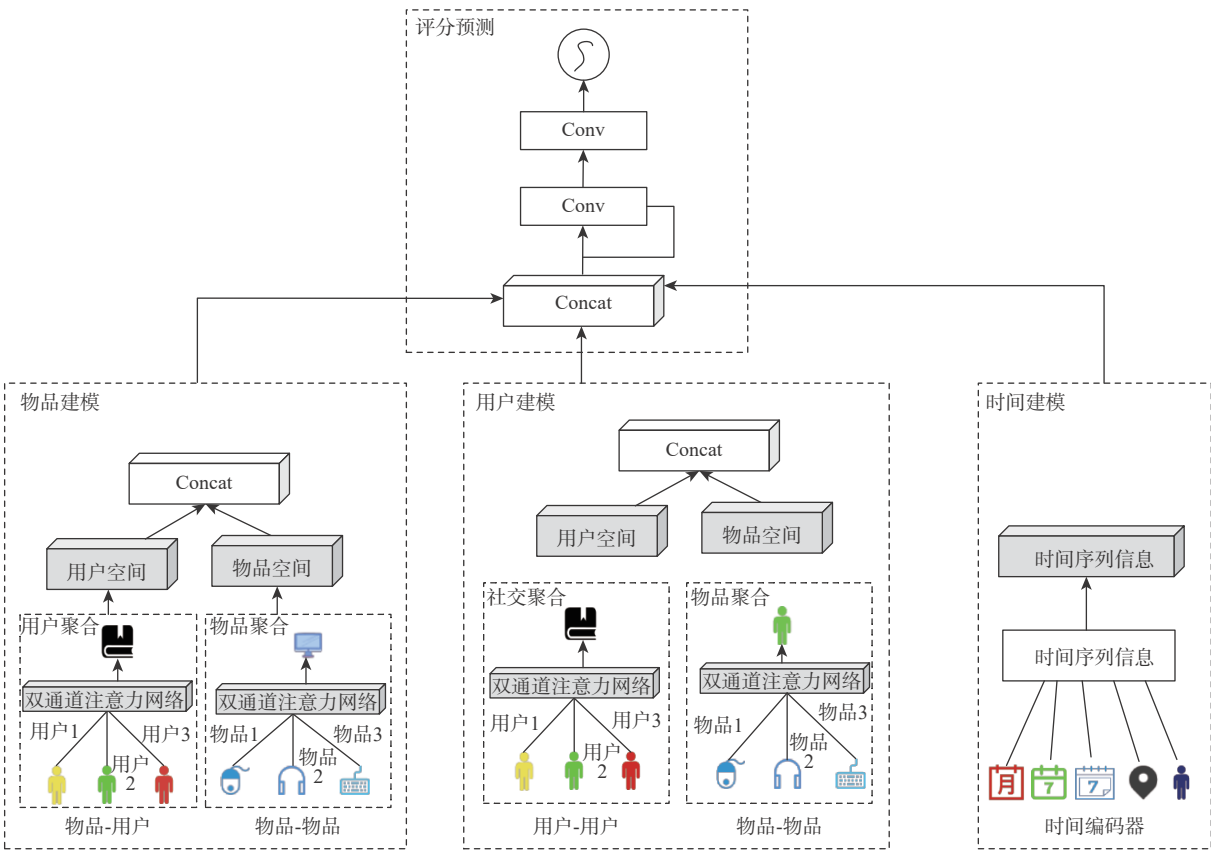


图 6 GUITRec 模型结构

Fig. 6 GUITRec model structure

2.2 物品建模

在物品建模过程中, 物品的嵌入表示学习扮演着核心角色, 其不仅捕捉了物品与用户交互行为的直接反馈, 还深入挖掘了物品间复杂而微妙的相似关系, 这为学习物品的特征关系提供了不同的视角。本文提出一种综合性的物品建模策略, 融合了 2 种关键的聚合机制——用户聚合与物品聚合, 旨在从数据集的丰富信息中高效且精确地学习物品的特征表示。

2.2.1 物品建模-用户聚合

用户-物品图作为一种关键数据结构, 不仅包含了用户与物品之间的交互行为, 还包含用户与物品

的评分。利用用户-物品图中丰富的交互数据与评分, 通过聚合函数, 能够挖掘并学习每个物品 v_j 在用户空间中的潜在特征表示 $\boldsymbol{z}_j^{\mathrm{U}}$, 从而更有效地捕捉物品与用户之间的关系和交互信息, 并收集、整合与其相关的用户交互记录与评分数据, 以此构建出既全面又精确的物品信息模型:

$$\boldsymbol{z}_j^{\mathrm{U}} = \sigma(\boldsymbol{W}' \cdot A_{\mathrm{users}}(\boldsymbol{f}_{jt}) + \boldsymbol{b}) \qquad \forall t \in B_{(j)} \tag{12}$$

式中: A_{users} 为用户聚合函数, 主要用于将用户的交互和评分信息进行聚合; $B_{(j)}$ 为与物品 v_j 交互过的用户集合; $\boldsymbol{f}_{jt}$ 为用户意见交互系数; $\boldsymbol{W}'$ 为权重矩阵; $\boldsymbol{b}$ 为偏置项。

即使针对同一个物品, 用户在与该物品的交互过程中, 受自身状态或周围环境等因素的影响, 可能会对该物品给出不同的评分。这种差异化的评分信息能够有效反映出用户兴趣的动态变化, 同时, 也能帮助捕捉物品的不同特征, 从而对物品的潜在表征进行更深入的学习和建模。因此, 在用户与物品 v_j 的交互过程中, 需要引入用户意见交互系数来表示用户对物品的动态评分变化。该系数可以量化用户对同一物品的不同意见, 有助于模型更准确地理解用户偏好随时间的变化及其对推荐结果的影响。

$$\boldsymbol{f}_{jt} = g_{\mathrm{u}}([\boldsymbol{p}_t \oplus \boldsymbol{e}_{\mathrm{r}}]) \tag{13}$$

式中: $\boldsymbol{p}_t$ 为原始的用户嵌入信息; $\boldsymbol{e}_{\mathrm{r}}$ 为用户的评分信息; "$\oplus$" 表示连接操作; g_{u} 为用户聚合信息的函数, 主要用于将评分信息和用户的原始信息进行融合。

对于聚合函数 A, 常对 $\boldsymbol{f}_{jt}$ 进行加权平均。但该方法将与物品 v_j 监护过的全部用户所含有的信息均认为是同等作用, 往往会忽视重要信息, 同时, 也会带来无用信息干扰最后的预测结果。针对上述问题, 本文将线性加权平均的聚合方式替换为通道卷积注意力机制即 CBAM。CBAM 注意力机制的好处是可以自适应地调整图结构中节点特征及节点之间关系的重要性, 使模型可以更好地捕捉图结构中的关键信息, 同时, 也可以更好地关注对推荐结果有重要影响的特征, 从而提升推荐的准确性。

引入 CBAM 注意力机制后, 物品 j 在用户空间中的潜在特征表示重新计算, 如式 (14) 所示, 不再对原始用户特征 $\boldsymbol{f}'_{jt}$ 直接求和, 而是对经过注意力加权后的用户特征进行聚合:

$$\boldsymbol{z}_j^{\mathrm{U}} = \sigma\left(\boldsymbol{W}' \sum_{\forall t \in B_{(j)}} \boldsymbol{f}''_{jt} + \boldsymbol{b}\right) \tag{14}$$

其中, 加权后的用户特征 $\boldsymbol{f}'_{jt}$ 由空间注意力模块对原始特征逐元素加权得到。具体地, 将原始用户特征 $\boldsymbol{f}_{jt}$ 输入空间注意力函数 $\boldsymbol{M}_{\mathrm{s}}(\cdot)$ 得到与 $\boldsymbol{f}_{jt}$ 同维度的空间注意力权重图, 再与原特征逐元素相乘, 表达式为

$$\boldsymbol{f}'_{jt} = \boldsymbol{M}_{\mathrm{s}}(\boldsymbol{f}_{jt}) \otimes \boldsymbol{f}_{jt} \tag{15}$$

为进一步描述特征, 将经过第一次加权后的特征 $\boldsymbol{f}'_{jt}$ 再次送入空间注意力模块进行二次加权, 得到更深层的精修特征, 计算如下:

$$\boldsymbol{f}''_{jt} = \boldsymbol{M}_{\mathrm{s}}(\boldsymbol{f}'_{jt}) \otimes \boldsymbol{f}'_{jt} \tag{16}$$

通道注意力模块的计算如下:

$$\begin{aligned}\boldsymbol{M}_{\mathrm{c}}(\boldsymbol{f}_{jt}) &= \sigma(\mathrm{MLP}(\mathrm{AvgPool}(\boldsymbol{f}_{jt})) + \mathrm{MLP}(\mathrm{MaxPool}(\boldsymbol{f}_{jt}))) = \\ &\sigma(\boldsymbol{W}_1(\boldsymbol{W}_0(\mathrm{avg}(\boldsymbol{f}_{jt}^{\mathrm{c}}))) + \boldsymbol{W}_1(\boldsymbol{W}_0(\max(\boldsymbol{f}_{jt}^{\mathrm{c}}))))\end{aligned} \tag{17}$$

空间注意力模块的计算如式 (18) 所示: 对输入特征分别沿通道维度执行平均池化与最大池化, 得到 2 个二维空间描述图; 将两者在通道维度上拼接后, 经过一个 $k \times k$ 卷积层 $c^{k \times k}$ 进行融合, 再经 Sigmoid 激活函数 σ 生成空间注意力权重。

$$\begin{aligned}\boldsymbol{M}_{\mathrm{s}}(\boldsymbol{f}_{jt}) &= \sigma(c^{k \times k}([\mathrm{AvgPool}(\boldsymbol{f}_{jt}); \mathrm{MaxPool}(\boldsymbol{f}_{jt})])) = \\ &\sigma(c^{k \times k}[\mathrm{avg}(\boldsymbol{f}_{jt}^{\mathrm{s}}); \max(\boldsymbol{f}_{jt}^{\mathrm{s}})])\end{aligned} \tag{18}$$

式中: "$\otimes$" 表示逐元素相乘; $\boldsymbol{f}_{jt}^{\mathrm{c}}$、$\boldsymbol{f}_{jt}^{\mathrm{s}}$ 分别为通道注意力、空间注意力机制中用户 i 与物品 j 的初始交互特征表示。

2.2.2　物品建模-物品聚合

物品和物品之间具有某些属性的相似, 并不是独立存在的。以鼠标与键盘为例, 这 2 类物品虽功能各异, 却共享了 "电子器材" 这一核心属性, 并紧密关联于电脑、平板等更广泛的电子设备生态系统之中, 因此, 在构建物品特征模型时, 需超越单一物品的界限, 深入探索其与其他物品之间的相似性与关联性。

为此, 本文提出在物品空间中引入 "物品学习系数" 概念, 旨在通过聚合具有相似关系或共享属性的物品群体, 来增强单个物品的特征表示能力。该方法不仅考虑了物品自身的固有属性, 还融入了其在整个物品网络中的位置与角色, 从而实现了对物品特征的更全面、更深入的刻画。具体聚合方式为

$$\boldsymbol{h}_j^{\mathrm{I}} = \sigma(\boldsymbol{W}' \cdot A_{\mathrm{items}}(\boldsymbol{y}_{jk}) + \boldsymbol{b}) \qquad \forall k \in I_{(j)} \tag{19}$$

式中: $\boldsymbol{h}_j^{\mathrm{I}}$ 为物品 j 经过相似物品聚合后得到的隐藏表示向量; A_{items} 为物品聚合函数; $\boldsymbol{y}_{(j)}$ 为与物品 v_j 相似的物品集合; $\boldsymbol{y}_{jk}$ 为物品相似系数。

当用户和物品发生交互行为时, 可以通过物品的评分或与目标物品相似度的物品评分等信息作为参考。例如, 当《热辣滚烫》上映时, 想去观看这部影片的人不仅会去关注这部影片的评分, 而且还会去看贾玲导演或参与拍摄的其他影片的评分情

况以选择是否观看该部影片。因此，对于物品v_j和物品v_k中具有相似的属性，引入物品相似性感知系数$\boldsymbol{y}_{jk}$来表示物品之间的相似性：

$$\boldsymbol{y}_{jk}=g_{\mathrm{v}}([\boldsymbol{q}_k\oplus\boldsymbol{k}_{\mathrm{s}}]) \tag{20}$$

式中：$\boldsymbol{q}_k$为与物品具有相似属性的嵌入信息；g_{v}为融合物品相似信息和相似度系数的函数；$\boldsymbol{k}_{\mathrm{s}}$为物品之间的相似度系数，本文采用皮尔逊相似度系数。

同理，物品之间的相似信息也同样不是同等重要的。例如，键盘和鼠标这2个物品之间重要的相似信息是“电子设备”“电脑”，不重要的相似性信息则是“青年人”。因此，应引入注意力机制对不同的相似信息赋予不同的权重。因此，本文聚合函数引入了通道卷积注意力机制CBAM对物品之间的相似信息进行监控，给重要的相似性信息赋予较大的权重，给不重要的信息或无用的信息赋予较小的权重：

$$\boldsymbol{h}_j^{\mathrm{I}}=\sigma\left(\boldsymbol{W}'\sum_{\forall k\in I_{(j)}}\boldsymbol{y}_{jk}^{''}+\boldsymbol{b}\right) \tag{21}$$

$$\boldsymbol{y}'_{jk}=\boldsymbol{M}_{\mathrm{s}}(\boldsymbol{y}_{jk})\otimes\boldsymbol{y}_{jk} \tag{22}$$

$$\boldsymbol{y}_{jk}^{''}=\boldsymbol{M}_{\mathrm{s}}(\boldsymbol{y}'_{jk})\otimes\boldsymbol{y}'_{jk} \tag{23}$$

$$\begin{aligned}\boldsymbol{M}_{\mathrm{c}}(\boldsymbol{y}_{jk})&=\sigma(\mathrm{MLP}(\mathrm{avg}(\boldsymbol{y}_{jk}))+\mathrm{MLP}(\max(\boldsymbol{y}_{jk})))=\\&\sigma(\boldsymbol{W}_1(\boldsymbol{W}_0(\mathrm{avg}(\boldsymbol{y}_{jk}^{\mathrm{c}})))+\boldsymbol{W}_1(\boldsymbol{W}_0(\max(\boldsymbol{y}_{jk}^{\mathrm{c}}))))\end{aligned} \tag{24}$$

$$\begin{aligned}\boldsymbol{M}_{\mathrm{s}}(\boldsymbol{y}_{jk})&=\sigma(c^{k\times k}([\mathrm{avg}(\boldsymbol{y}_{jk});\max(\boldsymbol{y}_{jk})]))=\\&\sigma(c^{k\times k}[\mathrm{avg}(\boldsymbol{y}_{jk}^{\mathrm{s}});\max(\boldsymbol{y}_{jk}^{\mathrm{s}})])\end{aligned} \tag{25}$$

式中：$\boldsymbol{y}_{jk}^{\mathrm{c}}$、$\boldsymbol{y}_{jk}^{\mathrm{s}}$分别为通道注意力、空间注意力物品相似性感知系数。

2.2.3 物品表示

为充分地对物品的特征进行学习，需要将用户聚合和物品聚合的结果向量进行拼接，形成最终的物品特征向量：

$$\boldsymbol{I}=[\boldsymbol{z}_j^{\mathrm{U}}\oplus\boldsymbol{h}_j^{\mathrm{I}}] \tag{26}$$

2.3 用户建模

用户空间的建模与物品空间的建模相似，均采用2种聚合方式，即用户聚合和物品聚合。这是因为用户不仅与物品存在交互关系，还可能与其他用户存在好友关系。因此，使用这2种建模方式，不仅能够深入挖掘用户与物品之间的互动，还能够通过用户之间的相似性捕捉到更多潜在信息。这种双重聚合方法能够更全面地刻画用户行为，提升模型对用户偏好和物品特征的理解能力。

2.3.1 用户建模-物品聚合

在物品聚合函数中，将多个用户交互过的相同物品信息进行聚合，得到聚合后的隐藏表示向量：

$$\boldsymbol{h}_i^{\mathrm{I}}=\sigma(\boldsymbol{W}'\cdot A_{\mathrm{items}}(\boldsymbol{X}_{ia}+\boldsymbol{b}))\qquad\forall a\in C_{(i)} \tag{27}$$

式中：$C_{(i)}$为与用户u_i交互过的物品集合；$\boldsymbol{X}_{ia}$为用户u_i与项目v_a的交互评分信息。

当用户和物品进行交互时，可以通过不同的方式来展现自己对该物品的喜恶，例如，人们在看电影时可以通过对电影的评分、是否向周围的人推荐作为自己的评价方式；人们在看抖音、快手等小视频时，可以通过停留时间、是否感兴趣等来展示自己的喜好。上述信息对用户建模是非常重要的，可以更好地建立用户画像，更加精确地捕捉用户偏好。因此，引入用户嵌入向量$\boldsymbol{e}_{\mathrm{r}}\in\mathbf{R}_d$，$d$为嵌入向量维度，将用户的评分等信息融入向量中，同时，引入$\boldsymbol{X}_{ia}$作为物品表征向量和用户向量融合的向量：

$$\boldsymbol{X}_{ia}=[\boldsymbol{q}_{\mathrm{u}}\oplus\boldsymbol{e}_{\mathrm{r}}] \tag{28}$$

式中：$\boldsymbol{q}_{\mathrm{u}}$为用户$u_i$与物品$v_a$交互的物品向量。

同理，用户建模的聚合函数仍采用通道卷积注意力机制：

$$\boldsymbol{h}_i^{\mathrm{I}}=\sigma\left(\boldsymbol{W}'\sum_{\forall a\in C_{(i)}}\boldsymbol{X}_{ia}^{''}+\boldsymbol{b}\right) \tag{29}$$

$$\boldsymbol{X}'_{ia}=\boldsymbol{M}_{\mathrm{s}}(\boldsymbol{X}_{ia})\otimes\boldsymbol{X}_{ia} \tag{30}$$

$$\boldsymbol{X}_{ia}^{''}=\boldsymbol{M}_{\mathrm{s}}(\boldsymbol{X}'_{ia})\otimes\boldsymbol{X}'_{ia} \tag{31}$$

$$\begin{aligned}\boldsymbol{M}_{\mathrm{c}}(\boldsymbol{X}_{ia})&=\sigma(\mathrm{MLP}(\mathrm{AvgPool}(\boldsymbol{X}_{ia}))+\\&\mathrm{MLP}(\mathrm{MaxPool}(\boldsymbol{X}_{ia})))=\sigma(\boldsymbol{W}_1(\boldsymbol{W}_0(\mathrm{avg}(\boldsymbol{X}_{ia}^{\mathrm{c}})))+\\&\boldsymbol{W}_1(\boldsymbol{W}_0(\max(\boldsymbol{X}_{ia}^{\mathrm{c}}))))\end{aligned} \tag{32}$$

$$\begin{aligned}\boldsymbol{M}_{\mathrm{s}}(\boldsymbol{X}_{ia})&=\sigma(c^{k\times k}([\mathrm{AvgPool}(\boldsymbol{X}_{ia});\mathrm{MaxPool}(\boldsymbol{X}_{ia})]))=\\&\sigma(c^{k\times k}[\mathrm{avg}(\boldsymbol{X}_{ia}^{\mathrm{s}});\max(\boldsymbol{X}_{ia}^{\mathrm{s}})])\end{aligned} \tag{33}$$

式中：$\boldsymbol{X}_{ia}^{\mathrm{c}}$、$\boldsymbol{X}_{ia}^{\mathrm{s}}$分别为通道注意力、空间注意力物品表征向量和用户向量融合的向量。

2.3.2 用户建模-用户聚合

用户偏好会受到周围人或偏好相似用户的影响，因此，对用户的偏好进行聚合十分重要。但不同的用户受到社交的影响强度不同，因此，采用CBAM注意力机制对目标用户不同的社交赋予不同的权重。需要先获取用户-用户的信息：

$$\boldsymbol{h}_i^{\mathrm{s}}=\sigma(\boldsymbol{W}'\cdot A_{\mathrm{friends}}(\boldsymbol{h}_f+\boldsymbol{b}))\qquad\forall f\in F_{(i)} \tag{34}$$

将用户-用户的相似向量$\boldsymbol{h}_f^{\mathrm{I}}$送入CBAM注意力机制中，即用户聚合函数$A_{\mathrm{friends}}$为CBAM注意力机制：

$$\boldsymbol{h}_i^{\mathrm{s}}=\sigma\left(\boldsymbol{W}'\sum_{\forall f\in f_{(i)}}\boldsymbol{h}_f^{''}+\boldsymbol{b}\right) \tag{35}$$

$$\boldsymbol{h}'_f=\boldsymbol{M}_{\mathrm{s}}(\boldsymbol{h}_f)\otimes\boldsymbol{h}_f \tag{36}$$

$$\boldsymbol{h}_f^{''}=\boldsymbol{M}_{\mathrm{s}}(\boldsymbol{h}'_f)\otimes\boldsymbol{h}'_f \tag{37}$$

$$\boldsymbol{M}_{\mathrm{c}}(\boldsymbol{h}_f)=\sigma(\mathrm{MLP}(\mathrm{AvgPool}(\boldsymbol{h}_f))+\mathrm{MLP}(\mathrm{MaxPool}(\boldsymbol{h}_f)))=\sigma(\boldsymbol{W}_1(\boldsymbol{W}_0(\mathrm{avg}(\boldsymbol{h}_f^{\mathrm{c}})))+\boldsymbol{W}_1(\boldsymbol{W}_0(\max(\boldsymbol{h}_f^{\mathrm{c}}))))\tag{38}$$

$$\boldsymbol{M}_{\mathrm{s}}(\boldsymbol{h}_f)=\sigma(c^{k\times k}([\mathrm{AvgPool}(\boldsymbol{h}_f);\mathrm{MaxPool}(\boldsymbol{h}_f)]))=\sigma(c^{k\times k}[\mathrm{avg}(\boldsymbol{h}_f^{\mathrm{s}});\max(\boldsymbol{h}_f^{\mathrm{s}})])\tag{39}$$

式中: $\boldsymbol{h}_f^{\mathrm{c}}$、$\boldsymbol{h}_f^{\mathrm{s}}$分别为通道注意力、空间注意力用户-用户的相似向量。

2.3.3　用户表示

为充分地对用户的特征进行学习, 需要将用户聚合和物品聚合的结果向量进行拼接, 形成最终的用户特征向量:

$$\boldsymbol{U}=[\boldsymbol{h}_i^{\mathrm{I}}\oplus\boldsymbol{h}_i^{\mathrm{s}}]\tag{40}$$

2.4　时间建模

该模型中的时间编码采用了多维度的方式进行建模。通过局部时间戳、全局时间戳、周编码、月编码等不同层次的时间建模方式全面地记录和反映时间信息。这种时间建模方式可以捕捉不同时间尺度下的数据变化和特征。局部时间戳可以更精细地定位特定事件或行为发生的具体时间点; 全局时间戳则可以提供一个整体的时间参照, 便于在更大的时间范围内进行数据分析和比较。周编码和月编码有助于从周期性的角度观察数据的趋势和规律, 如某些行为在每周或每月的特定时间段会呈现出一定的模式。通过这些多维度的时间编码, 可以更深入地理解数据与时间的关系, 为后续的数据分析和算法应用提供更丰富的时间信息基础。

相比于现有的时间建模方法(如 LSTM 等时间序列模型), 本文提出的时间编码方法具有显著的优势和特点。传统的时间序列模型(如 LSTM、GRU)主要通过递归方式逐步捕捉时间序列的动态变化, 适合处理连续的时间序列数据。然而, 这些方法通常只关注时间信息的顺序依赖性, 对时间中的全局、局部和周期性特征的捕捉能力有限, 且当序列较长时容易产生梯度消失等问题。

本文提出的时间编码方法则采用多维度建模, 对局部时间、全局时间和周期性时间特征进行编码。该方法能够捕捉时间的局部和全局规律, 使模型既可以精准定位特定时间点的行为特征, 又可以从更大的时间范围捕获行为趋势; 周期性时间(周编码、月编码)的加入, 能够自然地捕捉用户行为的周期性模式, 无需额外设计复杂的递归结构。时间编码的结构如图 7 所示。

2.4.1　全局时间编码

在全局时间编码中, 本文先将时间戳转化为数值型的秒级时间, 再提起年份、月、日和周等信息。在推荐系统中, 时间的周期性十分明显。如音乐推荐场景中, 周一早上人们常需充满活力的音乐开启工作, 周五晚上则倾向轻松音乐迎接周末; 电商推荐中, 换季时人们对不同季节的服装有周期性需求; 影视推荐方面, 节假日人们倾向大片或喜剧片, 工作日则可能选择短时长剧集或纪录片。推荐系统考虑时间周期性, 能够有效地捕捉时间的周期性。无论是一天、一周还是一年, 时间都具有明显的周期性。通过正弦和余弦函数, 可以将时间戳映射到一个周期为相应时间长度的曲线上。因此, 在全局时间编码阶段, 本文将对时间信息进行周期化表示, 详细信息如下:

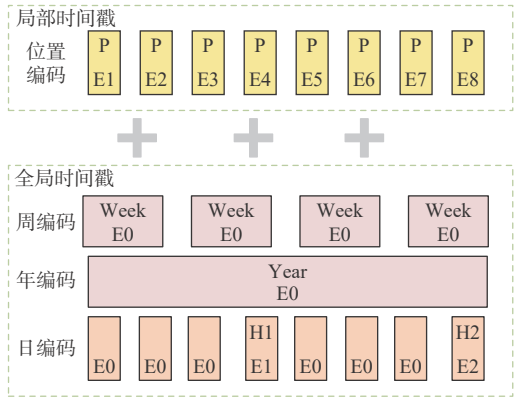


图 7　时间建模结构

Fig. 7　Time modeling structure

1) 日编码。其可反映短期用户行为变化, 适应短期趋势并评估短期推荐效果, 如根据一天不同时段调整推荐内容:

$$\boldsymbol{n}_{\mathrm{day}}=\left[\sin\left(\frac{2\pi T}{24\times60\times60}\right),\cos\left(\frac{2\pi T}{24\times60\times60}\right)\right]\tag{41}$$

式中: $\boldsymbol{n}_{\mathrm{day}}$为日编码; T为时间戳, s; 分母 24×60×60 表示一天的秒数。

将时间戳映射到一个周期为一天的正弦和余弦曲线上, 这两者的结合使时间信息可以嵌入一个二维圆形轨迹中, 能够同时保留周期性特征和连续性特征。例如, 当时间戳 T=43 200 s 时, 即为一天中的中午 12 点, 将 T 代入式(41)中可得到当前时间戳对应的日编码为[0, −1], 表示中午 12 点的时间特征。

2) 周编码。工作日和周末差异, 适应周期性活动, 还能评估推荐系统的稳定性, 如根据不同日子提供不同类型推荐, 以满足用户多样化需求:

$$\boldsymbol{n}_{\mathrm{week}}=\left[\sin\left(\frac{2\pi T}{24\times60\times60\times7}\right),\cos\left(\frac{2\pi T}{24\times60\times60\times7}\right)\right]\tag{42}$$

式中: $\boldsymbol{n}_{\mathrm{week}}$为周编码; 分母$24\times60\times60\times7$为一周的秒数。

周编码能够捕捉一周内的行为变化, 如周一到

周五的工作日和周六、周日的休息日模式。例如，T=304 200 s，即周三中午12点，将T代入式(42)中即可得到周编码为[0,−1]，表示一周中周三的中午时间特征。

3) 年编码。其能捕捉季节性和周期性需求，用于长期用户行为分析和规划长期推荐策略：

$$\boldsymbol{n}_{\text{year}}=\left[\sin\left(\frac{2\pi T}{24\times60\times60\times365}\right),\cos\left(\frac{2\pi T}{24\times60\times60\times365}\right)\right] \tag{43}$$

式中：$\boldsymbol{n}_{\text{year}}$为年编码；分母$24\times60\times60\times365$为一年的秒数。

年编码能够捕捉一年中长周期的时间变化，如季节性消费习惯或节假日购物模式。例如，T=15 768 000 s，即一年中的第182天，即6月底，将T代入式(43)中即可得到年编码为[0,−1]，表示一年中的时间特征。

2.4.2 局部时间编码——位置编码

在Transformers中，位置编码起着至关重要的作用，其为输入序列中的每个位置赋予独特的表示，使模型能够捕捉序列中的顺序信息。将邮编作为位置信息的输入，例如，邮编“12345”可以被看作一个长度为5的序列，每个数字占据一个位置。对于邮编序列，设向量维度为d_{model}，邮编位置索引为p_{os}，取值范围为0～4，分别对应邮编中的5个位置。同时，l表示向量维度的索引。位置编码的计算式为

$$P_{(p_{\text{os}},2l)}=\sin\left(p_{\text{os}}/1\,000^{\frac{2l}{d_{\text{model}}}}\right) \tag{44}$$

式(44)表示在偶数维度上，位置编码由正弦函数计算得出。其中，p_{os}决定了正弦函数的相位，而随着l和d_{model}的变化，正弦函数的频率也会相应改变。这样可以为不同的位置和维度生成独特的编码值。

$$P_{(p_{\text{os}},2l+1)}=\cos\left(p_{\text{os}}/1\,000^{\frac{2l}{d_{\text{model}}}}\right) \tag{45}$$

在奇数维度上，位置编码由余弦函数计算得出。与正弦函数类似，通过调整p_{os}、l和d_{model}，可以得到不同位置和维度的独特编码值。

最后得到的位置编码是正余弦值相互交替的：

$$\boldsymbol{P}_{p_{\text{os}}}=\begin{bmatrix}\sin(\omega_1 p_{\text{os}})\\ \cos(\omega_1 p_{\text{os}})\\ \sin(\omega_2 p_{\text{os}})\\ \cos(\omega_2 p_{\text{os}})\\ \vdots\\ \sin(\omega_{d/2} p_{\text{os}})\\ \cos(\omega_{d/2} p_{\text{os}})\end{bmatrix} \tag{46}$$

式中：$\omega_{d/2}=1/1\,000^{\frac{2l}{d_{\text{model}}}}$。

将局部时间编码和位置时间编码进行拼接，形成最终的时间信息编码：

$$\boldsymbol{T}_{\text{s}}=[\boldsymbol{n}_{\text{day}},\boldsymbol{n}_{\text{week}},\boldsymbol{n}_{\text{year}},\boldsymbol{P}_{p_{\text{os}}}] \tag{47}$$

2.5 评分预测及模型训练

在评分预测部分，将用户建模、物品建模和时间建模部分所输出的向量进行拼接融合，再将融合向量送入前馈网络中进行评分预测：

$$\begin{cases}\boldsymbol{g}_1=[\boldsymbol{U}\oplus\boldsymbol{I}\oplus\boldsymbol{T}_{\text{s}}]\\ \boldsymbol{g}_3=\sigma(\boldsymbol{W}_3\boldsymbol{g}_2+\boldsymbol{b}_3)\\ \boldsymbol{g}_2=\sigma(\boldsymbol{W}_2\boldsymbol{g}_1+\boldsymbol{b}_2)\\ \boldsymbol{g}_2=\sigma(\boldsymbol{W}_2\boldsymbol{g}_1+\boldsymbol{b}_2)\\ \quad\vdots\\ \boldsymbol{g}_{n-1}=\sigma(\boldsymbol{W}_n\boldsymbol{g}_{n-1}+\boldsymbol{b}_n)\end{cases} \tag{48}$$

$$R'_{ij}=\boldsymbol{W}'^{\text{T}}\boldsymbol{g}_{n-1} \tag{49}$$

式中：$\boldsymbol{g}_n$为第n层的特征表示；R'_{ij}为用户u_i对物品v_j的预测评分。

由于本文采用预测评分，在训练过程中采用损失函数L_{s}：

$$L_{\text{s}}=\frac{1}{2|N|}\sum_{i,j\in N}(R'_{ij}-R_{ij}) \tag{50}$$

式中：N为用户-物品的交互数量；R_{ij}为用户u_i对物品v_j的真实评分。

3 实验结果及分析

3.1 实验数据集

本文采用Ciao数据集，其来源于Ciao.co.uk，是一个用户生成内容的平台，用户可以在该平台对各种产品和服务进行评分和评论。Ciao数据集包含了大量的用户对DVD等产品的评分和评论信息，这些评分通常以数字形式(1～5)反映用户对产品的满意度或喜好程度。同时，数据集还包含了产品的类别信息及时间戳等信息。Ciao数据集的详细信息如表2所示。

表2 Ciao数据集的详细信息

Table 2 Details of the Ciao dataset

用户数量	物品数量	评分	评分密度	社交连接	社交密度
7 317	104 975	283 320	0.036 9	111 781	0.208 7

其中，评分密度是衡量用户评分数据稀疏程度的一个指标：

$$p_{\text{r}}=N_{\text{r}}/(N_{\text{u}}N_{\text{i}}) \tag{51}$$

式中：p_{r}为评分密度；N_{r}为评分数量；N_{u}为用户数量；N_{i}为物品数量。

$$p_s = N_c/[N_u(N_u-1)] \tag{52}$$

式中: p_s为社交密度; N_c为社交连接数。

3.2　评价指标

本文采用的评价指标为 MAE、MSE、RMSE。

1) MAE 是推荐算法中常用的评价指标, 其是预测值与实际值之差绝对值的平均数:

$$E_{\mathrm{MAE}} = \frac{1}{M}\sum_{m=1}^{M}|y_m-\hat{y}_m| \tag{53}$$

式中: y_m为第m个样本的真实输出值; $\hat{y}_m$为第m个样本的预测输出值; M为样本总数。

MAE 的值越小, 模型的预测越准确。

2) RMSE 衡量的是预测值与实际值之间的偏差程度, 具体计算为预测值与实际值之差平方和的平方根:

$$E_{\mathrm{RMSE}} = \sqrt{\frac{1}{M}\sum_{m=1}^{M}(y_m-\hat{y}_m)^2} \tag{54}$$

RMSE 的取值范围为 0 到正无穷大, 数值越小表示模型的预测误差越小, 表明模型的预测能力越强。

3) MSE 用于衡量预测值与实际值之间平均误差的平方值, MSE 越小, 说明预测效果越好:

$$E_{\mathrm{MSE}} = \frac{1}{M}\sum_{m=1}^{M}(y_m-\hat{y}_m)^2 \tag{55}$$

3.3　实验设置

3.3.1　参数设置

将数据集随机划分 70% 为训练集, 20% 为验证集, 10% 为训练集。在所有的实验中, 参数均先使用均值为 0、标准差为 0.1 的标准正态分布进行初始化。超参数则利用 optuna 优化参数进行寻优, 其中, 用户嵌入大小的搜索范围为 [8,16,32,64,128,256], 批次大小的搜索范围为 [32,64,128,256,512], 学习率的搜索范围为 [0.000 5,0.001 0,0.005 0,0.010 0,0.050 0,0.100 0], Dropout 率的搜索范围为 [0.1,0.2,0.3,0.4,0.5,0.6,0.7,0.8,0.9]。激活函数为 ReLU, 为防止训练过程中产生过拟合现象, 在训练过程中引入早停策略, 设置耐心值为 5 , 如果验证集上的 MSE 连续 5 次没有提高, 则中止实验, 显示评价指标。经过实验, 最优参数如表 3 所示。

表 3　参数最佳值

Table 3　Optimal parameter values

嵌入维度	学习率	批次大小	Dropout率
64	0.000 5	64	0.8

图 8 展示了不同嵌入维度对实验结果的影响。可知, 嵌入维度对推荐算法的性能有显著影响。在嵌入维度从 8 增加到 64 的过程中, 模型的性能逐步提升, 表现为 MAE、MSE 和 RMSE 指标值的显著下降, 分别在嵌入维度为 64 时达到最低值(约为 0.720、0.817 和 0.904), 表明此时模型的特征表示能力和预测效果达到最佳。嵌入维度为 64 提供了一个理想的平衡点, 能够充分捕获用户和物品之间的复杂关系, 同时, 避免因维度不足导致的信息丢失问题。然而, 当嵌入维度进一步增加到 128 和 256 时, 这些指标值均开始上升, 说明过高的嵌入维度可能引入噪声或导致模型过拟合, 降低泛化性能, 同时增加了计算成本。因此, 选择嵌入维度为 64 作为最佳值, 既能够捕获丰富的用户和物品特征, 又能够避免高维度带来的过拟合和计算资源浪费问题。

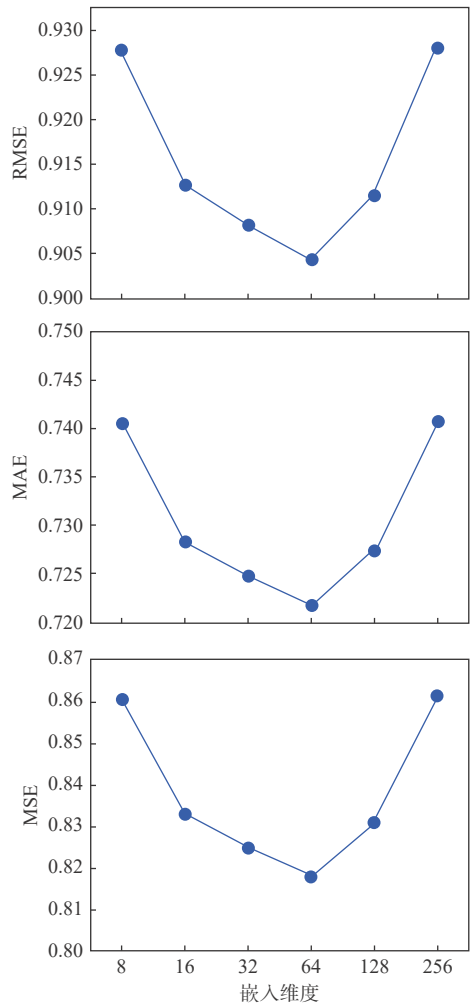


图 8　不同的嵌入维度实验结果

Fig. 8　Experimental results for different embedding dimensions

实验 1　学习率对实验结果的影响。由图 9 可以看出, 不同学习率下 RMSE、MSE 和 MAE 均表现出相似的变化趋势: 随着学习率的增加, 这 3 项指标逐步升高, 表明模型性能逐渐下降。当学习率为 0.000 5 时, RMSE、MSE 和 MAE 分别达到最低

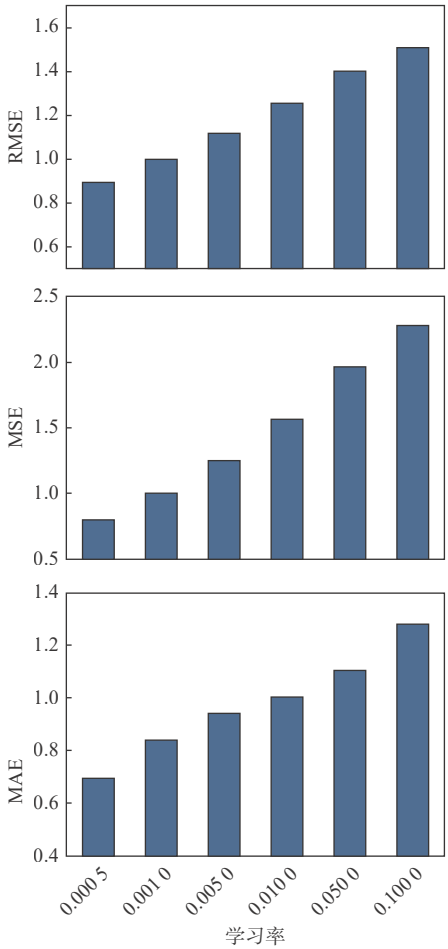


图 9 不同学习率对应的实验结果

Fig. 9 Experimental results corresponding to different learning rates

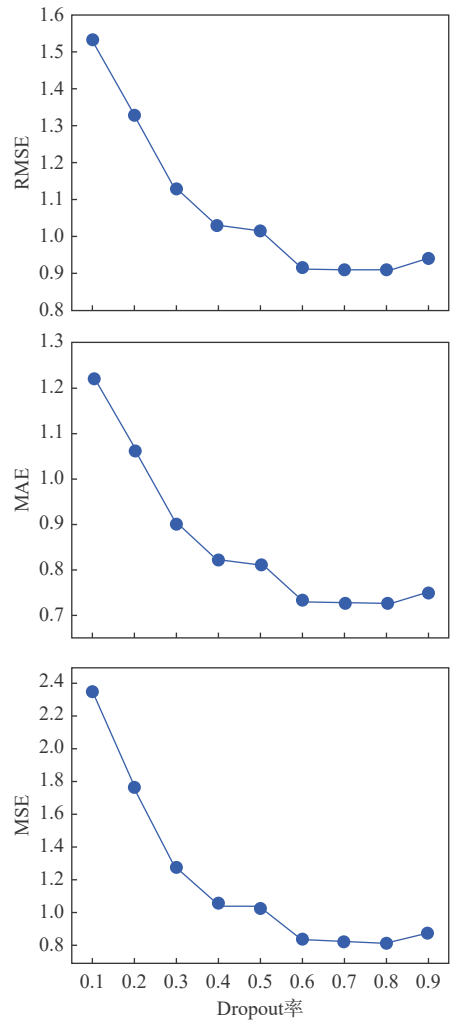


图 10 不同 Dropout 率对应的实验结果

Fig. 10 Experimental results corresponding to different Dropout rates

值，说明此学习率能够有效控制模型误差，实现最佳性能；而随着学习率增加至 0.010 0 及以上，RMSE、MSE、MAE 这 3 个指标不降反升，模型的优化能力显著下降。特别是学习率为 0.100 0 时，3 项误差指标达到最大值，表明过高的学习率导致模型优化过程失控。综上，在本实验中选择学习率的值为 0.000 5。

实验 2 Dropout 率对实验结果的影响。不同的 Dropout 率对模型有着重要的影响。通过对图 10 分析可以发现，随着 Dropout 率的逐步增加，模型的主要性能指标均呈现出逐渐下降的趋势，表明适当的 Dropout 率可以有效地抑制模型过拟合并提升泛化能力。当 Dropout 率达到 0.8 时，3 个性能指标均达到其最优值，此时模型实现了最优。然而，当 Dropout 率进一步增大至 0.9 时，指标不降反升，这表明过高的 Dropout 率会对模型训练带来不利影响。因此，选择 Dropout 率为 0.8 作为本次实验的最优值。

3.3.2 对比模型

1）PMF[23] 是一种基于概率模型的矩阵分解模型，通过将用户-项目评分矩阵分解为 2 个潜在因子矩阵，以处理稀疏数据并进行推荐系统中的预测。

2）SoRec 是一种结合社交网络信息进行推荐的模型，通过利用用户之间的社交关系来增强推荐系统的效果，认为用户的社交关系可以帮助更好地捕捉用户偏好，从而提高推荐的准确性和个性化。

3）社交矩阵分解（social matrix factorization，SocialMF）[15] 是一种推荐系统模型，其结合了矩阵分解技术和社交网络信息，通过考虑用户间的信任关系来提高推荐的准确性。

4）神经矩阵分解（neural matrix factorization，NeuMF）[24] 是一种将矩阵分解与神经网络结合的推荐模型，旨在利用神经网络的非线性建模能力来增强传统矩阵分解的表现。其通过同时学习线性（矩阵分解）和非线性（多层神经网络）特征的交互，能够捕捉到用户和项目之间更加复杂的关系，从而提高推荐精度。

5）基于图的推荐（graph-based recommendation，

GraphRec)[25] 是一种利用图神经网络技术的 SoRec 系统模型。其通过分析社交网络中的用户-物品交互关系图, 捕捉用户行为的深层社会影响, 为用户提供更加个性化和准确的推荐。

3.3.3　与基线模型对比结果

如表 4 所示, 将本文提出的 GUITRec 模型与多种基线模型进行对比, 以验证其有效性。对比的基线模型包括 PMF 模型、SoRec 模型、SocialMF 模型、NeuMF 模型和 GraphRec 模型, 实验数据的结果范围均在 0～1 之间, 以便统一衡量各模型的性能表现。

表 4　与基线模型对比数据

Table 4　Data compared to the baseline model

模型	MSE	MAE	RMSE	F_1
PMF[23]	0.896 4	0.755 6	0.946 8	0.744 7
SoRec	0.835 7	0.729 6	0.914 2	0.755 6
SocialMF[15]	0.819 2	0.722 3	0.905 1	0.757 7
NeuMF[24]	0.816 7	0.721 2	0.903 7	0.756 9
GraphRec[25]	0.813 6	0.727 4	0.902 0	0.758 6
GUITRec	0.813 1	0.720 0	0.902 0	0.762 1

在各项误差指标上, GUITRec 模型均表现出了优势。与 PMF 模型相比, GUITRec 模型的 MSE、MAE 和 RMSE 都有显著降低, 这表明 GUITRec 模型在预测用户对未知物品的评分方面更加准确。与其他结合社交网络信息的模型(如 SoRec 模型、SocialMF 模型和 GraphRec 模型)相比, GUITRec 模型也在误差指标上有更好的表现, 说明其在利用社交信息进行推荐方面更加有效。与 NeuMF 模型相比, 虽然两者在某些指标上较为接近, 但 GUITRec 模型的 MAE 更低, 说明 GUITRec 模型在 MAE 方面表现更好。

从实验结果显著性上来看, 本文提出的 GUITRec 模型在所有指标上均表现出色, 特别是在 F_1 分数上达到 0.762 1, 优于其他所有模型。相比传统 PMF 模型, GUITRec 模型的 F_1 分数提升了 2.34%, 相较于表现较好的 GraphRec 模型也有小幅提升。这表明, GUITRec 模型通过用户建模、物品建模和时间建模的方式, 显著优化了推荐的精确性和覆盖率, 能够更好地平衡推荐质量。

综上所述, 通过与多种基线模型的对比表明, GUITRec 模型在推荐准确性和有效性方面具有明显优势。

3.3.4　消融实验

为验证本文模型各部分的有效性, 设置了 3 组消融实验。

1) 为验证本文模型中用户和物品建模的有效性, 分别进行用户建模单独实验(GUITRec_user)、物品建模单独实验(GUITRec_item)及组合实验(GUITRec), 并对比不同实验的 MSE、MAE 和 RMSE 指标, 如图 11 所示。

从图 11 可以看出, 组合实验中, 加入用户建模和物品建模后, 推荐结果在各项误差指标上均有明显的改善。具体来说, MSE、MAE 和 RMSE 的降低意味着预测值与实际值之间的误差减小, 推荐结果更加准确。单独的用户建模和物品建模已经能够在一定程度上提升推荐效果, 而将两者结合起来进行组合实验, 效果进一步提升。这充分说明用户建模和物品建模在推荐系统中是有效的, 其能够为推荐结果提供更丰富的信息和更准确的预测, 从而提高推荐系统的性能和质量。

2) 设置 3 组对比实验来测试 CBAM 注意力机制在 GUITRec 模型中的有效性。对比实验分别为去掉 CBAM 注意力、换为 attention 注意力的 GUITRec_attention、将 CBAM 注意力换为 SENet 注意力机制的 GUITRec_SENet 及保留 CBAM 注意力机制的 GUITRec, 如图 12 所示。

通过对比可以发现, 在各项误差指标上, 保留

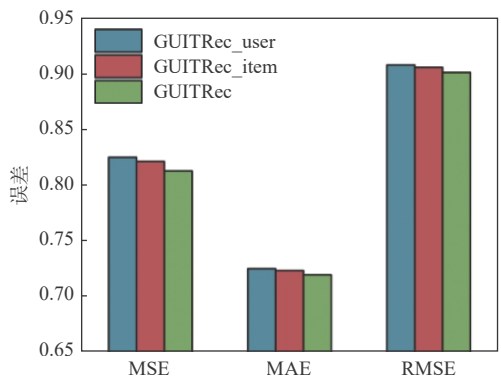


图 11　验证组合建模实验的有效性

Fig. 11　Validating effectiveness of combinatorial modeling experiments

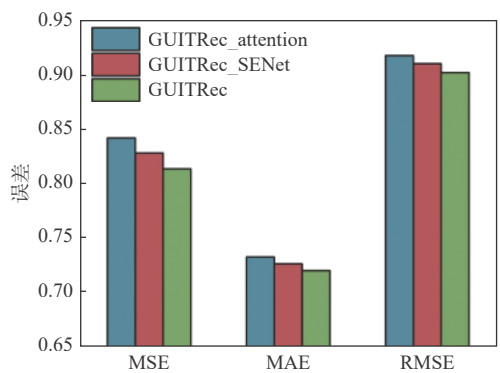


图 12　CBAM 注意力机制有效性实验数据

Fig. 12　Experimental data on effectiveness of CBAM attention mechanism

CBAM 注意力机制的 GUITRec 模型表现最佳。相比之下，换为 attention 注意力机制后，误差指标明显增大；换为 SENet 注意力机制后，虽然比 attention 注意力机制效果好，但仍不如 CBAM 注意力机制。这充分说明在 GUITRec 模型中，CBAM 注意力机制能够有效提升推荐结果的准确性。其能够更好地关注重要的特征信息，从而降低预测值与实际值之间的误差，提高推荐系统的性能。

3）为验证时间建模在推荐模型中的重要性，通过对比去掉时间建模的 GUITRec_notime 模型和包含时间建模的原 GUITRec 模型的实验结果，观察时间建模是否有效，如图 13 所示。

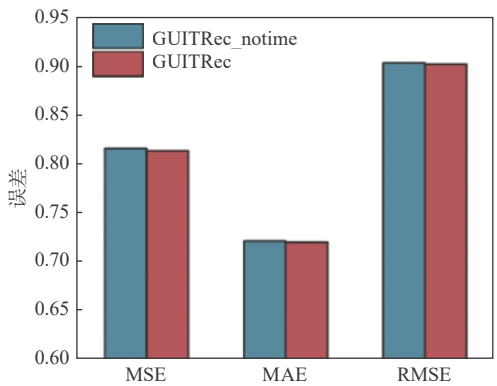


图 13 时间建模有效性实验数据

Fig. 13 Experimental data of time modeling effectiveness

从图 13 可以发现，GUITRec_notime 模型的各项指标均高于 GUITRec 模型的各项指标。在各项误差指标上，包含时间建模的原模型都表现更优。

具体来说，MSE、MAE 和 RMSE 的值越小，表示预测值与实际值之间的误差越小，推荐结果越准确。通过对比可以看出，加入时间建模后，模型的误差进一步降低，表明时间建模能够为推荐模型提供有价值的信息，帮助模型更好地理解用户行为和物品特征随时间的变化，从而提高推荐的准确性和有效性。

综上所述，实验结果充分证明了时间建模在推荐模型中的重要性，加入时间建模能够显著提升推荐结果。

4 结 论

本文针对当前多数图神经网络推荐算法在处理用户与物品交互数据时未充分考虑时间信息的问题，提出一种创新的融合双通道注意力和时间编码的图神经网络推荐算法 GUITRec，旨在通过更全面地捕捉和利用数据集中的各类信息，提升推荐系统的准确性和有效性。

1）GUITRec 将用户自身特征、物品信息及用户与物品之间的交互行为构建为图结构，并利用图神经网络进行数据聚合，以形成用户和物品的表征行为。这不仅充分利用了数据集中的信息，还有助于更深入理解用户和物品的特征及其相互关系。

2）为进一步提升模型的性能，引入了双通道注意力机制 CBAM。通过为用户和物品的表征行为赋予不同的权重，CBAM 使模型能够在进行深度学习时更加关注重要的特征信息，从而提高了推荐的准确性。

3）针对时间信息在推荐系统中的重要性，引入时间编码器模型。该模型不仅对用户与物品的交互时间进行编码，还考虑了用户位置信息，并新增了日、周、年编码和位置编码。这些额外的编码信息为推荐系统提供了更丰富的上下文，有助于模型更好地理解用户的行为模式和偏好。

4）为验证 GUITRec 算法的有效性，在 Ciao 数据集上进行了实验。实验结果表明，在 MAE、MSE 和 RMSE 这 3 个评价指标上，GUITRec 算法均优于基线模型。这一结果充分证明了 GUITRec 算法在推荐系统领域的优越性和实用性。

5）除上述实验结果外，还进行了充分的消融实验，以进一步验证模型中各个组件的有效性。实验结果表明，无论是双通道注意力机制还是时间编码器模型，都对提升模型性能起到了重要作用。这一发现不仅进一步证实了本文的设计思路，也为后续的研究提供了有益的参考。

综上所述，本文融合双通道注意力和时间编码的图神经网络推荐算法 GUITRec 有效提升了推荐效果。

参考文献（References）

[1] Goldberg D, Nichols D, Oki B M, et al. Using collaborative filtering to weave an information tapestry[J]. Communications of the ACM, 1992, 35(12): 61-70.

[2] 张磊, 陈俊亮, 孟祥武, 等. 基于 BP 神经网络的协作过滤推荐算法[J]. 北京邮电大学学报, 2009, 32(6): 42-46.
Zhang L, Chen J L, Meng X W, et al. BP neural networks-based collaborative filtering recommendation algorithm[J]. Journal of Beijing University of Posts and Telecommunications, 2009, 32(6): 42-46(in Chinese).

[3] 舒新峰, 曹望美, 王曙燕. 多特征融合的 MOOC 推荐模型[J]. 计算机工程与应用, 2023, 59(10): 123-133.
Shu X F, Cao W M, Wang S Y. Multi-feature fusion based model for MOOC recommendation[J]. Computer Engineering and Applications, 2023, 59(10): 123-133(in Chinese).

[4] Rendle S. Factorization machines[C]//Proceedings of the 2010 IEEE International Conference on Data Mining. Piscataway: IEEE Press, 2010: 995-1000.

[5] Koren Y, Bell R, Volinsky C. Matrix factorization techniques for

recommender systems[J]. Computer, 2009, 42(8): 30-37.

[6] 唐宇, 吴贞东. 基于残差网络的轻量级图卷积推荐方法[J]. 计算机工程与应用, 2024, 60(3): 205-212.
Tang Y, Wu Z D. Light graph convolution recommendation method based on residual network[J]. Computer Engineering and Applications, 2024, 60(3): 205-212(in Chinese).

[7] 吴静, 谢辉, 姜火文. 图神经网络推荐系统综述[J]. 计算机科学与探索, 2022, 16(10): 2249-2263.
Wu J, Xie H, Jiang H W. Survey of graph neural network in recommendation system[J]. Journal of Frontiers of Computer Science and Technology, 2022, 16(10): 2249-2263(in Chinese).

[8] 闫阳, 王雷全, 李家瑞. 融合语义信息与注意力的图神经网络推荐算法[J]. 计算机系统应用, 2023, 32(4): 214-222.
Yan Y, Wang L Q, Li J R. Graph neural network recommendation algorithm fused with semantic information and attention[J]. Computer Systems and Applications, 2023, 32(4): 214-222(in Chinese).

[9] 潘润超, 虞启山, 熊泓霏, 等. 基于深度图神经网络的协同推荐算法[J]. 计算机应用, 2023, 43(9): 2741-2746.
Pan R C, Yu Q S, Xiong H F, et al. Collaborative recommendation algorithm based on deep graph neural network[J]. Journal of Computer Applications, 2023, 43(9): 2741-2746(in Chinese).

[10] 冯兴杰, 生晓宇. 基于图神经网络与深度学习的商品推荐算法[J]. 计算机应用研究, 2021, 38(12): 3617-3622.
Feng X J, Sheng X Y. Item recommendation algorithm based on GNN and deep learning[J]. Application Research of Computers, 2021, 38(12): 3617-3622(in Chinese).

[11] Zhong T, Zhang S M, Zhou F, et al. Hybrid graph convolutional networks with multi-head attention for location recommendation[J]. World Wide Web, 2020, 23(6): 3125-3151.

[12] Scarselli F, Gori M, Tsoi A C, et al. The graph neural network model[J]. IEEE Transactions on Neural Networks, 2009, 20(1): 61-80.

[13] Li Y J, Tarlow D, Brockschmidt M, et al. Gated graph sequence neural networks[C]//Proceedings of the 4th International Conference on Learning Representations. San Juan: ICLR, 2016.

[14] Zhao L, Song Y J, Zhang C, et al. T-GCN: a temporal graph convolutional network for traffic prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(9): 3848-3858.

[15] Ma H, Yang H X, Lyu M R, et al. SoRec: social recommendation using probabilistic matrix factorization[C]//Proceedings of the 17th ACM Conference on Information and Knowledge Management. New York: ACM, 2008: 931-940.

[16] 邬硕, 汪海涛, 姜瑛, 等. 融合图神经网络与长短期偏好的序列推荐算法[J]. 信息技术, 2024(2): 66-72.
Wu S, Wang H T, Jiang Y, et al. Sequence recommendation algorithm based on Graph Neural Network and long short term preference[J]. Information Technology, 2024(2): 66-72(in Chinese).

[17] 于健, 赵满坤, 高洁, 等. 基于高阶和时序特征的图神经网络社会化推荐算法研究[J]. 计算机科学, 2023, 50(3): 49-64.
Yu J, Zhao M K, Gao J, et al. Study on graph neural networks social recommendation based on high-order and temporal features[J]. Computer Science, 2023, 50(3): 49-64(in Chinese).

[18] 曾碧卿, 丁明浩, 宋逸云. 基于图卷积网络的知识感知对话生成[J]. 计算机系统应用, 2023, 32(7): 47-56.
Zeng B Q, Ding M H, Song Y Y. Knowledge-aware conversation generation based on graph convolutional network[J]. Computer Systems and Applications, 2023, 32(7): 47-56(in Chinese).

[19] 袁满, 褚润夫, 袁靖舒, 等. 融合上下文信息的图神经网络推荐模型研究[J]. 吉林大学学报 (信息科学版), 2023, 41(4): 693-700.
Yuan M, Chu R F, Yuan J S, et al. Research on graph neural network recommendation model of integrating context information[J]. Journal of Jilin University (Information Science Edition), 2023, 41(4): 693-700(in Chinese).

[20] Azri A, Haddi A, Allali H. AutoTimeSVD++: a temporal hybrid recommender system based on Contractive autoencoder and Matrix factorization[C]//Proceedings of the Smart Applications and Data Analysis. Berlin: Springer International Publishing, 2022: 93-103.

[21] He B W, He X, Zhang Y X, et al. Dynamically expandable graph convolution for streaming recommendation[C]//Proceedings of the ACM Web Conference 2023. New York: ACM, 2023: 1457-1467.

[22] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[C]//Proceedings of the Computer Vision-ECCV 2018. Berlin: Springer International Publishing, 2018: 3-19.

[23] Yoo J, Choi S. Probabilistic matrix tri-factorization[C]//Proceedings of the 2009 IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway: IEEE Press, 2009: 1553-1556.

[24] Lee M, Choi P, Woo Y. A hybrid recommender system combining collaborative filtering with neural network[C]//Proceedings of the Adaptive Hypermedia and Adaptive Web-Based Systems. Berlin: Springer, 2002: 531-534.

[25] Bai T, Zhang Y J, Wu B, et al. Temporal graph neural networks for social recommendation[C]//Proceedings of the 2020 IEEE International Conference on Big Data (Big Data). Piscataway: IEEE Press, 2020: 898-903.

Graph neural network recommendation algorithm fused with dual-channel attention and time encoding

BAI He，LI Yu*，HAO Ming，XU Tingting

(College of Information Engineering，Liaoning Institute of Science and Engineering，Jinzhou 121000，China)

Abstract：In response to the problem that most graph neural network recommendation algorithms do not incorporate temporal information, leading to wasted information and inaccurate recommendations, this paper proposes a graph neural network recommendation algorithm, GUITRec, that fuses dual-channel attention with time encoding. Utilizing all of the data in the dataset, this model creates a graph structure based on the user's attributes, the item's details, and the user-item interaction behavior. Data aggregation is carried out using graph neural networks to create user and item representation behaviors, more thoroughly capturing the traits and connections of both. Secondly, the dual-channel attention mechanism convolutional block attention module (CBAM) is introduced to assign different weights to the user and item representation behaviors, enabling the model to learn according to those weights and pay more attention to important features. Finally, a time encoder model is introduced to encode the interaction time between the user and the item and the user's location, and new daily, weekly, and monthly cycle encodings and location encodings are added to fully mine time and location information and provide a richer context for recommendations. Experiments on the Ciao dataset show that GUITRec is superior to the baseline model in terms of the three evaluation indicators of mean absolute error (MAE), mean squared error (MSE), and root mean square error (RMSE).

Keywords：dual-channel attention mechanism；graph neural network；time encoding；location encoding；recommendation algorithm

Received：2024-11-06；**Accepted**：2025-01-03；**Published Online**：2025-01-08 15：39

URL：link.cnki.net/urlid/11.2625.V.20250108.1414.001

Foundation item：Basic Scientific Research Project of Liaoning Provincial Department of Education in 2023

* **Corresponding author**. E-mail：1531281593@qq.com

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0810

面向集群的工业CFD软件交互设计与实现

张凡[1,2]，丁明松[1,2]，陈坚强[1,2]，刘婉[1,2,*]，江涛[1,2]，李鹏[1,2]，蒋军[1,2]

(1. 中国空气动力研究与发展中心 计算空气动力研究所，绵阳 621000；
2. 空天飞行空气动力科学与技术全国重点实验室，绵阳 621000)

摘　　要：在航空航天领域，工业计算流体力学(CFD)软件依赖于高性能计算集群生产气动数据，是辅助飞行器设计的重要工具。针对国产CFD软件集群部署、仿真场景交互、软硬件环境兼容等问题，结合国家数值风洞（NNW）软件研发和推广应用需求，设计并实现了一种面向集群交互的CFD软件框架。该框架采用客户端/服务器架构，集成交互界面、集群通信、登录认证、仿真任务管理与作业监控等功能，支持命令调用求解器并传递参数文件的求解模式，具有良好的通用性和扩展性。测试表明：该框架可兼容主流集群架构与作业调度系统，相较传统耦合架构，在百次并发下内存占用率降低36%，CPU占用率降低69%，平均响应时间稳定在100 ms以内，具有资源占用低、响应速度快等优势。目前，所设计框架已应用于NNW软件体系，为用户提供流畅的集群仿真交互服务，提升了CFD仿真用户体验。

关 键 词：高性能计算集群；计算流体力学；工业软件；作业调度；航空航天；国家数值风洞工程

中图分类号：TP311.52; TB126
文献标志码：A　　**文章编号**：1001-5965(2026)11-3879-15

计算流体力学(computational fluid dynamics, CFD)数值仿真软件通过计算机求解流动控制方程生产气动数据，是辅助飞行器设计的重要工具[1]。随着数值求解方法和高性能计算技术的发展，CFD软件在航空航天和高端制造等领域得到了快速发展及应用[2-4]。为实现CFD软件自主可控和国产替代，2018年，在国家数值风洞(National Numerical Windtunnel, NNW)工程的资助下，中国空气动力研究与发展中心牵头建设了空气动力数值模拟平台，目前已向全国发布套装软件[5-6]。NNW-HyFLOW[7]软件是基于风雷框架[8-9]研发的高速流动数值模拟软件，属于NNW套装软件的重要组成部分，已在国内多家工业部门部署应用。

CFD软件属于计算密集型软件，在工程应用中依赖于高性能计算集群(简称集群)。长期以来，国内CFD软件研发团队侧重于CFD理论方法研究，在集群交互、兼容部署等方面发展相对迟缓，在国产工业软件替代的过程中给用户带来诸多不便。早期的NNW-HyFLOW集群版软件采用交互界面与求解程序耦合一体的设计方案，面对工业部门集群硬件环境缺乏GPU支持或集群软件环境不兼容等问题，无法直接部署使用，用户在集群只能单独使用求解器，依靠手动操作完成参数文件上传、提交计算、结果文件下载等仿真流程，操作繁琐、效率低下。

关于CFD软件研究，美欧等西方国家发展较早，推出了ANSYS Fluent/CFX、Star-CCM+、CFD++、Numeca等成熟商业软件[10]，在国内市场受众广、用

收稿日期：2024-11-12；**录用日期**：2025-03-28；**网络出版时间**：2025-04-30 12:35
网络出版地址：link.cnki.net/urlid/11.2625.V.20250430.1114.001
基金项目：国家数值风洞工程
*通信作者. E-mail：13340898729@163.com

引用格式：张凡，丁明松，陈坚强，等. 面向集群的工业CFD软件交互设计与实现[J]. 北京航空航天大学学报，2026，52(11)：3879-3893.
Zhang F，Ding M S，Chen J Q，et al. Interactive design and implementation of cluster-oriented industrial CFD software[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3879-3893 (in Chinese).

户黏性高。近年来,在政策和需求的驱动下,国内涌现出如索辰流体仿真软件、QFLUX 软件、UNSMB 软件、HUNS3D 软件等一批国产 CFD 软件[11-12]。在面向集群交互仿真方面,国内外已有相关研究和实践。例如,航空工业西安航空计算技术研究所针对 CFD 软件云化技术进行了探索和设计,以简化仿真流程,降低仿真难度[13];北京空间飞行器总体设计部设计了面向航天器设计的高性能计算平台,提升用户体验,降低了使用门槛[14];中国船舶及海洋工程设计研究院通过整合计算资源设计了混合云架构的仿真平台,实现远程仿真可视化,提高了仿真效率[15]。子虔科技采用 Web 轻量化前端与云端后端分离架构开发了 Zixel CFD 数据分析模块,支持多用户实时共享仿真结果;华北计算机系统工程研究所构建了云端服务器,实现云计算环境的 CFD 数据可视化[16];达索系统将交互界面与后端分离构建了 SIMULIA 平台,使用户无需本地算力支持即可完成大规模仿真;ANSYS Fluent 软件在 2018 版本优化了客户端/服务器模式,以更好地支持分离式部署解决硬件环境兼容问题。总的来说,交互模式的革新是 CFD 软件普惠化与高效化的核心,传统的以命令行和复杂参数输入为主的交互方式正逐步被云端交互所取代。

本文针对 NNW-HyFLOW 软件在推广部署中面临的兼容性与交互性问题,基于跨平台开发语言,采用客户端/服务器设计模式,通过解耦集群作业管理系统的交互指令,构建了一套高效的 CFD 软件集群交互框架。实验结果表明,该框架具有资源占用低、响应速度快、兼容性强等优势,并在 CFD 集群求解任务中展现出良好的通用性,为大规模数值模拟提供了可靠的技术支持。

1 系统设计

1.1 架构设计

面向集群的工业 CFD 交互软件架构设计采用客户端/服务器模式,如图 1 所示。

客户端使用 QT 语言开发,主要负责仿真参数设置和结果渲染,通过将求解程序与交互界面解耦合的客户端/服务器设计,能够有效避免由于集群架构、显卡、编译器版本等软硬件差异而导致的交互界面无法运行问题。

服务端使用能够跨平台的 Java 语言开发,能够兼容国内航空航天单位的集群软硬件环境,对于 Slurm、负载共享设施 (load sharing facility, LSF)、便携式批处理系统 (portable batch system, PBS)、Sun 网格引擎 (Sun grid engine, SGE) 等不同类型的作业

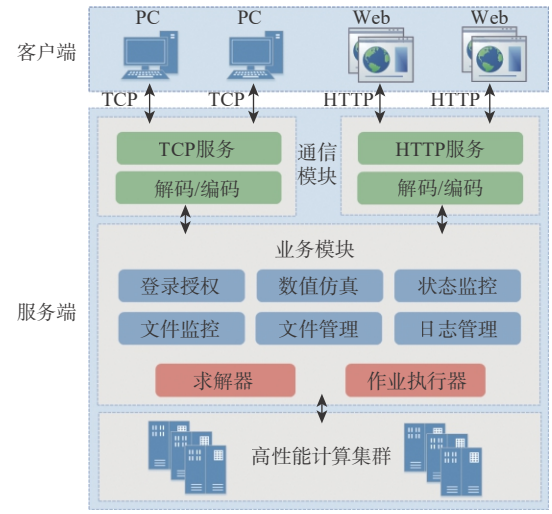


图 1 面向集群的工业 CFD 软件架构

Fig. 1 Industrial CFD software architecture for clusters

管理系统,服务端通过将与作业管理系统交互的指令解耦到 Shell 脚本中进行兼容。基于客户端对服务端的功能需求,服务端设计包括通信、登录认证、数值仿真、状态监控、文件监控、文件管理和日志管理等模块。

1.2 部署方案设计

从集群部署角度来看,目前工业部门集群可分为 2 类:①具有集群门户网站,用户登录后由门户网站的 Web 服务提交作业;②用户能够直接通过终端命令使用集群。本文针对上述集群环境,面向集群的工业 CFD 软件设计了不同的部署方案。

部署方案 1:针对集群门户网站,CFD 软件服务端提供了作业提交的交互接口,服务端会在完成作业计算准备后生成压缩包文件,调用门户网站提交作业脚本至集群,门户网站的执行脚本仅需返回作业在集群的绝对路径和作业在集群作业管理系统中的编码即可;将客户端交互界面部署在门户网站的 Web 服务器内,用户通过登录门户网站使用客户端交互界面。

部署方案 2:针对用户能够直接通过终端使用集群,集群登录节点具备可视化硬件条件支撑时,客户端交互界面与 CFD 软件服务均部署在登录节点,用户通过终端打开 CFD 软件客户端交互界面使用;集群登录节点不具备可视化硬件条件支撑时,将客户端部署在用户本地 PC 端,在集群登录节点部署服务,用户之间通过本地 PC 端远程连接集群服务端进行使用。

2 模块设计

2.1 通信模块

Reactor 模式是 Doug Schmidt 提出的一种基于

事件驱动的设计模式, 其能够处理并发服务请求, 并通过多路复用机制将请求分发给相应的处理器进行处理。经过逐步演化, 目前, 并发网络编程中最为流行的是 Reactor 主从多线程模式[17], 如图 2 所示。在此基础上, Trustin Lee 构建了一个异步的、事件驱动的网络应用程序框架 Netty, 用于快速开发可维护的高性能协议服务器。服务器通信模块在 Netty 框架基础上, 结合 CFD 软件在集群作业过程中残差、气动力/热等大量高频气动数据实时传输的特点, 开展了线程模型设计和通信协议设计。

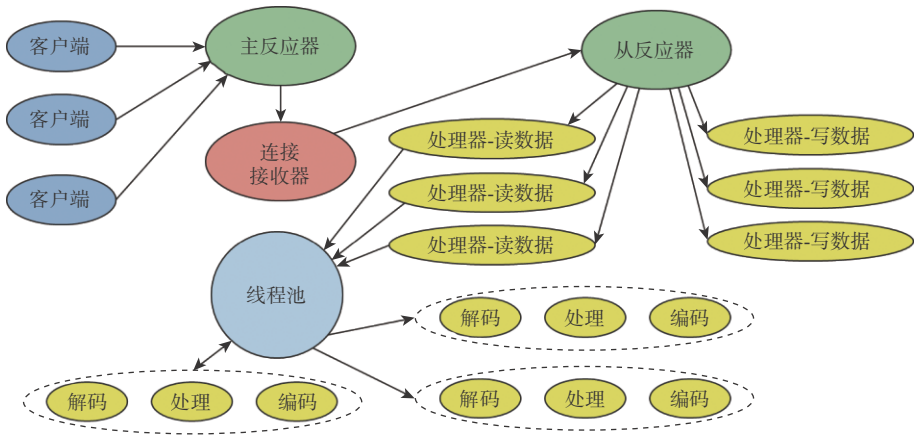


图 2　Reactor 主从多线程模式结构

Fig. 2　Structure of Reactor master-slave multi-threading mode

2.1.1　线程模型设计

Netty 框架基于 Reactor 主从多线程模型, 抽象出 2 组线程池, 将监听端口服务和处理数据功能剥离, 监听线程组负责接收客户端的连接请求, 事件处理线程组负责仿真请求事件的读写, 具体流程如图 3 所示, 监听线程组中的事件循环器轮询客户端的请求连接事件, 发现请求事件后, 与对应客户端建立连接, 将其注册到事件处理线程组中的事件循环组选择器上, 由事件处理线程组中的读写事件循环器轮询读写事件, 发现读写事件后, 交由流水线中的业务处理器中进行后续处理, 期间不会发生线程切换。Netty 通过非阻塞式处理客户端的连接和读写事件, 避免了反复建立与销毁线程耗费资源的操作, 能够有效提高软件服务端性能。

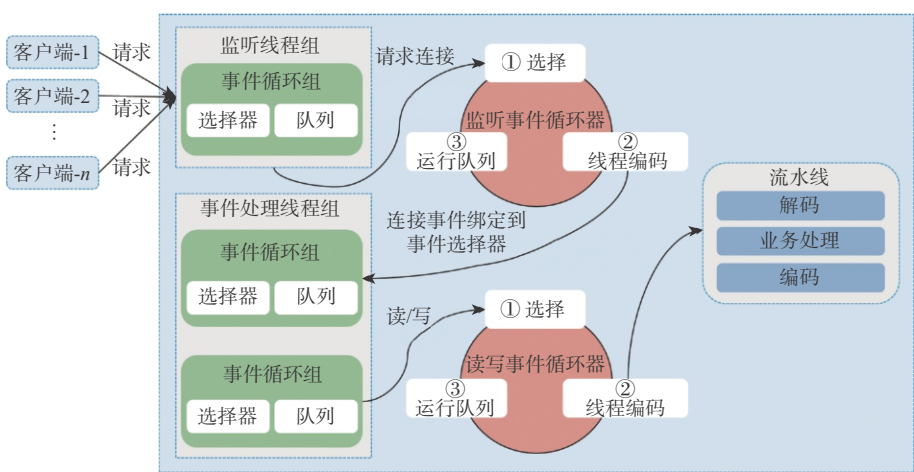


图 3　基于 Netty 的通信模块线程模型

Fig. 3　Thread model of communication module based on Netty

代码清单 1 是 NNW-HyFLOW 软件应用 Netty4.1 版本构建服务端通信模块的核心代码。其中, boss 和 worker 这 2 个事件循环线程组对象负责处理连接和读写事件, 线程数根据集群情况和软件应用情况设置。ServerBootstrap 对象是构建 Netty 框架服务的核心引导类, 参数包括设置传输控制协议(transmission control protocol, TCP)通道类型、绑定事件循环线程组、定义客户端连接的处理器链等。在此基础上, 用户需要构建自定义的入站和出站事件读写处理器来处理业务逻辑, 如编解码、消息转换、登录、求解、数据监控、状态监控、作业管理、文件管理等处理器, 并通过 addLast 方法添加到双

向链表结构的 pipeline 中。服务端接收到请求后，出入站的适配器会根据添加处理器的顺序按照入站顺序执行和出站逆序执行的顺序调用处理器，自定义的处理器可通过继承 SimpleChannelInboundHandler 和 ChannelOutboundHandlerAdapter 这 2 个基础的处理器适配器来处理指定消息类型的读写事件。

代码清单 1

```
public void start(){
    NioEventLoopGroup boss = new NioEventLoopGroup(1); //处理连接的线程组
    NioEventLoopGroup worker = new NioEventLoopGroup(thread_max); //处理读写事件的线程组
    try {
      ServerBootstrap serverBootstrap = new ServerBootstrap();
      serverBootstrap.channel(NioServerSocketChannel.class); //异步非阻塞 TCP 通道
      serverBootstrap.group(boss, worker);
      serverBootstrap.childHandler(new ChannelInitializer<NioSocketChannel>(){
        @Override
        protected void initChannel(NioSocketChannel ch) throws Exception {
          ch.pipeline().addLast(new ProcotolFrameDecoder()); //解码器
          //省略非关键代码
          ch.pipeline().addLast(new MessageInboundHandler()); //消息入站处理器
          ch.pipeline().addLast(new JobManageHandler()); //作业管理处理器
          ch.pipeline().addLast(new JobFileMonitoringHandler()); //气动数据监控器
          ch.pipeline().addLast(new JobStateMonitoringHandler()); //作业状态监控器
          ch.pipeline().addLast(new FileManageHandler()); //文件处理器
          //省略非关键代码
          ch.pipeline().addLast(new MessageOutboundHandler()); //消息出站处理器
          ch.pipeline().addLast(new ProcotolFrameEncoder()); //编码器
        }
      });
      Channel channel = serverBootstrap.bind(port).sync().channel(); //启动服务
      //省略非关键代码
      channel.closeFuture().sync();
    } catch (InterruptedException e) {
      //省略非关键代码
    }
}
```

2.1.2 通信协议设计

TCP 消息传输是基于流的方式，本身没有边界，设计通信协议的目的是划定消息边界，制定通信双方要共同遵守的通信规则，解决双方通信过程中由于套接字缓冲区的大小限制而出现的拆包/黏包的情况。在工程应用中，结合仿真消息传输需求，同时考虑工程实现的难易程度、编解码性能等因素。本文设计了如图 4 所示的协议以供参考，该协议消息头包含数据长度和指令类型，消息体的数据采用 JavaScript 对象表示法（JavaScript object notation, JSON）格式。在数据传输前，先将需要传输的 JSON 格式数据序列化为十六进制数据，计算出数

据长度, 将数据长度信息写入消息头部固定长度的字段中, 再将消息的类型, 如作业查询、计算、数据监控、状态监控等类型通过数字标识存放到指令类型字段中, 方便双方处理, Netty 框架提供了二进制、十六进制、JSON、可扩展标记语言(extensible markup language, XML)等丰富的编码器, 本节继承于 Netty 的 LengthFieldBasedFrameDecoder 类进行实现。

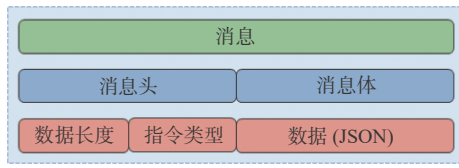


图 4　通信协议示意图

Fig. 4　Schematic of communication protocol

2.2　登录认证

不同用户在集群上的访问权限和文件空间不同, 当服务端以管理员权限部署在集群上时, 需要鉴别用户权限, 并根据鉴别结果找到对应的文件空间进行仿真作业的业务操作, 设置登录认证模块一方面是为根据用户权限在集群进行仿真业务操作, 另一方面是为方便用户对集群求解器授权, 该模块包括登录和求解器授权 2 部分。

2.2.1　登　录

登录流程如图 5 所示, 服务端登录处理器会拦截未登录用户的登录请求, 解码用户登录信息, 与集群中配置的用户信息进行匹配, 并校验密码, 以此判断是否登录成功。

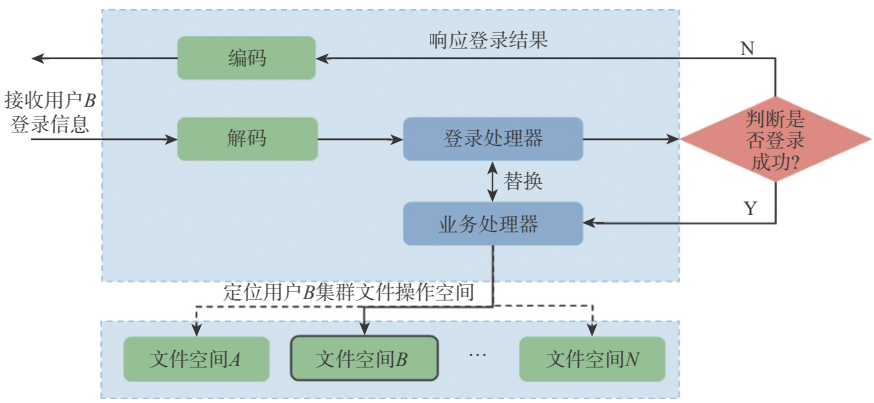


图 5　登录流程示意图

Fig. 5　Schematic of login process

用户登录成功后, 服务端会将用户登录信息、集群文件空间地址信息存储在客户端与用户的连接信息中, 并移除登录处理器, 添加业务处理器, 达到用户在集群管理员配置的文件空间内操作仿真作业的目的。

2.2.2　求解器授权

为保护软件版权, 防止软件非法传播和破解, 求解器设置了许可证管控。目前, 主流的基于硬件信息特征码的许可证管控方式大多是针对单机授权, 面对节点众多的集群, 往往难以获取每个节点的硬件信息特征码, 针对集群多节点授权场景, 本文设计了 CFD 软件授权管理服务。如图 6 所示, 授权管理服务部署在集群登录节点, 在运行时会读取登录节点介质访问控制 (media access control, MAC) 地址、中央处理器标识符(identifier, ID)和硬盘序列号, 并结合需要管控的 CFD 软件信息生成硬件信息特征码, 根据硬件信息特征码, 设置并行计算核数、网格规模等管控信息, 通过加密算法生成授权证书, 并导入集群登录节点, CFD 软件在集群并行计算时, 计算节点通过集群高速互联网络请求授权管理服务获取软件运行权限及允许的并行计算核数和网格规模, 实现软件版权保护及允许限制的管控需求。

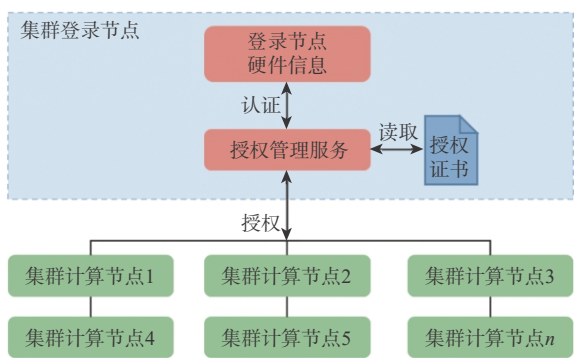


图 6　CFD 软件集群授权认证流程

Fig. 6　Cluster authorization and authentication process for CFD software

2.3　仿真模块

仿真模块作为面向集群的工业 CFD 软件系统的核心之一, 其主要作用是为客户端提供接口支撑, 保障用户能够通过客户端交互界面操作集群, 完成仿真作业的上传/下载、提交、查询、取消等仿

真相关操作。

仿真模块的设计难点在于兼容不同作业管理系统的指令集及其返回值。目前，主流的集群作业管理系统的关键操作指令如表1所示。为实现上述指令集的兼容，仿真模块将集群作业调度相关的指令代码解耦合，将指令代码及工业部门提交作业的特殊参数写入Shell脚本，通过执行Shell脚本的方式进行兼容。对于指令的返回值，服务端基于适配器原理设计了统一的作业状态，作业提交之后的初始状态设置为PD，作业开始计算后状态为R，其他状态均设置为S，当执行集群作业管理系统指令后，其运行状态返回值不同时，由Shell脚本代码进行转换。

表1 集群作业管理系统常用指令

Table 1 Common instructions of cluster job management system

集群作业管理系统	提交指令	查询指令	取消指令
Slurm	sbatch\srun	squeue	scancel
LSF	bsub	bjobs\bqueue	bstop\bkill
PBS/SGE	qsub	qstat	qdel

服务端仿真流程如图7所示，其主要流程是用户通过服务端程序在集群文件空间创建仿真作业，通过服务端程序执行Shell脚本调用作业管理系统将仿真作业分发到计算节点完成并行计算，具体包括创建作业和管理作业。

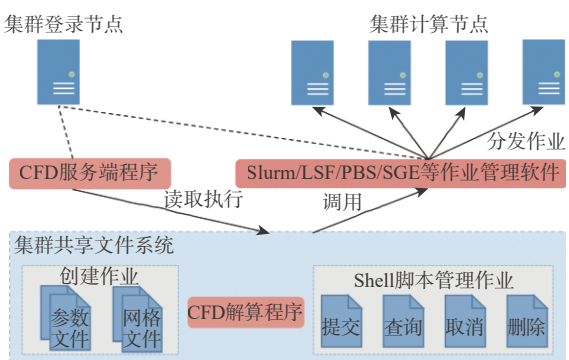


图7 CFD软件集群作业示意图

Fig. 7 Schematic of CFD software cluster job

2.3.1 创建作业

在面向集群的工业CFD软件服务系统中，创建作业由用户在交互界面导入网格模型，设置计算核数、计算模型、边界条件、离散格式、输出格式等参数后，生成参数文件，通过服务端提供的文件上传接口将参数文件、网格文件上传至服务端用户文件空间。考虑到工程实用性，服务端提供了创建批量作业的接口，客户端仅需在单个作业创建完成后，调用批量作业接口发送批量的工况参数，如高度、迎角、马赫数、侧滑角等，服务端接收到创建批量作业参数后会创建批量作业，并根据批量的工况参数修改参数文件的参数，完成批量作业创建。

2.3.2 作业管理

作业管理主要是为客户端提供面向集群作业管理系统的支持，具体包括以下功能：

1）提交作业。用户完成输入参数文件上传后，客户端调用服务端提交作业接口发送消息请求，接口部分参数如表2所示，服务端接收消息后，入站消息处理器MessageInboundHandler会根据消息类型messageType通过反射将JSON数据转换为Java实体对象，在pipeline中由JobManageHandler处理器根据作业类型进行处理，执行对应的提交作业脚本，由Shell脚本调用作业管理软件完成作业分发及计算，并在作业路径下记录该作业在集群的作业编码及求解器的写屏输出，以供服务端后续的作业查询和写屏数据监控，通常在单作业计算时，提交作业完成后，客户端会发起作业状态监控和气动数据监控请求，代码清单2是提交作业的Shell脚本伪代码。此处将获取作业projectId的代码解耦到脚本中，可以通过在部署过程中灵活改写配置脚本，避免不同集群返回不同格式的数据，造成服务端无法解析的情况，实现不同类型集群管理系统的兼容。

表2 客户端与服务器提交作业交互接口的部分参数

Table 2 Some parameters of interface between client and server when submitting jobs

相关参数	功能
messageType	消息类型
jobType	作业类型
batchPara	批量作业参数
solverName	求解器名称
solverType	求解器类型
ncpus	并行计算核数
jobPath	作业在集群的绝对路径
state	作业在集群的运行状态
projectId	作业在集群的运行编码

代码清单2

submit.sh

```
#!/bin/bash
projectId=yhbatch HyFLOW_Submit.sh ncpus solverName jobPath //向集群管理系统提交作业
//省略非关键代码
echo projectId > jobPath/id.hy //记录作业编码
HyFLOW_Submit.sh
```

```
#!/bin/bash
//省略非关键代码
wait=$(rm jobPath/HyFLOW.out)
mpirun -n ncpus installPath/solverName jobPath >> HyFLOW.out 2>&1 //求解并重定向写屏数据
```

2) 查询作业。用户完成作业提交后, 客户端调用服务端查询作业接口, 传入作业在集群作业管理系统中的 ID, 服务端会执行查询作业的 Shell 脚本获取作业在集群作业管理系统中的状态。

3) 取消作业。作业在集群运行过程中, 客户端调用服务端取消作业接口, 传入作业在集群作业管理系统中的 ID, 服务端执行取消作业的 Shell 脚本停止集群作业。

4) 删除作业。作业计算完成后, 用户将作业结果数据下载至本地客户端后, 调用删除作业接口, 服务端会根据客户端发送的作业路径删除相关文件。

2.4　作业监控

客户端交互界面为用户提供仿真场景交互离不开作业状态和气动数据的监控和实时推送, 服务端提供了作业状态监控和气动数据监控 2 个接口, 其难点在于轮询作业管理系统和气动数据带来的性能开销。针对性能开销问题, 服务端监控程序设计采用单例模式, 轮询作业状态和文件属性实现状态和气动数据的实时监控。

2.4.1　作业状态监控

服务端作业状态监控主要流程如图 8 所示, 作业状态监控采用异步单线程定时执行集群上的批量查询脚本, 其优点是单个线程能够满足所有客户端的状态监控需求, 效率高且内存资源开销小, 在集群兼容方面, 通过解耦批量查询脚本, 在实际部署过程中, 能够根据集群作业管理系统的返回值在现场快速完成修改得到作业编号和运行状态。图 9 给出了监控模块关键步骤的时序图, 监控模块接收到作业状态监控请求后, 将作业状态监控请求添加至作业监控队列中, 开启异步监听线程, 时序图中步骤 8, 监听线程会先获取监控队列中的任务对象, 该对象包括作业在集群上的 ID、上一次运行状态等属性, 随后执行步骤 9, 按轮询时间间隔运行监听线程执行批量查询脚本, 获取作业在集群上的 ID 和运行状态, 对比任务的当前状态与上一次运行状态, 当计算作业状态由 PD 变为 R 时, 通知客户端作业开始计算, 当作业状态 R 变为 S 时, 通知客户端作业计算完成并将其从监听队列移除, 状态监控模块线程会定时循环执行, 直至监控队列为空时, 停止监听线程。相比耦合交互 CFD 软件每个客户端需独立开启监听线程, 本文架构服务端共享状态监听器, 显著减少了监听线程数量, 降低了 CPU 和内存消耗, 同时缓解了作业管理系统应对大量轮询的压力。

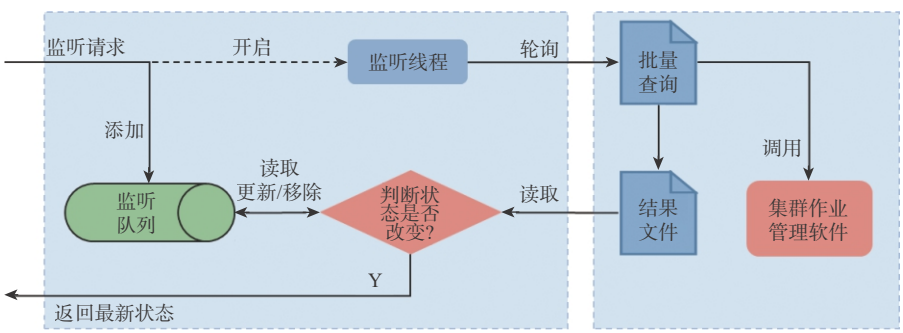


图 8　集群作业状态监控示意图

Fig. 8　Schematic of cluster job status monitoring

2.4.2　气动数据监控

气动数据监控主要包括残差、气动力、气动热及流场文件数据, 区别于作业状态监控。气动数据监控的特点是同时监控读取多个文件空间的气动数据文件, 具有数据量大且实时性要求高等特点, 属于典型的高频数据监控。针对气动数据的监控难点, 为减少集群登录节点内存开销, 如图 10 所示, 服务端将文件的监听与读写事件解耦合, 监听线程采用单线程设计, 负责接受客户端的文件监听请求, 并监听文件的创建和写入动作, 将结果返回给文件监听模块。图 11 给出了文件监控模块的时序图, 步骤 9 检测文件改变实现的核心逻辑是轮询对比文件状态快照, 在接收到文件监听请求后, 为需要监控的文件生成包括文件路径、最后修改时间、大小、是否存在等属性的状态快照, 在下一次轮询中, 递归文件监控目录树, 对比 2 次文件状态快照获取文件是否创建或更新。文件监听模块接收到文件创建和写入动作后, 会从线程池分配线程读取文件中实时更新的数据返回给客户端。由于 CFD 仿真具有计算周期长、输出数据多等特点, 用

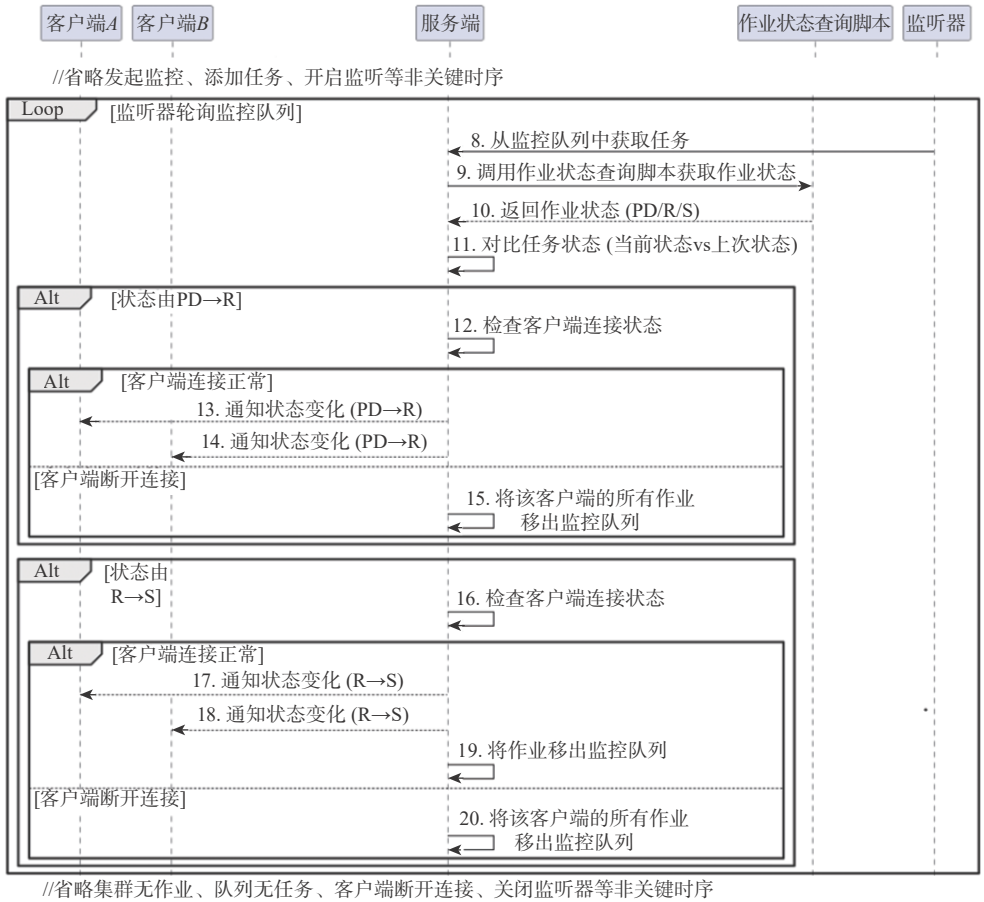


图 9 作业状态监控核心时序图

Fig. 9 Sequence diagram of job status monitoring

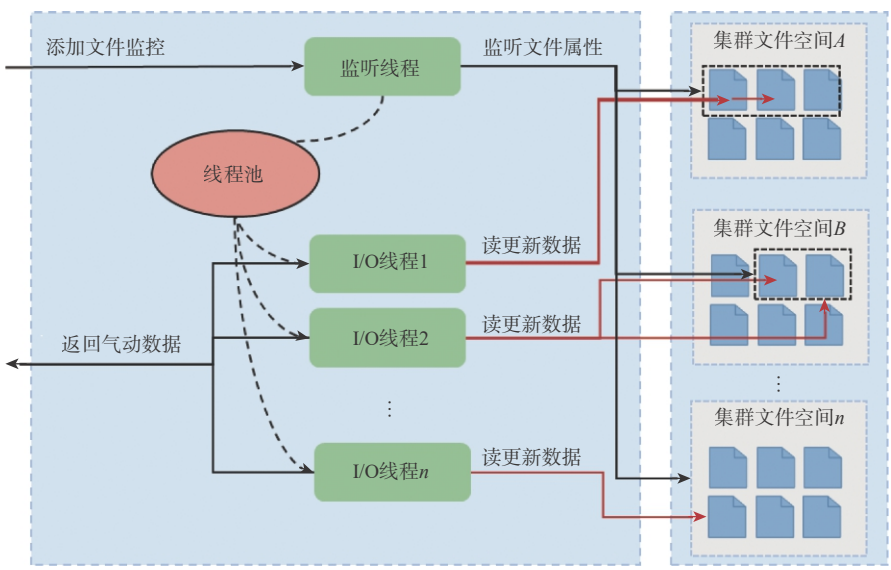


图 10 集群气动数据监控流程

Fig. 10 Process of cluster aerodynamic data monitoring

户在提交作业关闭客户端后，集群端仍在不断向结果文件写入气动数据，当用户再次连接时，为避免一次性读出大量历史数据导致客户端交互界面阻塞，服务端会先将客户端关闭期间生产的历史气动数据分段读出推送给客户端，再开始监听结果文件产生的最新气动数据并读取推送给客户端，时序图中的步骤 12 采用 Java 的 RandomAccessFile 类实现，其提供的 getFilePointer() 方法和 seek() 方法能够精确控制文件指针位置。

2.5 日志与文件管理

文件管理模块主要目的是为客户端提供灵活的文件查看、上传、下载、删除接口，方便客户端向

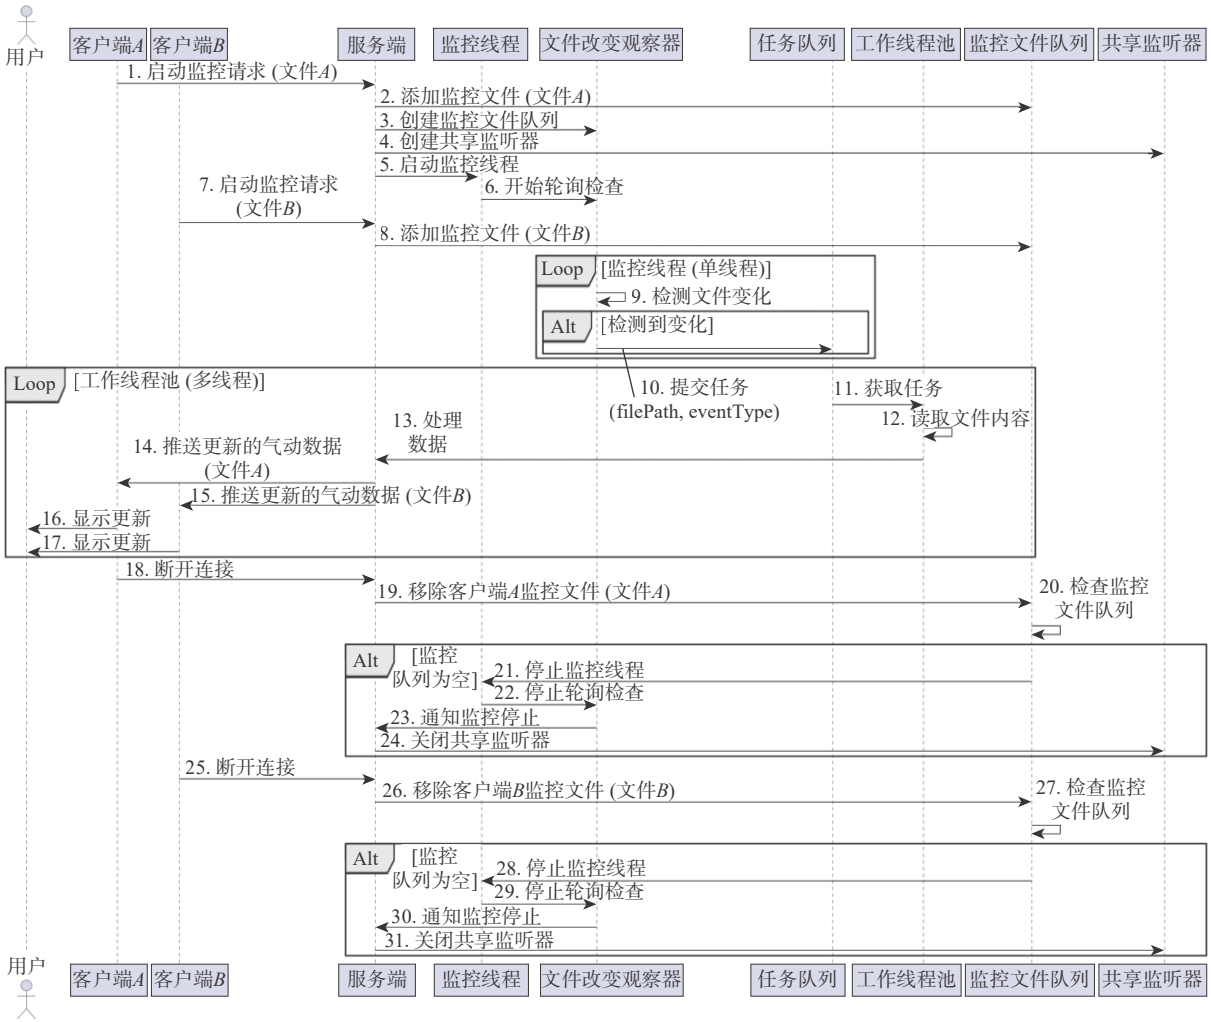


图 11　集群气动数据监控时序图

Fig. 11　Sequence diagram of cluster aerodynamic data monitoring

集群传输参数文件和查看结果文件。

日志模块主要是便于用户故障排查, 服务端日志模块包括提交作业后调度系统的输出及求解器输出, 在 linux 系统中, 每个进程都和标准输入 0-stdin (standard input)、标准输出 1-stdout(standard output)、标准错误 2-stderr(standard error)3 个系统文件相关联, 服务端在提交作业时, 通过使用 2&1 将求解器写屏输出和作业调度系统输出数据全部重定向到 HyFLOW.out 文件中, 再由客户端通过文件监控模块实时读取到控制台实现集群日志监控的数据交互。

3　测　试

3.1　软件简介

NNW-HyFLOW 是中国空气动力研究与发展中心自主研发的高速 CFD 软件, 是 NNW 系列软件的重要组成部分。专注于高速流场及热化学非平衡、稀薄滑移、湍流等多物理效应耦合模拟仿真, 具备高速飞行器流场结构、气动力特性、气动热环境、等离子体环境及其相关气动电磁、气动光学、气动辐射效应综合分析与评估能力。软件发展一系列自主模型算法和独特技术, 具有稳定、精准、高效的特点。

3.2　兼容测试

3.2.1　架构兼容测试

测试环境分别使用进阶精简指令集机器 (advanced RISC machine, ARM)架构和 X86 架构集群, 为避免不同集群软件环境的版本差异, 服务端将 Java 依赖的 Java 运行环境(Java runtime environment, JRE)和.jar 格式的依赖包, 及求解器依赖的消息传递接口(message passing interface, MPI)运行环境统一打包至安装包内, 在软件运行时通过设置加载临时环境变量来兼容集群环境的差异性。

测试集群 1: 服务器处理器类型为 FT-3000, 主频为 2.5 GHz, 操作系统版本 Ubuntu 19.04, ARM 架构, 计算节点为 12 000 余个, 单节点核心数为 64, 单节点内存为 128 GB, CFD 软件服务器在其登录节点启动如图 12 所示。

测试集群 2: 服务器类型为 Intel Xeon, X86 架



图 12 ARM 架构部署服务启动日志

Fig. 12 Server startup log based on ARM architecture



图 13 X86 架构部署服务启动日志

Fig. 13 Server startup log based on X86 architecture

构，计算节点为 30，单节点核心数为 40，单节点内存为 196 GB，CFD 软件服务器在其登录节点启动如图 13 所示。

3.2.2 调度系统兼容测试

为兼容集群作业管理系统，HyFLOW 软件服务端采用固定输入输出的方式来兼容集群实现交互。针对集群作业管理系统的差异性，在实际部署过程中，能够根据输入输出灵活配置服务端的提交作业、状态监控、作业查询、取消作业等脚本文件。表 3 给出了 HyFLOW 软件在 Slurm 作业管理系统主要脚本的输入输出配置。

表 3 HyFLOW 软件兼容 Slurm 作业管理系统的脚本配置

Table 3 Script configuration of HyFLOW software compatible with Slurm job management system

脚本类型	关键指令	输入	输出
提交作业 HyFLOW_Submit.sh	mpirun -n $n $solver $jobPath >>HyFLOW.out 2>&1	$n:[计算核数]、$solver:[求解器名称]、$jobPath:[作业路径]	日志文件
状态监控query.sh	squeue |grep $scriptName |awk -F: '{split(id status)}' >> $1/queryResults.txt	$scriptName:[提交作业脚本名称]	作业状态记录文件
状态查询queryByID.sh	squeue | grep $id	$id:[作业编号]	0:成功，1:失败
取消作业cancel.sh	scancel $id	$id:[作业编号]	0:成功，1:失败

在集群基于表 3 完成 NNW-HyFLOW 软件在 Slurm 作业调度系统的脚本配置后，首先，通过 HyFLOW_Submit.sh 提交作业至集群计算，然后，执行 query.sh 脚本模拟作业状态监控时的接口调用，得到结果如图 14 所示。结果表明，通过脚本配置的方式可以获得 CFD 服务器能够解析的标准返回值，具备与集群作业调度系统交互的能力。进一步说明，通过解耦集群作业管理系统交互指令，在部署过程中按照输入输出标准配置指令脚本，能够解决集群版 CFD 软件兼容作业管理系统的问题。

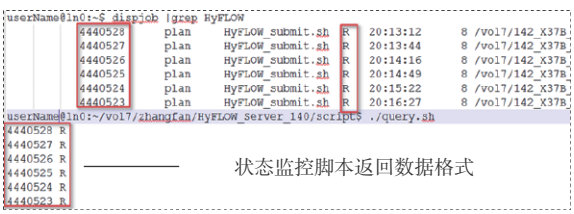


图 14 Slurm 作业管理系统指令兼容测试结果

Fig. 14 Instruction compatibility test results of Slurm job management system

3.3 功能测试

3.3.1 测试算例

测试算例选择类航天飞机 OV-102，通过使用本地客户端设置参数生成参数文件提交集群计算的方式考察服务端接口正确性及系统整体交互能力。图 15 和表 4 给出了类航天飞机网格和计算条件。

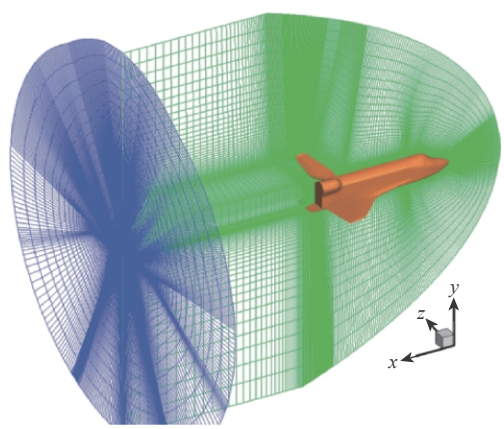


图 15 计算网格示意图

Fig. 15 Schematic of computational grid

表 4 计算条件

Table 4 Computational conditions

马赫数	迎角/(°)	密度/(kg·m^{-3})	单位长度雷诺数/m^{-1}	压力/Pa	壁温/K	侧滑角/(°)	来流温度/K
35	39.58	8.04×10^{-5}	1.1×10^{5}	32.31	1 120	0	216.28

3.3.2　气动数据监控接口测试

图 16 表明, 客户端向服务端发送气动数据监控请求后, 服务端根据客户端请求监听气动数据文件的写入, 读取最新的气动数据, 并按照如图 4 所示的通信协议格式, 在消息头部写入消息长度和消息类型, 消息体采用 JSON 格式数据, 写入气动数据及该工程的相关信息, 并返回给客户端。



图 16　气动数据监控日志

Fig. 16　Aerodynamic data monitoring log

3.3.3　状态监控接口测试

客户端向服务端发送状态监控请求后, 服务端会开启状态监听线程, 通过轮询的方式查询 HyFLOW 软件提交至集群的作业状态, 并将读取到的当前状态与上一次查询到的状态进行比较, 当集群上计算作业状态由初始状态 PD 改变为计算状态 R 或由计算状态 R 改变为停止状态 S 时, 服务端会将计算状态推送给客户端。图 17 表明, 服务端监听到作业 OV_102, 由初始状态 PD 改变为计算状态 R, 按照约定的通信协议格式推送给客户端。



图 17　作业状态监控日志

Fig. 17　Job status monitoring log

3.3.4　批量作业接口测试

在飞行器设计中, 常常需要针对不同状态进行大批量计算, HyFLOW 软件批量作业基于单作业生成, 在单作业参数文件基础上, 通过客户端发送的批量作业参数复制参数文件并修改马赫数、高度、迎角、侧滑角等参数, 完成批量作业工程的创建, 交互界面设置如图 18 所示。图 19 表明, HyFLOW 软件服务端监控到的作业 ID 与直接通过集群作业管理系统查询的结果一致。

3.3.5　扩展能力测试

NNW-HyFLOW 软件集成了流场、气动光学、气动电磁、气动辐射等 10 余种求解器。尽管不同求解类型在客户端对应不同的参数设置界面, 但从

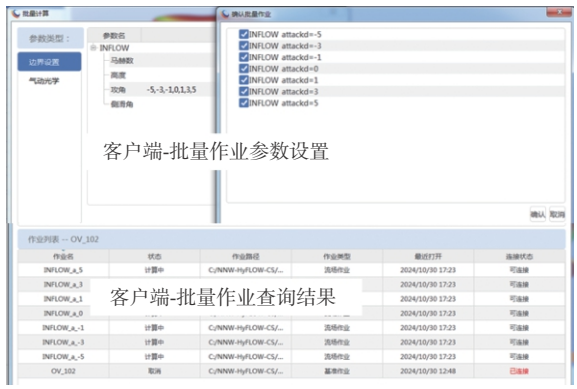


图 18　客户端提交批量作业截图

Fig. 18　Screenshot of submitting batch job on client



图 19　服务器批量作业状态监控日志截图

Fig. 19　Screenshot of batch job status monitoring log

服务端的角度来看, 其求解、监控和数据交互等操作具有一致性。与单机版类似, 面向集群的工业 CFD 软件提供了友好的交互界面, 用户可通过客户端完成网格导入、参数设置及集群计算任务, 并实时监控作业状态变化, 获取残差、气动力/热等气动数据的变化信息, 同时实现与集群仿真数据的快速同步。图 20 和图 21 展示了服务端集成气动光学、气动电磁、流场求解等多种求解类型的集群交互测试结果, 验证了该架构面对命令调用求解器并传递参数文件的 CFD 求解模式的良好扩展能力。目前, 集群交互版 NNW-HyFLOW 软件已成功部署于中国空气动力研究与发展中心、空天飞行空气动力科学与技术全国重点实验室等单位的集群环境中, 并在实际研究任务中取得了显著的应用效果。

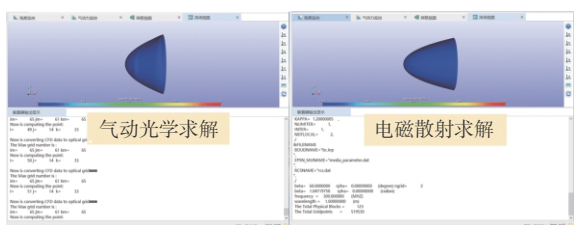


图 20　求解器兼容测试示意图

Fig. 20　Schematic of solver compatibility test

3.4　性能测试

3.4.1　测试环境

客户端使用一台 24 核工作站作为搭载系统, 配置参数信息为: CPU 主频为 2.5 GHz, 采用 Intel(R) Xeon(R) CPU E5-2648 v3 处理器, 32 GB 内存,

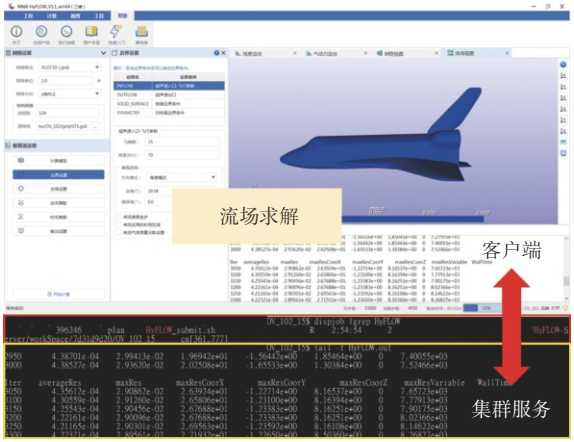


图 21 HyFLOW 软件客户端与集群数据交互示意图

Fig. 21 Schematic of HyFLOW software data interaction between client and cluster

500 GB 固态硬盘，型号为 Samsung SSD 870，操作系统为 win7。服务端部署在测试集群 1 上，Java 开发工具包（Java development kit, JDK）版本为 JRE1.8，Netty 版本为 netty-all-4.1.39.Final。性能测试采用开源压力测试工具 jmeter-5.6.3。测试在局域网进行，机器间通过千兆交换机相连，因此，实验不考虑带宽的影响。

3.4.2 资源占用率测试

1）整体资源占用率。根据客户端/服务器的设计模式，服务端的数量不会随客户端增加，多个客户端共享一个服务端，而传统耦合交互的单机版 CFD 软件每一个客户端都需要一个服务端，对比本文客户端/服务器设计模式与传统耦合交互的单机版 CFD 软件使用场景，得到资源占用率对比数据。

在不影响集群正常生产次序下，客户端数量缓慢增加至 100，在不考虑交互界面在集群上资源占用的条件下，图 22 和图 23 分别给出了客户端/服务器模式一个服务端和传统耦合交互模式每个客户端一个服务端的内存占用率和 CPU 占用率对比，

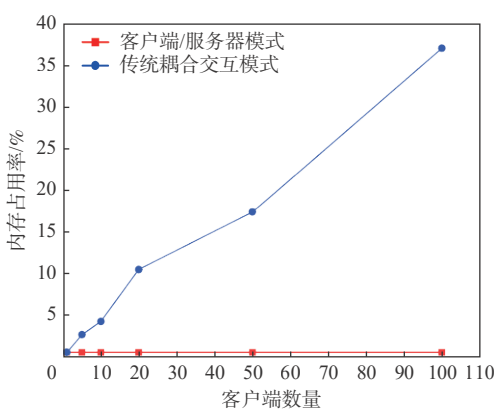


图 22 内存占用率对比

Fig. 22 Comparison of memory usage rate

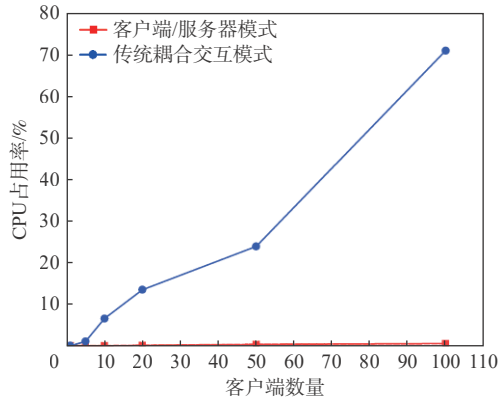


图 23 CPU 占用率对比

Fig. 23 Comparison of CPU usage rate

在 100 个客户端发起作业请求时，客户端/服务器模式的内存占用率不超过 0.6%，CPU 占用率不超过 0.7%，而在传统耦合交互模式每个客户端一个服务器的模式，由于线程数的增加及频繁创建销毁线程带来的性能开销，内存占用率和 CPU 占用率随客户端数量增加而上升，在 100 个客户端使用时，内存占用率为 37%，CPU 占用率超过 70%。相比之下，客户端/服务器的设计模式在 100 个客户端并发使用时，内存占用率减少约 36%，CPU 占用率减少约 69%，显著降低了资源占用率。

2）状态监听器性能对比测试。在只使用共享状态监听器的情况下，将采用一个线程监听所有作业运行状态（共享线程）和每个作业开启一个监听线程（独立线程）的方案进行对比。图 24 给出了不同线程模型的平均响应时间对比。从整体趋势上分析，随着客户端使用人数增多，独立线程模型平均响应时间逐步增加，在超过 50 个客户端数量时，大量线程轮询集群作业管理系统查询接口，独立线程模型平均响应时间超过 100 ms，而共享线程模型响应时间稳定在 100 ms 以内，在 100 个客户端情况下，平均响应时间降低了约 80%。

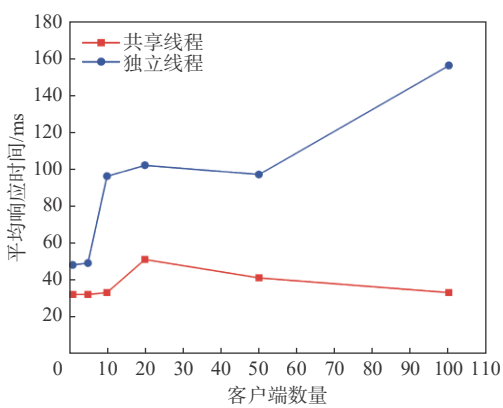


图 24 不同线程模型的平均响应时间对比

Fig. 24 Comparison of average response time between different thread models

3.4.3　服务端性能测试设计与分析

服务端性能测试主要探究其在不同并发量下的平均响应时间和吞吐量, 其中, boss 和 worker 这 2 个事件循环线程组大小设置采用官网推荐设置, 处理连接线程组设置为 1, 处理读写事件线程组设置为服务器 CPU 核数的 2 倍, 采用开源压力测试工具 apache-jmeter-5.6.3, 模拟大量客户端的 TCP 连接请求, 设置每秒线程数分别为 50、100、500、1 000、1 500、2 000, 每个线程请求 1 次, 发送和接收数据约 200 Byte。

1) 服务端平均响应时间。图 25 给出了 HyFLOW 软件服务端的系统平均响应时间对比。测试结果表明, 在 2 000 个并发数内, HyFLOW 框架的平均响应时间稳定在 100 ms 以内, 符合 Netty 框架的并发预期。在与 Slurm 系统交互的情况下, 受 Slurm 作业管理系统性能限制, 服务端在并发数不超过 500 个时, 平均响应时间缓慢增加, 但均在 1 000 ms 以内, 当并发数超过 500 个时, 平均响应时间急剧增加, 在 2 000 个并发数时达到约 6 100 ms。

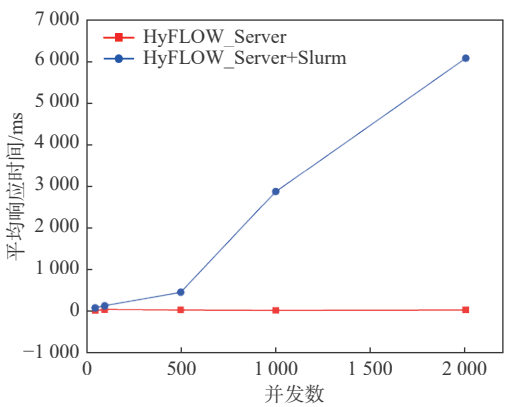


图 25　平均响应时间对比

Fig. 25　Comparison of average response time

2) 服务端平均吞吐量。图 26 给出了 HyFLOW 软件服务端的系统吞吐量对比。测试结果表明, HyFLOW 软件服务端在 2 000 个并发数内, 吞吐量线性增长, 受 Slurm 性能限制, 当并发数小于 100 个时, 吞吐量随并发数增加而增加, 当并发数大于 100 个时, 吞吐量缓慢下降, 在并发数达到 2 000 个时, 吞吐量约为 16 个/s。

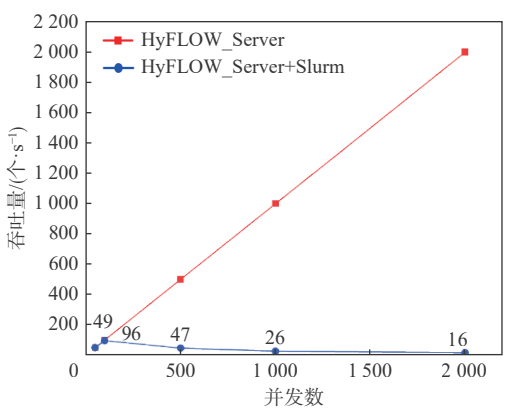


图 26　吞吐量对比

Fig. 26　Comparison of throughput

4　结　论

本文针对国产 CFD 软件在工业部门集群部署过程中存在的兼容性和交互性问题, 基于客户端/服务器架构, 从系统设计、部署方案、数据交互、作业调度与监控等维度, 设计并实现了面向集群交互的 NNW-HyFLOW 软件。通过集群环境下的兼容测试、功能测试和性能评估, 得出以下结论:

1) 系统自动化能力与易用性提升。相较于传统集群独立运行求解器模式, 本文架构能够自动监控集群作业运行状态获取结果数据, 通过文本和图形化界面直观展示残差、气动力及流场等关键计算结果, 降低了用户的学习成本, 促进了国产软件的应用推广。

2) 集群环境兼容能力显著提高。采用客户端/服务器架构, 通过解耦交互界面与求解程序, 解决了传统 CFD 软件对集群 GPU 支持的依赖问题。基于跨平台开发语言的服务程序可兼容 ARM 和 X86 等主流 CPU 架构, 显著提升了软件在异构集群环境中的适应能力, 为国产软件在工业领域的规模化部署奠定了基础。

3) 作业调度系统兼容性优化。通过解耦集群作业管理系统交互指令, 并采用标准化的输入输出配置方案, 有效解决了集群版软件与作业管理系统的兼容性问题, 提高了 CFD 软件的部署效率和运行稳定性。

4) 系统具备良好的可扩展性。针对命令调用求解器并传递参数文件的 CFD 求解模式, 本文架构仅需在交互界面增加功能参数设置, 并在服务端调整 Shell 脚本命令即可实现功能扩展, 显著提升了系统的通用性和可扩展能力。

5) 系统性能优势显著。与传统单机版架构相比, 在 100 个并发量的应用场景下, 软件的内存占用率、CPU 占用率和平均响应时间分别降低了 36%、69% 和 80%。系统在 100 个并发数以内可保持毫秒级响应速度, 为用户提供了高效的集群仿真交互体验。

展望未来, 在 CFD 软件的集群应用领域, 交互模式正朝着数字化、智能化方向快速发展。通过解耦客户端/Web 前端与集群后端, 整合算力资源, 用户无需依赖本地高性能硬件即可高效完成大规模复杂仿真任务。下一步, 面向集群交互的 NNW-

HyFLOW软件将在工业部门部署应用，为用户提供高效、易用的集群仿真服务，并基于用户反馈和工程实践需求持续迭代优化。未来，服务端将集成至数字化平台，助力软件完成数字化升级，从而更好地满足工业部门对智能化、协同化仿真解决方案的需求。

参考文献（References）

[1] 张健, 周乃春, 李明, 等. 面向航空航天领域的工业CFD软件研发设计[J]. 软件学报, 2022, 33(5): 1529-1550.
Zhang J, Zhou N C, Li M, et al. R & D and design of industrial CFD software for aeronautics and astronautics[J]. Journal of Software, 2022, 33(5): 1529-1550(in Chinese).

[2] 周铸, 黄江涛, 黄勇, 等. CFD技术在航空工程领域的应用、挑战与发展[J]. 航空学报, 2017, 38(3): 020891.
Zhou Z, Huang J T, Huang Y, et al. CFD technology in aeronautic engineering field: applications, challenges and development[J]. Acta Aeronautica et Astronautica Sinica, 2017, 38(3): 020891(in Chinese).

[3] 陈琦, 陈坚强, 袁先旭, 等. 国家数值风洞(NNW)工程在高超声速中的应用研究进展[J]. 航空学报, 2021, 42(9): 625746.
Chen Q, Chen J Q, Yuan X X, et al. Progress on application of National Numerical Windtunnel Project for hypersonic[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(9): 625746(in Chinese).

[4] 阎超. 航空CFD四十年的成就与困境[J]. 航空学报, 2022, 43(10): 526490.
Yan C. Achievements and predicaments of CFD in aeronautics in past forty years[J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(10): 526490(in Chinese).

[5] 陈坚强. 国家数值风洞(NNW)工程关键技术研究进展[J]. 中国科学: 技术科学, 2021, 51(11): 1326-1347.
Chen J Q. Advances in the key technologies of Chinese national numerical windtunnel project[J]. Scientia Sinica (Technologica), 2021, 51(11): 1326-1347(in Chinese).

[6] 袁先旭, 陈坚强, 杜雁霞, 等. 国家数值风洞(NNW)工程中的CFD基础科学问题研究进展[J]. 航空学报, 2021, 42(9): 625733.
Yuan X X, Chen J Q, Du Y X, et al. Research progress on fundamental CFD issues in National Numerical Windtunnel Project[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(9): 625733(in Chinese).

[7] 李鹏, 陈坚强, 丁明松, 等. NNW-HyFLOW高超声速流动模拟软件框架设计[J]. 航空学报, 2021, 42(9): 161-177.
Li P, Chen J Q, Ding M S, et al. Framework design of NNW-HyFLOW hypersonic flow simulation software[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(9): 161-177(in Chinese).

[8] 赵钟, 何磊, 何先耀. 风雷(PHengLEI)通用CFD软件设计[J]. 计算机工程与科学, 2020, 42(2): 210-219.
Zhao Z, He L, He X Y. Design of general CFD software PHengLEI[J]. Computer Engineering & Science, 2020, 42(2): 210-219(in Chinese).

[9] 赵钟, 张来平, 何磊, 等. 适用于任意网格的大规模并行CFD计算框架PHengLEI[J]. 计算机学报, 2019, 42(11): 2368-2383.
Zhao Z, Zhang L P, He L, et al. PHengLEI: a large scale parallel CFD framework for arbitrary grids[J]. Chinese Journal of Computers, 2019, 42(11): 2368-2383(in Chinese).

[10] 陈坚强, 吴晓军, 张健, 等. FlowStar: 国家数值风洞(NNW)工程非结构通用CFD软件[J]. 航空学报, 2021, 42(9): 625739.
Chen J Q, Wu X J, Zhang J, et al. FlowStar: general unstructured-grid CFD software for National Numerical Windtunnel (NNW) Project[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(9): 625739(in Chinese).

[11] 章锦威, 戚姝妮, 郭承鹏, 等. 基于非结构平台的DLR-F6标模阻力预测[J]. 航空计算技术, 2015, 45(2): 84-87.
Zhang J W, Qi S N, Guo C P, et al. Computed verification of drag prediction for DLR-F6 wing body on unstructured grids flow solver[J]. Aeronautical Computing Technique, 2015, 45(2): 84-87(in Chinese).

[12] 刘毅, 王刚, 叶正寅. 典型外形高超声速气动力/气动热数值计算研究[J]. 西北工业大学学报, 2014, 32(2): 169-175.
Liu Y, Wang G, Ye Z Y. Numerical investigation of aerodynamic and aero-thermal effects for hypersonic vehicles[J]. Journal of Northwestern Polytechnical University, 2014, 32(2): 169-175(in Chinese).

[13] 徐瑞, 杨永, 胡春馨, 等. 航空计算技术工业软件云化研究[J]. 山西电子技术, 2024(1): 116-118.
Xu R, Yang Y, Hu C X, et al. Research on cloudization of industrial software in aviation computing technology[J]. Shanxi Electronic Technology, 2024(1): 116-118(in Chinese).

[14] 安洲, 袁义, 宋文龙, 等. 面向航天器设计的高性能计算平台研究与应用[J]. 航天制造技术, 2022(4): 74-78.
An Z, Yuan Y, Song W L, et al. Research and application of high performance computing platform for spacecraft design[J]. Aerospace Manufacturing Technology, 2022(4): 74-78(in Chinese).

[15] 陈晓明, 田喜民, 万李韦. 基于混合云的舰船高性能计算仿真平台研究[J]. 信息技术, 2023(10): 79-83.
Chen X M, Tian X M, Wan L W. Research on ship high-performance computing simulation platform based on hybrid cloud[J]. Information Technology, 2023(10): 79-83(in Chinese).

[16] 牟泓宇, 马轶聪, 淮晓永. 面向云计算环境的CFD数据可视化分析服务[J]. 电子技术应用, 2023, 49(3): 118-123.
Mou H Y, Ma Y C, Huai X Y. CFD data visualization analysis service for cloud computing environment[J]. Application of Electronic Technique, 2023, 49(3): 118-123(in Chinese).

[17] 李林锋. Netty权威指南[M]. 北京: 电子工业出版社, 2014: 1-505.
Li L F. Netty authoritative guide[M]. Beijing: Publishing House of Electronics Industry, 2014: 1-505(in Chinese).

Interactive design and implementation of cluster-oriented industrial CFD software

ZHANG Fan[1, 2], DING Mingsong[1, 2], CHEN Jianqiang[1, 2], LIU Wan[1, 2, *], JIANG Tao[1, 2], LI Peng[1, 2], JIANG Jun[1, 2]

(1. Computational Aerodynamic Institute, China Aerodynamics Research and Development Center, Mianyang 621000, China;
2. State Key Laboratory of Aerodynamics, Mianyang 621000, China)

Abstract: In the field of aerospace engineering, industrial computational fluid dynamics (CFD) software relies on high-performance computing clusters to generate aerodynamic data, serving as a critical tool for assisting aircraft design. This paper devises and executes a CFD software framework for cluster interaction to address the challenges faced by domestic CFD software in high-performance computing cluster deployment and simulation, along with compatibility issues with software/hardware environments, while considering the requirements of the National Numerical Windtunnel (NNW) project for software research, development, and promotion. The architecture employs a client/server model, incorporating features such as an interactive interface, cluster communication, login authentication, simulation task management, and job monitoring, while facilitating a command-based solver invocation and parameter file transfer, demonstrating significant versatility and scalability. Testing outcomes indicate that the framework is congruent with prevalent cluster architectures and job scheduling systems; in contrast to conventional coupled architectures, it diminishes memory utilisation by 36% and CPU consumption by 69% under hundreds of simultaneous tasks, while maintaining average response times within 100 milliseconds, highlighting its benefits in resource efficiency and swift responsiveness. Currently, the designed framework has been applied to the NNW software ecosystem, provide users with smooth cluster simulation interaction services and significantly improve the user experience of CFD simulations.

Keywords: high-performance computing cluster; computational fluid dynamics; industrial software; job scheduling; aerospace; National Numerical Windtunnel Project

Received: 2024-11-12; **Accepted**: 2025-03-28; **Published Online**: 2025-04-30 12:35
URL: link.cnki.net/urlid/11.2625.V.20250430.1114.001
Foundation item: National Numerical Windtunnel Project
* **Corresponding author**. E-mail: 13340898729@163.com

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0679

基于时空特征提取的GTA-Seq2Seq多步4D航迹预测模型

石庆研，赵婉彤，韩萍*

(中国民航大学 智能信号与图像处理天津市重点实验室，天津 300300)

摘 要：高精度多步航迹预测有助于实时调整飞行路径，避免潜在冲突，提高飞行安全。传统模型通常面临多步预测精度低、难以捕获飞行轨迹中时空特征之间非线性关系的问题。为此，提出一种在序列到序列(Seq2Seq)模型中使用门控循环单元(GRU)、时间卷积网络(TCN)和时序模式注意力(TPA)机制的多步4D航迹预测模型GTA-Seq2Seq。该模型分为编码器和解码器部分，编码器使用GRU提取航迹数据中时间依赖性，并结合TCN-GRU网络提取航迹数据的空间特征，通过TPA分配各隐藏特征的权重。在解码器部分，时空特征经过拼接后输入GRU中，实现高精度的多步航迹预测。实验表明：所提模型在预测精度上优于传统模型，该模型中第5步预测相较于对比模型中最优模型——基于时空特征融合的编码器-解码器(STED)模型，均方根误差(RMSE)减小了27.70%，平均绝对误差(MAE)减小了23.82%。此外，GTA-Seq2Seq模型在训练过程中所需的参数量相较于STED模型减少了67.42%，提高了模型的运算效率。

关 键 词：航迹预测；时空特征；时间卷积网络；注意力机制；编码解码；序列到序列模型
中图分类号：V355; TP391.9
文献标志码：A **文章编号**：1001-5965(2026)11-3894-13

近年来，航空运输业的快速发展使空中交通量不断增长，航班延误、空域紧张等现象时有发生[1]。为应对不断增加的空中交通量给空中交通管制(air traffic control, ATC)系统带来的挑战，国际民航组织(International Civil Aviation Organization, ICAO)将基于航迹运行(trajectory based operation, TBO)加入航空系统中[2]。TBO是以航空器全飞行周期的四维航迹为基础，在空管、机场、航空公司、航空器等相关方之间实时共享和动态维护航迹信息，进而实现多方协同决策[3-4]。2020年3月，中国民用航空局空中交通管理局制定了《中国民航空管现代化战略(CAAMS)实施路线图》[5]，将TBO和4D航迹预测列为未来空管现代化的核心目标，高精度的航迹预测对于提升空管系统的安全性和效率至关重要[6]。相比于单步预测，多步预测可以预测未来一段时间航班的飞行位置，有助于实时调整飞行路径，为避免潜在冲突提供关键信息，提高飞行安全。然而，现阶段多步航迹预测研究面临严峻挑战，其紧迫性日益凸显。目前，多步预测面临预测误差累积、时空特征捕捉能力不足及计算效率低等问题。因此，提高多步预测的精度和效率，已成为当前航空领域需解决的关键问题。

目前，有关短期航迹预测的方法大致可以分为基于质点运动、基于状态估计和基于机器学习3类。基于质点运动的航迹预测[7]是将空中飞行器看作一个粒子，对其进行受力分析，将运动学模型及飞机参数结合起来建立预测模型。该方法存在所需飞机自身及运动学相关参数过多的问题。基

收稿日期：2024-09-18；**录用日期**：2024-11-22；**网络出版时间**：2024-12-20 13:04
网络出版地址：link.cnki.net/urlid/11.2625.V.20241219.1708.001
基金项目：民航局安全能力建设资金(KJZ49420210082)
* **通信作者**. E-mail：hanpingcauc@163.com

引用格式：石庆研，赵婉彤，韩萍. 基于时空特征提取的GTA-Seq2Seq多步4D航迹预测模型[J]. 北京航空航天大学学报，2026，52(11)：3894-3906. Shi Q Y，Zhao W T，Han P. GTA-Seq2Seq multi-step 4D trajectory prediction model based on spatio-temporal feature extraction[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3894-3906 (in Chinese).

于状态估计的航迹预测[8]将飞机的运动过程看作状态转移过程, 通过运动方程构建状态转移矩阵, 研究未来时间点的位置与历史时间点中位置、速度、加速度等状态之间的关系。然而, 这种方法所构建的模型在处理航迹数据时存在明显局限, 难以应对其中复杂的非线性关系和外部干扰等问题, 且计算复杂度较高。

基于机器学习的算法逐渐应用于航迹预测。机器学习在大量航迹数据中挖掘隐藏信息, 建立神经网络, 提取航迹信息之间的非线性关系, 这对于提高航迹预测精度至关重要。短期航迹预测根据预测范围分为单步预测和多步预测。目前, 用于航迹预测的经典神经网络有反向传播 (back propagation, BP) 神经网络[9]、长短期记忆 (long short-term memory, LSTM) 网络[10-12]、门控循环单元 (gate recurrent unit, GRU)[13-14] 等循环神经网络 (recurrent neural network, RNN) 的变体。然而, RNN 及其变体依赖于递归机制来处理时间序列, 即通过前一个时间步的隐藏状态传递信息, 导致计算效率较低, 难以并行处理。近年来, 卷积神经网络 (convolutional neural network, CNN)[15] 和时间卷积网络 (temporal convolutional networks, TCN)[16] 逐渐应用在航迹预测中。在多步航迹预测中, 焦卫东等[17] 采用多尺度卷积 (multi-scale convolution, MSC) 网络和时空双重注意力 (spatio-temporal dual attention, STDA) 机制相结合的 TCN 来提高多步预测的连续性和准确性。随着深度学习的发展, 能够捕捉航迹序列长时间依赖关系的编码器-解码器结构应用到多步航迹预测中。卢婷婷等[18] 提出一种基于序列到序列 (sequence-to-sequence, Seq2Seq) 框架的机场终端区航迹预测模型, 结合注意力机制和教师强制中的指数衰减采样方法预测航迹序列, 以提高预测的准确性和模型的训练效率。Tran 等[19] 通过编码器-解码器结构建模和整合飞机的战术意图来进行多步航迹预测。Zeng 等[20] 同样采用编码器-解码器架构, 专注于挖掘航迹之间的长时间依赖关系, 以预测终端区的未来飞行轨迹。Zhang 等[21] 除使用编码器-解码器架构外, 还引入了时间频率小波变换, 以提高模型获取飞行数据中时间-频率特征的能力。石庆研等[22] 提出一种新型的基于时空特征融合的编码器-解码器 (spatio-temporal encoder-decoder, STED)模型, 通过集成 GRU、CNN 和注意力机制来精确提取航迹数据的时空特征。单步预测通常关注于根据输入信息预测下一时刻的状态, 而多步预测更适合捕捉未来轨迹的变化趋势, 尽管误差累积和模型复杂度较高, 但能够提供更完整的轨迹信息。上述多步预测的方法都有一定有效性, 在一定程度上改进了传统迭代多步预测中误差累积的问题, 但仍存在时空特征提取不完全, 以及多步预测误差随着预测步数增加而出现不稳定变化的问题。

鉴于此, 本文以编码器-解码器架构为基础, 提出一种在 Seq2Seq 模型中使用 GRU、TCN 和时序模式注意力 (temporal pattern attention, TPA) 机制的多步 4D 航迹预测模型 GTA-Seq2Seq。模型中编码器部分采用 GRU 提取航迹数据中的时间依赖性, 为提取航迹中多维度空间特征, 使用 TCN 和 GRU 结合的网络输出高级隐藏信息, 并对高级隐藏特征通过 TPA 使用评分函数分配各隐藏特征的权重, 不同隐藏特征的权值大小对未来预测航迹的精度有不同影响。在解码器中, 将编码器提取到的时空特征输入 GRU, 实现高精度的多步航迹预测。本文利用真实数据集进行实验, 并与其他模型进行比较, 以验证本文模型的有效性。

1　GTA-Seq2Seq 多步航迹预测模型

1.1　问题定义

本文关注短期多步航迹预测任务, 即根据给定的历史输入序列, 预测接下来几个时间步的飞机位置。在处理航迹数据时, 通常设置长度为 p 和 s 的滑动窗口分别构造输入数据和标签数据。从第 1 个航迹点开始, 选取 p 个航迹点作为模型的输入数据, 再选取后面要预测的 s 个真实航迹点作为标签数据, 生成第 1 个样本。每次滑动可以提取出一组新的数据样本, 输入数据 $\boldsymbol{X}$ 和标签数据 $\boldsymbol{Y}$ 分别为

$$\boldsymbol{X}=[\boldsymbol{X}_1,\boldsymbol{X}_2,\cdots,\boldsymbol{X}_N] \tag{1}$$

$$\boldsymbol{Y}=[\boldsymbol{Y}_1,\boldsymbol{Y}_2,\cdots,\boldsymbol{Y}_N] \tag{2}$$

$$\boldsymbol{X}_t=\left[\boldsymbol{x}_t,\boldsymbol{x}_{t+1},\cdots,\boldsymbol{x}_{t+p-1}\right] \tag{3}$$

$$\boldsymbol{Y}_t=\left[\boldsymbol{y}_{t+p},\boldsymbol{y}_{t+p+1},\cdots,\boldsymbol{y}_{t+p+s-1}\right] \tag{4}$$

式中: N 为通过滑动窗口滑窗得到的样本数量; $\boldsymbol{X}_t$ 和 $\boldsymbol{Y}_t$ 分别为第 t 个样本的输入和标签数据 ($t=1,2,\cdots,N$); 每个输入航迹点 $\boldsymbol{x}_t$ 又包含多维特征。

模型输入的是长度为 p 的历史航迹数据 $\boldsymbol{X}_t=\left[\boldsymbol{x}_t,\boldsymbol{x}_{t+1},\cdots,\boldsymbol{x}_{t+p-1}\right]$, 模型的目标是可以输出未来 s 个时间步的航迹信息 $\hat{\boldsymbol{Y}}_t=\left[\hat{\boldsymbol{y}}_{t+p}^{(t)},\hat{\boldsymbol{y}}_{t+p+1}^{(t)},\cdots,\hat{\boldsymbol{y}}_{t+p+s-1}^{(t)}\right]$, 其中, $\hat{\boldsymbol{y}}_{t+p}^{(t)}$ 为使用前 p 个历史数据作为输入样本, 预测第 p+1 个时间步得到的航迹数据。上标 "(t)" 表示预测模型的输入是第 t 个样本数据 $\boldsymbol{x}_t$。

1.2　模型框架构建

航迹预测是具有时空特征的多维时间序列预

测任务。每个特征都有长短期的时间变化模式，航迹点随时间变化能够呈现出飞机整体的运动变化规律。通过学习这些规律，模型能更准确地预测飞机未来的轨迹。同时，每个特征之间也存在着相互依赖的空间信息，例如，在巡航阶段，输入数据中的纬度变化对高度变化影响不大，因此，获取不同特征之间的空间信息有助于捕捉飞机在不同飞行状态下的移动规律，从而使预测模型能更准确地预测飞机未来的轨迹。轨迹数据中的空间位置信息与时间变化趋势相关，表明了空间与时间维度的紧密联系，因此，本文提出一种能充分提取航迹数据之间时空特征并实现高精度航迹预测的方法。本文航迹预测模型如图 1 所示，该模型包含提取空间特征和提取时间特征 2 个模块组成的编码器部分及由 GRU 神经网络和全连接层 (fully connected layer, FC) 构成的解码器部分。

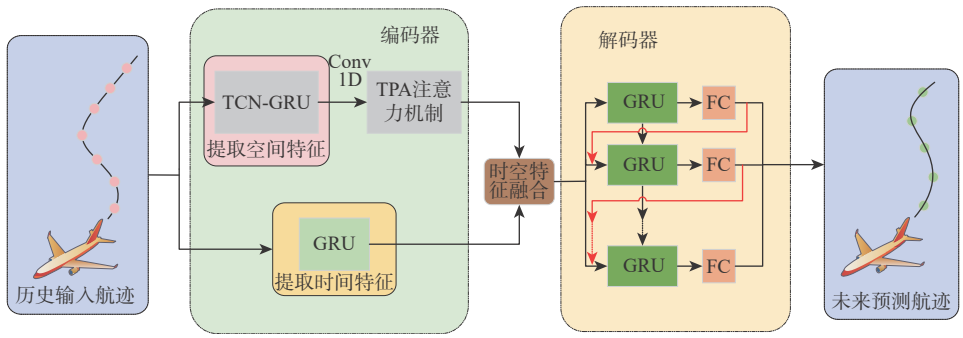


图 1 GTA-Seq2Seq 航迹预测模型总体结构

Fig. 1 GTA-Seq2Seq overall structure of trajectory prediction model

模型输入是长度为 p 的航迹点，包含经度、纬度、高度和时间。模型结构包含 4 个部分：①时间特征提取模块，将 $\boldsymbol{X}$ 输入 GRU 中提取每个航迹点之间的时间依赖性；②空间特征提取模块，由于 TCN 能有效挖掘航迹数据之间的变量关系，因此，选定 TCN 作为提取历史空间信息的主要神经网络之一，将历史航迹数据 $\boldsymbol{X}$ 输入 TCN-GRU 模型中，以便建模并提取空间隐藏信息；③在提取出空间隐藏信息后，搭建 TPA 注意力机制以确定哪些过去的隐藏信息对当前预测影响更大；④编码器中提取时间特征模块和空间特征模块的输出进行拼接融合，生成编码器输出的语义向量，解码器使用 GRU 网络递归输出未来 s 步的航迹点。GTA-Seq2Seq 模型结构如图 2 所示。

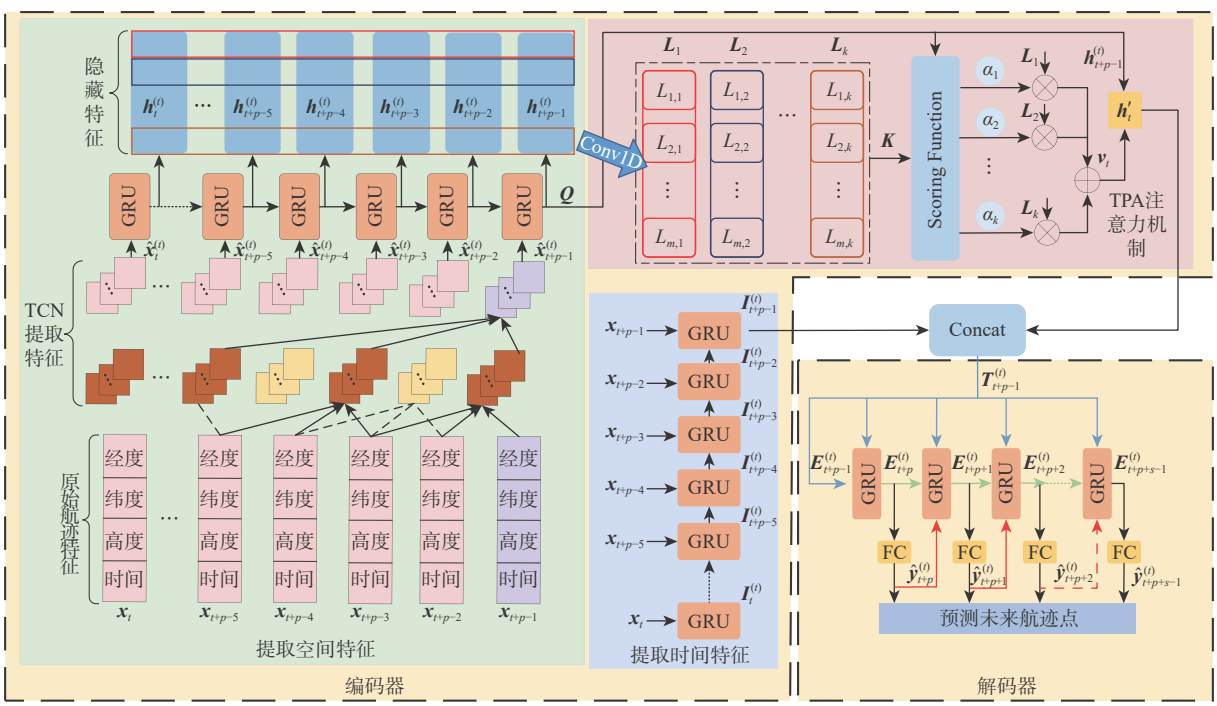


图 2 GTA-Seq2Seq 航迹预测模型结构

Fig. 2 Structure of GTA-Seq2Seq trajectory prediction model

1.3　GTA-Seq2Seq 模型编码器

1.3.1　提取时间特征

编码器中提取时间特征部分是用 GRU 提取航迹序列中的时间依赖性。航迹序列中包含了在不同时间收集到的数据, 这些数据呈现飞机随时间变化的规律。RNN 是早期用于处理时间序列数据的网络, 但由于其结构问题, 训练慢, 容易出现梯度消失或爆炸。LSTM[23] 是改进的 RNN 模型, 通过引入输入门、输出门和遗忘门来解决梯度消失问题, 但其参数多且训练效率低。GRU[24] 是更简单的 RNN 变种, 其通过更新门和重置门来处理时间序列中时间间隔较大的依赖关系, 且具有更少的参数和更快的训练速度。更新门控制着上一步隐藏状态信息在当前隐藏状态中的保留程度, 重置门控制着上一步隐藏状态信息在当前隐藏状态中的遗忘程度。GRU 的具体结构如图 3 所示, 相关计算式如下:

$$\boldsymbol{z}_t=\sigma(\boldsymbol{W}_z\cdot[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_z) \tag{5}$$

$$\boldsymbol{r}_t=\sigma(\boldsymbol{W}_r\cdot[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_r) \tag{6}$$

$$\hat{\boldsymbol{h}}_t=\tanh(\boldsymbol{W}_h\cdot[\boldsymbol{r}_t*\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_h) \tag{7}$$

$$\boldsymbol{h}_t=(1-\boldsymbol{z}_t)*\boldsymbol{h}_{t-1}+\boldsymbol{z}_t*\hat{\boldsymbol{h}}_t \tag{8}$$

式中: $\boldsymbol{z}_t$为更新门; $\boldsymbol{r}_t$为重置门; “[]”表示 2 个向量连接; “·”表示 2 个矩阵相乘; “ * ”表示 2 个矩阵中的对应元素相乘; σ和 tanh 分别为 sigmoid 和 tanh 激活函数; $\boldsymbol{W}$ 和 $\boldsymbol{b}$ 分别为可训练的权重矩阵和偏置项; $\boldsymbol{h}_t$和$\boldsymbol{h}_{t-1}$分别为当前时间步和上一时间步隐藏状态向量; $\hat{\boldsymbol{h}}_t$为候选隐藏状态向量。

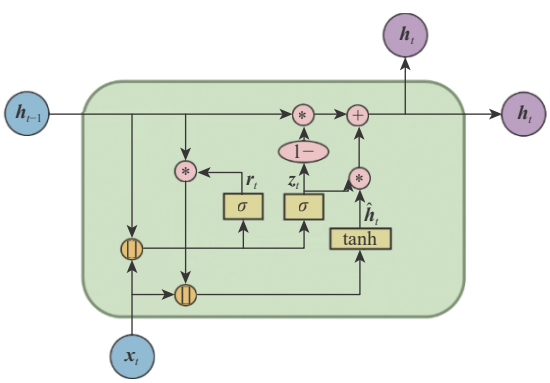


图 3　GRU 单元结构

Fig. 3　GRU unit structure

如图 2 中提取时间特征时, 每个时间步的经度、纬度、高度、时间数据同时输入到 GRU 中, 且每个 GRU 单元都会根据当前输入和上一隐藏状态来计算新的隐藏状态。新状态包含到当前时间步为止的历史信息, 并可以用作下一个时间步的输入状态或最终输出。GRU 通过逐步学习各个时间步的时序模式, 输出最后一个时间步的隐藏状态信息 $\boldsymbol{I}_{t+p-1}^{(t)}$, 可表示为

$$\boldsymbol{I}_{t+p-1}^{(t)}=\mathrm{GRU}\left(\boldsymbol{I}_{t+p-2}^{(t)},\boldsymbol{X}_{t+p-1}\right) \tag{9}$$

式中: $\boldsymbol{I}_{t+p-2}^{(t)}$为在 t+p−2 时间步 GRU 输出的包含前面所有时间步的隐藏向量; $\boldsymbol{X}_{t+p-1}$为第 t+p−1 个航迹点。

1.3.2　提取空间特征

TCN 是由 Bai 等在 2018 年提出的, 是一种基于 CNN 的模型, 专门用于处理时序数据, TCN 结构如图 4 所示。其主要由堆叠的残差模块构成, 如图 4(a) 所示。为避免梯度消失问题, TCN 中的残差模块包括扩张因果卷积、空间 Dropout 和权值归一化, 残差块的输出还通过 1×1 卷积增强, 保持输入和输出维度的一致性, 如图 4(b) 所示。扩张因果卷积输出只依赖于当前和之前的数据, 适合预测任务, 另外, 还能通过扩张因子提高模型的记忆能力, 并获取长期依赖信息, 如图 4(c) 所示。扩张卷积的计算式为

$$F_d(t)=\sum_{i=0}^{k-1}f_i*\boldsymbol{x}_{t-d\cdot i} \tag{10}$$

式中: $\boldsymbol{F}_d(t)$为扩张因子为 d 时, t 时刻的扩张因果卷积的输出结果; $\boldsymbol{x}_{t-d\cdot i}$为当前和过去的输入数据; $t-d\cdot i$表示以扩张的方式选取输入序列中的元素进行卷积运算; k 为卷积核大小; f_i为滤波器在 i 位置上的权重。

TCN-GRU 模型对输入长度为 p 的历史航迹信息进行空间隐藏特征的提取, TCN 通过两层堆叠, 每层具有不同数量的卷积核, 以增强模型提取空间特征能力, 且采用了多个不同扩张率的卷积核来进行卷积。GRU 则用于进一步提取隐藏特征矩阵中更复杂的时序关系。每个 GRU 输出当前时间步的隐藏状态向量, 所有 GRU 输出的向量构成隐藏特征矩阵 $\boldsymbol{H}^{(t)}=\left[\boldsymbol{h}_t^{(t)},\boldsymbol{h}_{t+1}^{(t)},\cdots,\boldsymbol{h}_{t+p-1}^{(t)}\right]\in\mathbf{R}^{m\times p}$, m 为隐藏特征个数。矩阵的每行是相同的隐藏特征在各个时间步的信息表达, 每列为 GRU 输出的当前时间步所有隐藏特征组成的向量。

1.3.3　TPA 注意力机制

引入注意力机制能对 TCN-GRU 所提取到的隐藏特征进行动态权重分配, 从而将注意力集中到重要的隐藏特征, 忽略次要特征, 以提高预测精度。

TPA 注意力机制通过一阶 CNN 提取隐藏特征矩阵 $\boldsymbol{H}^{(t)}$中每个特征的高阶隐藏信息。卷积核 $\boldsymbol{C}_u\in\mathbf{R}^{1\times p}$沿着隐藏特征矩阵 $\boldsymbol{H}^{(t)}$的列向量进行遍历, 可以融合每个特征在不同时间步的高级信息。由于 CNN 可以从特征向量中提取许多不同的模式, 因此, 不同的卷积核在提取特征时从多个角度获取到单个隐藏特征的变化趋势。最终生成高级

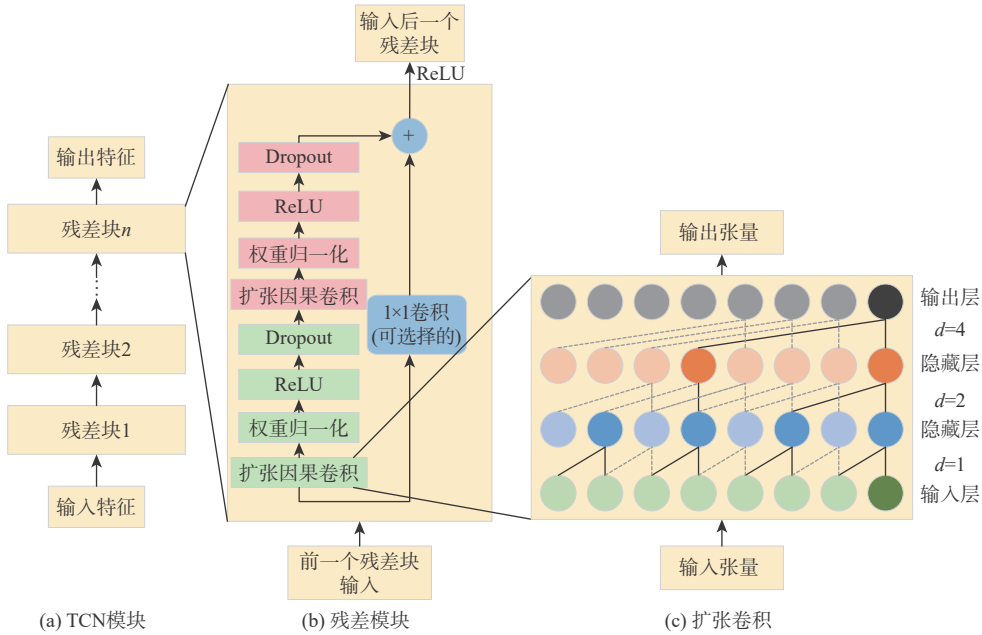


图 4 TCN 及其内部结构

Fig. 4 TCN and its internal structure

特征矩阵$\boldsymbol{L}\in\mathbf{R}^{m\times k}$。卷积过程可表示为

$$\boldsymbol{L}_{a,u}=\boldsymbol{H}_a^{(t)}\boldsymbol{C}_u^{\mathrm{T}} \tag{11}$$

式中：$a=1,2,\cdots,m,u=1,2,\cdots,k$；$\boldsymbol{H}_a$为隐藏特征矩阵中第 a 行的行向量。

提取空间特征中，最后一个 GRU 生成的隐藏状态向量$\boldsymbol{h}_{t+p-1}^{(t)}$不仅作为所有时间步的隐藏状态特征，而且作为注意力机制中的查询序列 $\boldsymbol{Q}$，以确定在当前时间步长下哪个隐藏特征影响更大。通过 CNN 得到的高级特征矩阵 $\boldsymbol{L}$ 被用作 TPA 注意力机制中的键向量 $\boldsymbol{K}$，以映射每个隐藏特征在特定时间步长的重要性。借助权重矩阵$\boldsymbol{W}_{\mathrm{sf}}\in\mathbf{R}^{k\times m}$，根据式 (12) 通过打分函数 Scoring Function 进行打分，使用式 (13) 中的 softmax 函数对各注意力权重系数做归一化处理，得到在特定时间步下隐藏特征注意力权重$\boldsymbol{\alpha}=[\alpha_1,\alpha_2,\cdots,\alpha_k]$。

$$e_u=\boldsymbol{L}_u^{\mathrm{T}}\boldsymbol{W}_{\mathrm{sf}}\boldsymbol{h}_{t+p-1}^{(t)} \tag{12}$$

$$\alpha_u=\mathrm{Softmax}(e_u)=\exp(e_u)\Big/\sum_{q=1}^{k}\exp(e_q) \tag{13}$$

式中：$\boldsymbol{L}_u$为生成的高级特征矩阵 $\boldsymbol{L}$ 第 u 列的列向量；α_u为第 u 个卷积核中特征在$\boldsymbol{h}_{t+p-1}^{(t)}$下的重要性权重，且$\sum_{u=1}^{k}\alpha_u=1$；$e_u$、$e_q$为注意力得分。

使用$\boldsymbol{\alpha}$对高级特征矩阵 $\boldsymbol{L}$ 的列向量重新计算为加权向量$\boldsymbol{v}_t\in\mathbf{R}^m$，得到注意力机制层的输出，表达式为

$$\boldsymbol{v}_t=\sum_{u=1}^{k}\alpha_u\boldsymbol{L}_u \tag{14}$$

将得到的注意力权重$\boldsymbol{v}_t$和隐藏向量$\boldsymbol{h}_{t+p-1}^{(t)}$通过$\boldsymbol{W}_v$和$\boldsymbol{W}_h$进行组合，获得包含当前时间步下重要特征权重的矩阵$\boldsymbol{h}_t'$：

$$\boldsymbol{h}_t'=\boldsymbol{W}_h\boldsymbol{h}_{t+p-1}^{(t)}+\boldsymbol{W}_v\boldsymbol{v}_t \tag{15}$$

式中：$\boldsymbol{W}_h\in\mathbf{R}^m$；$\boldsymbol{W}_v\in\mathbf{R}^m$；$\boldsymbol{h}_t'\in\mathbf{R}^m$。

1.4 GTA-Seq2Seq 模型解码器

GTA-Seq2Seq 模型中解码器部分采用单层 GRU 单元组成的神经网络。解码器的输入是含有时空特征的向量$\boldsymbol{T}_{t+p-1}^{(t)}$，该向量通过将向量$\boldsymbol{I}_{t+p-1}^{(t)}$与$\boldsymbol{h}_t'$拼接而得到，可记为

$$\boldsymbol{T}_{t+p-1}^{(t)}=\mathrm{Concat}\left(\boldsymbol{I}_{t+p-1}^{(t)},\boldsymbol{h}_t'\right) \tag{16}$$

设 GRU 的初始状态$\boldsymbol{T}_{t+p-1}^{(t)}$为$\boldsymbol{E}_{t+p-1}^{(t)}$，将$\boldsymbol{T}_{t+p-1}^{(t)}$输入 s 次到 GRU 单元中，在预测下一个时间步时 GRU 单元使用拼接向量$\boldsymbol{T}_{t+p-1}^{(t)}$和$\boldsymbol{E}_{t+p-1}^{(t)}$来生成预测值，此时 GRU 单元的输出是隐藏状态向量$\boldsymbol{E}_{t+p}^{(t)}$，在后面加一个 FC 生成在该时间步下的预测值$\hat{\boldsymbol{y}}_{t+p}^{(t)}$。GRU 单元的隐藏状态计算式为

$$\boldsymbol{E}_{t+p}^{(t)}=g\left(\boldsymbol{T}_{t+p-1}^{(t)},\boldsymbol{E}_{t+p-1}^{(t)}\right) \tag{17}$$

式中：g 为 GRU 单元的隐藏状态计算函数。

在预测后面的航迹点时，GRU 单元的输入是由含有时空特征向量$\boldsymbol{T}_{t+p-1}^{(t)}$、GRU 在前一时间步输出的隐藏状态和前一时间步输出的预测值组成，预测第 s 步的表达式为

$$\hat{\boldsymbol{y}}_{t+p+s-1}^{(t)}=F\left(\boldsymbol{T}_{t+p-1}^{(t)},\boldsymbol{E}_{t+p+s-1}^{(t)},\hat{\boldsymbol{y}}_{t+p+s-2}^{(t)}\right) \tag{18}$$

式中：F 为预测值输出方式函数。

1.5　总体方案设计

在 GTA-Seq2Seq 模型的基础上, 结合数据样本划分, 可以得到完整的航迹预测方案, 如图 5 所示。具体步骤如下:

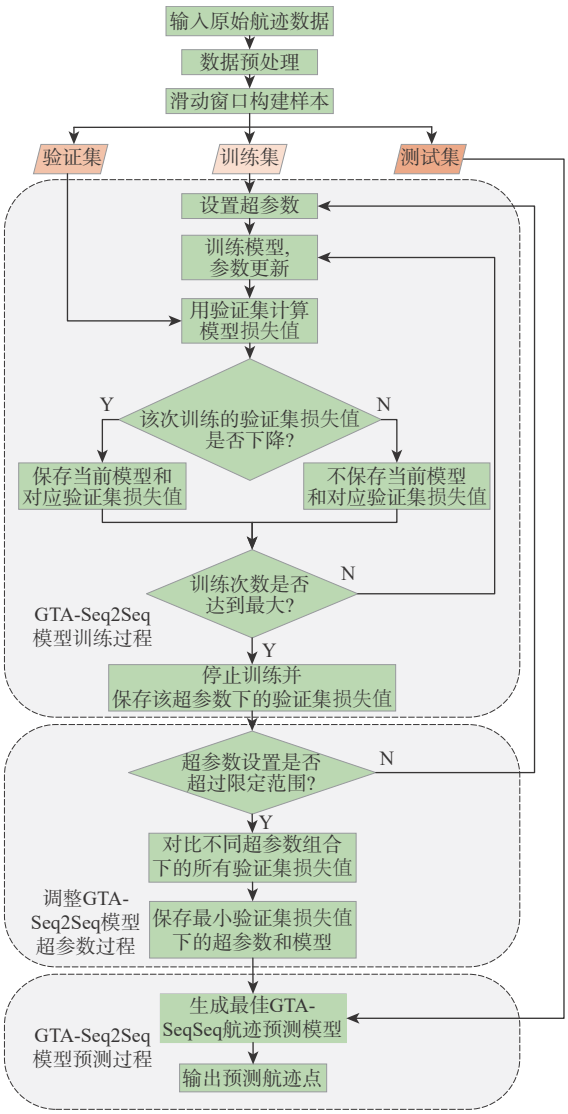


图 5　航迹预测方案流程

Fig. 5　Trajectory prediction scheme flow

1) 滑动预处理之后的航迹数据构建样本, 划分训练集、验证集和测试集;

2) 将训练集输入 GTA-Seq2Seq 模型中训练, 设定 epoch 迭代轮次, 基于训练集的损失函数使用 Adam 优化器更新模型参数, 同时, 引入验证集来评估模型的性能, 根据模型在验证集上由损失函数计算得到的损失值来判断模型的泛化能力并调整超参数, 迭代完成后停止训练, 保存最佳模型;

3) 保存最佳模型后, 使用测试集进行测试, 预测未来航迹点位置, 完成航迹预测。

2　数据构建

航迹数据是不连续的, 由一系列离散轨迹点组成, 但有一些信息缺失或重复的航迹点。信息不全的航迹点排除在数据集中, 重复的点被删除。经过数据清洗后的航迹数据更加平滑, 为后续的模型训练提供质量较好的数据样本, 提升模型的预测精度。

将航迹数据输入模型训练之前, 需要将航迹数据划分为样本数据和标签数据。使用滑动窗口的方法对每条航迹进行分割, 生成第 1 个样本时, 从第 1 个航迹点开始, 选取 p 个航迹点作为输入到模型中的历史输入数据, 后面要预测的 s 步真实航迹点作为标签数据。生成第 2 个样本时, 从第 2 个航迹点继续滑窗, 重复上述操作。滑窗处理过程如图 6 所示。

	经度/(°)	纬度/(°)	高度/m	
样本1	106.753 1	29.859 5	1 979	
	106.807 1	29.920 5	2 651	样本2
样本3	106.891 2	29.959 1	3 471	
	106.959 5	30.022 5	4 248	
	107.012 5	30.097 9	5 034	
	107.005	30.184 9	5 617	
	106.927	30.259 1	5 975	
	106.841 4	30.338 9	6 511	
	106.737 4	30.402 2	7 051	
	106.617 5	30.451 4	7 421	

(a) 样本数据(p=3)

	经度/(°)	纬度/(°)	高度/m	
	106.753 1	29.859 5	1 979	
	106.807 1	29.920 5	2 651	
	106.891 2	29.959 1	3 471	
	106.959 5	30.022 5	4 248	
标签2	107.012 5	30.097 9	5 034	
	107.005	30.184 9	5 617	标签1
	106.927	30.259 1	5 975	
	106.841 4	30.338 9	6 511	标签3
	106.737 4	30.402 2	7 051	
	106.617 5	30.451 4	7 421	

(b) 标签数据(s=5)

图 6　滑窗处理过程示意图

Fig. 6　Schematic diagram of sliding window processing

航迹数据是由不同特征组成的, 为去除度量单位和类型不同而导致不同数据取值范围差异较大所带来的影响, 需要将滑窗后的航迹数据进行归一化。本文采用最大最小归一化对航迹数据进行处理, 使输入模型的数据大小在 [0,1] 之间, 其归一化表达式为

$$\tilde{\boldsymbol{X}} = (\boldsymbol{X} - \boldsymbol{X}_{\min})/(\boldsymbol{X}_{\max} - \boldsymbol{X}_{\min}) \tag{19}$$

式中: $\boldsymbol{X}_{\max}$ 和 $\boldsymbol{X}_{\min}$ 分别为航迹数据中某个特征的最大和最小值; $\tilde{\boldsymbol{X}}$ 为归一化后的特征值。

3　仿真实验与结果分析

3.1　数据准备及超参数选择

为验证 GTA-Seq2Seq 模型的预测效果, 本文选

取重庆飞往乌鲁木齐的CCA4155航班的28条航迹数据，每条轨迹在预处理后包含大约200个多维航迹点，数据间隔约为60 s。所使用的航迹数据由航班号、飞机ID、接收时间、经度、纬度、高度、地速、俯仰角、横滚角、航向角组成。所有实验均采用Keras深度学习框架进行模型的训练和验证，实验设备的硬件环境是IntelCorei7-10700 CPU 2.9 GHz和16 GB内存的计算机。

合理的超参数设置在模型训练中起到了至关重要的作用，直接影响模型在训练集和测试集上的表现。本文设置预测步数s为5，也就是预测约5 min之后的飞机位置，因为这段时间足够长，能够为潜在的空中冲突提供预警，并留出充足的反应时间，以便采取相应的规避措施。根据模型训练过程中验证集损失值是否减小来调整模型的各项参数，包括输入历史航迹点个数、CNN卷积核数量、TCN卷积核数量、GRU隐藏层神经元数量、批尺寸及学习率等，取训练时最优的结果并保存模型，进行测试。在实验中，编码器和解码器中都使用单层GRU，设置CNN卷积核个数为64，TCN的第1、第2层的卷积核个数设置为16和32，卷积核大小设置为3，扩张因子d选取为1和2。由于这些参数对实验结果的影响较小，故不需要进行大规模寻优。因为输入不同的历史航迹点p在模型训练时有不同的效果，合适的GRU隐藏层神经元个数m能更好地提取输入数据的隐藏特征，所以对关键超参数p和m进行网格化搜索，设定2个超参数的搜索范围分别为p={5,6,7,8,9,10}，m={16,32,64}，得到18种超参数组合模型下的验证集误差，图7为不同超参数组合下的验证集误差。最后选定的超参数p=7、m=32，因为GRU的隐藏层参数量很小，所以在训练中能提高模型的运算效率，同时，也能得到很高的精度。验证集误差越小说明模型收敛效果越好，预测值和真实值的差异越小。该模型最终的参数如表1所示。

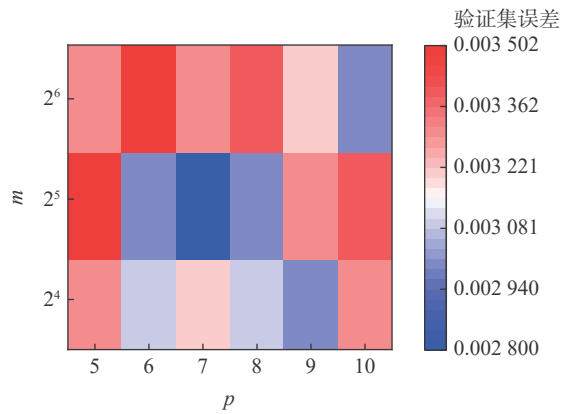


图7 不同超参数组合下的验证集误差

Fig. 7 Verification set error under different combinations of hyperparameters

表1 模型超参数优选结果

Table 1 Optimization results of model hyperparameter

TCN第1、第2层卷积核个数	TCN卷积核尺寸	TCN的膨胀系数	CNN卷积核个数	批尺寸	学习率	输入历史航迹点个数p	GRU隐藏层神经元个数	预测航迹点个数s
16、32	3	[1,2]	64	128	0.001	7	32	5

3.2 模型比较与分析

为检验GTA-Seq2Seq模型的有效性，将该模型与较为先进的航迹预测模型GRU模型[25]、Bi-GRU模型[26]、CNN-LSTM模型[15]、LSTM-ED模型[20]、STED模型[22]进行比较。为保证公平性，所有模型均采用了相同的训练集、验证集、测试集，将不同模型的最佳参数结果与该模型进行比较。为定量分析预测结果，本文采用均方根误差(root mean square error, RMSE)和平均绝对误差(mean absolute error, MAE)作为误差评价指标来判断航迹预测的准确性。RMSE和MAE计算式分别为

$$\eta_{\mathrm{RMSE}}=\sqrt{\sum_{t=1}^{N}\left(\left|\hat{\boldsymbol{Y}}_t\right|-\left|\boldsymbol{Y}_t\right|\right)^2/N} \tag{20}$$

$$\eta_{\mathrm{MAE}}=\sum_{t=1}^{N}\left|\left|\hat{\boldsymbol{Y}}_t\right|-\left|\boldsymbol{Y}_t\right|\right|/N \tag{21}$$

RMSE和MAE越小，预测效果越好。

测试集的对比结果如表2所示，在预测步数s为5的情况下每个航迹点的经度、纬度、高度的预测误差如图8所示。

从表2可以看出，本文模型在测试集上达到很好的精度(见表2中加粗部分)。经典模型GRU预测精度较低。Bi-GRU模型是基于GRU模型的双向RNN，使信息可以在时间序列的正反2个方向上进行传播，从而提高了模型对序列全局特征的捕捉能力，精度高于GRU模型。CNN-LSTM模型和LSTM-ED模型都是基于LSTM的混合模型，其中，CNN-LSTM模型使用CNN提取空间特征，LSTM提取时间特征，LSTM-ED模型结合了LSTM和编码器-解码器架构，而STED模型以编码器-解码器架构为基础提取时空特征，都具有较高的预测精度，但都低于GTA-Seq2Seq模型。GTA-Seq2Seq模

表 2　各模型预测误差比较

Table 2　Comparison of prediction errors of each model

模型	预测步数	经度RMSE/(°)	经度MAE/(°)	纬度RMSE/(°)	纬度MAE/(°)	高度RMSE/m	高度MAE/m	时间RMSE/s	时间MAE/s
GRU[25]	1	0.018 6	0.013 8	0.023 1	0.018 1	92.1	34.5	6.7	5.2
	2	0.037 0	0.027 2	0.046 3	0.036 3	202.1	76.6	11.2	8.3
	3	0.544 0	0.039 8	0.067 4	0.053 0	325.1	127.5	14.7	10.4
	4	0.071 4	0.052 8	0.087 1	0.068 9	435.3	179.9	18.1	12.5
	5	0.088 1	0.065 8	0.105 7	0.084 1	535.5	229.4	21.5	14.5
Bi-GRU[26]	1	0.015 7	0.012 6	0.015 1	0.011 8	91.1	33.9	5.6	4.4
	2	0.031 5	0.024 7	0.031 5	0.025 0	196.3	71.7	8.9	7.0
	3	0.048 3	0.037 2	0.049 0	0.039 1	306.8	118.2	11.5	8.9
	4	0.067 0	0.050 1	0.067 3	0.053 2	396.8	162.0	13.8	10.6
	5	0.087 2	0.063 4	0.086 6	0.067 2	467.3	201.7	15.7	12.3
CNN-LSTM[15]	1	0.013 2	0.009 8	0.016 5	0.012 7	96.8	47.7	6.7	5.5
	2	0.019 8	0.015 6	0.017 0	0.012 1	151.5	70.9	7.2	5.6
	3	0.027 1	0.020 8	0.022 6	0.016 8	206.4	94.1	8.1	5.8
	4	0.033 4	0.026 0	0.026 0	0.016 9	229.1	110.5	8.8	6.7
	5	0.041 7	0.032 7	0.033 8	0.022 8	243.7	119.2	9.7	7.7
LSTM-ED[20]	1	0.022 3	0.017 1	0.022 0	0.018 4	100.3	43.5	9.6	6.6
	2	0.031 2	0.022 7	0.028 3	0.018 1	186.1	74.8	14.9	10.2
	3	0.047 0	0.035 3	0.034 4	0.021 8	250.8	98.5	15.4	10.8
	4	0.062 6	0.047 9	0.037 8	0.024 8	277.1	115.6	16.7	11.0
	5	0.078 3	0.060 1	0.041 4	0.028 1	274.5	126.1	17.2	12.0
STED[22]	1	0.013 4	0.009 4	0.009 0	0.007 3	86.1	38.2	0.8	0.7
	2	0.018 2	0.011 7	0.015 5	0.010 6	123.6	50.9	1.2	0.9
	3	0.025 0	0.012 8	0.019 0	0.013 1	187.1	75.2	1.3	1.0
	4	0.033 0	0.016 4	0.022 4	0.015 3	224.2	90.2	1.4	1.1
	5	0.035 9	0.019 9	0.026 0	0.016 7	254.0	105.9	1.6	1.2
GTA-Seq2Seq	1	**0.007 7**	**0.005 7**	**0.005 6**	**0.003 6**	**65.8**	**28.5**	**0.7**	**0.5**
	2	**0.013 9**	**0.008 9**	**0.009 7**	**0.005 8**	**96.2**	**38.3**	**0.9**	**0.7**
	3	**0.017 5**	**0.011 5**	**0.013 3**	**0.007 7**	**119.3**	**47.5**	**1.0**	**0.7**
	4	**0.021 2**	**0.014 2**	**0.016 5**	**0.009 7**	**131.1**	**55.3**	**1.1**	**0.8**
	5	**0.025 9**	**0.017 5**	**0.019 7**	**0.011 7**	**136.6**	**58.3**	**1.4**	**1.1**

型第 5 步预测相较于 STED 模型的 RMSE 减小了 27.70%, MAE 减小了 23.82%, 且在训练过程中所需的参数量相较于 STED 模型减少了 67.42%。由图 8 可以看出, GTA-Seq2Seq 模型相较于其他对比模型, 在不同空间维度均取得了较小的误差, 进一步验证了 GTA-Seq2Seq 模型具有较好的性能。

此外, 由于在多步预测任务中误差积累不能完全避免, 表 2 中 5 个对比模型展现出预测误差随预测步数增加而逐渐累积的趋势, 但 GTA-Seq2Seq 模型在避免误差累积任务中取得更显著的优势, 因为在解码阶段进行预测时, GRU 模型是基于前一个时间步的输出、当前的隐藏状态和编码器生成的语义向量来生成当前时间步的输出, 改善了预测结果的误差累积。

为进一步验证本文方法的性能, 使用从西安飞往北京的 33 条航班数据来进行航迹预测实验。图 9 和图 10 展示了不同时间步长下各模型的预测误差, 可以看出 GTA-Seq2Seq 模型具有较好性能。

3.3　不同飞行状态下预测结果分析

本文通过对复杂飞行状态下的航班数据进行分析, 检验了 GTA-Seq2Seq 模型在不同飞行状态下的预测性能, 验证了其广泛适用性。图 11 为各模型在输入 7 个航迹点的历史轨迹后, 预测输出未来 5 个航迹点轨迹, 并在不同飞行状态下对比各模型预测航迹的三维曲线。

图 11 (a) 为飞机在下降转弯过程中预测曲线与真实曲线对比, 由于飞机在转弯处变换飞机姿态, GRU 模型、Bi-GRU 模型、CNN-LSTM 模型、LSTM-ED 模型、STED 模型这 5 个模型在预测时不能捕捉到飞机的转弯姿态, 尤其是 GRU 模型严重偏离真实航迹, 因为第 1 个航迹点偏差较大, 所以后面产生错误的航迹, 而 GTA-Seq2Seq 模型的预测曲线相

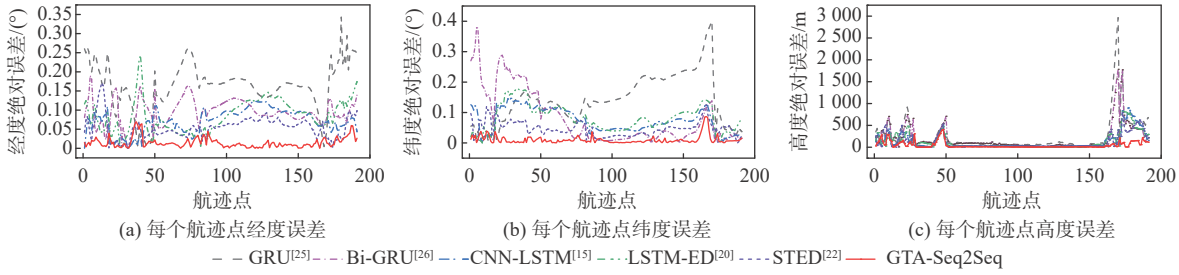


图 8 每个航迹点纬度、经度、高度的预测误差

Fig. 8 Forecast error of latitude, longitude and altitude for each trajectory point

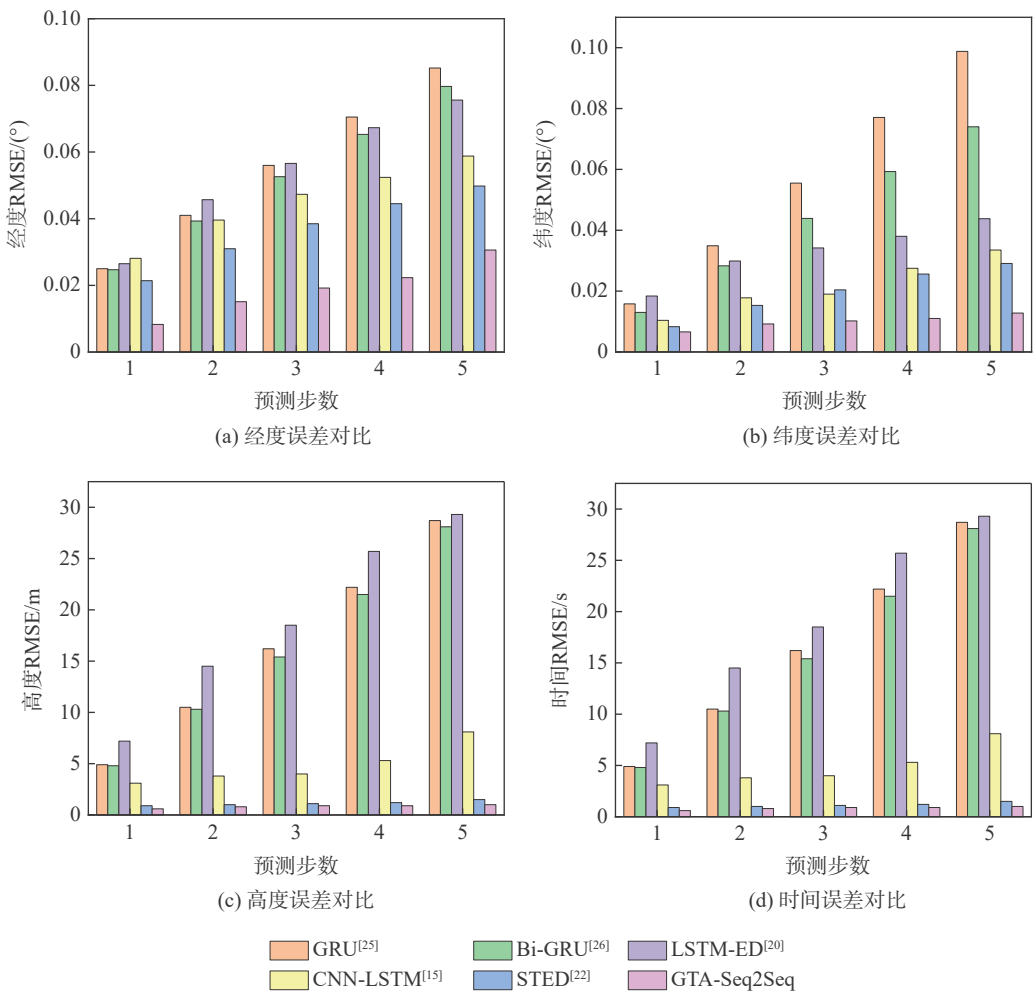


图 9 各模型 RMSE 比较(西安至北京)

Fig. 9 Comparison of RMSE of each model (Xian to Beijing)

较于其他 5 个模型,与真实曲线更加贴近,且在预测第 3、第 4 个航迹点时,该模型能很好地识别出转弯过程。图 11 (b) 展示了飞机在爬升转弯阶段的轨迹预测与真实航迹的比较。在这复杂的飞行场景中,其他 5 个模型均偏离真实航迹,尤其是 GRU 模型在预测时产生了错误的航迹点,没有识别出转弯的飞行意图,而 Bi-GRU 模型在第 4、第 5 个航迹点时预测高度快速上升,预测效果不好。因此,GTA-Seq2Seq 模型不仅能获取飞机在复杂场景中的飞行意图,而且能准确预测未来的飞行趋势,很好地完成了多步航迹预测任务。

综上所述,基于 GTA-Seq2Seq 的航迹预测模型表现出良好的性能,能准确反映未来飞行器的飞行情况,具有较低的预测误差。

3.4 消融实验

在不同模型对比实验中,已经验证了 GTA-Seq2Seq 模型的有效性。为深入探寻各个模块在整个模型中的作用,本节设计了消融实验。以编码器-解码器为基础模块,编码器中分别移除了提取基础航迹数据时序模式的 GRU 模块、TCN 模块和

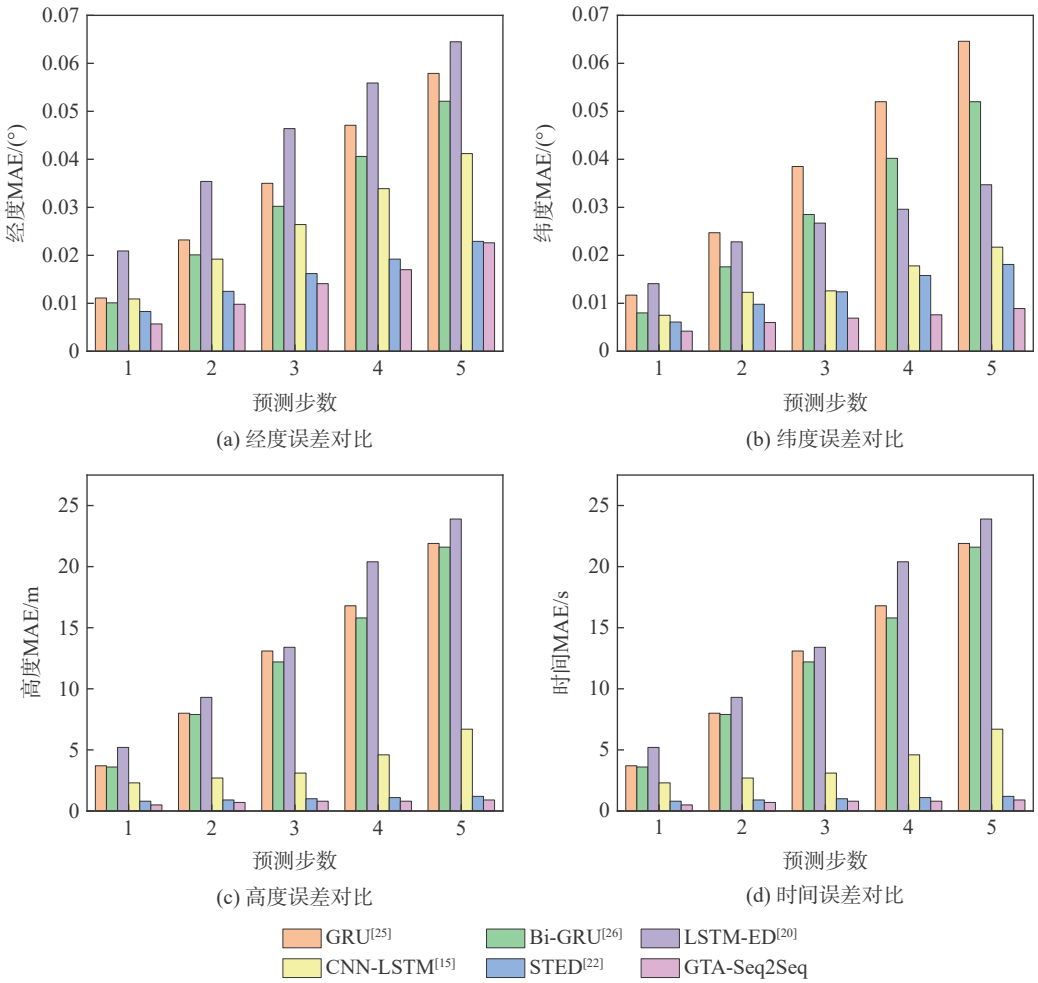


图 10　各模型 MAE 比较(西安至北京)

Fig. 10　Comparison of MAE of each model (Xian to Beijing)

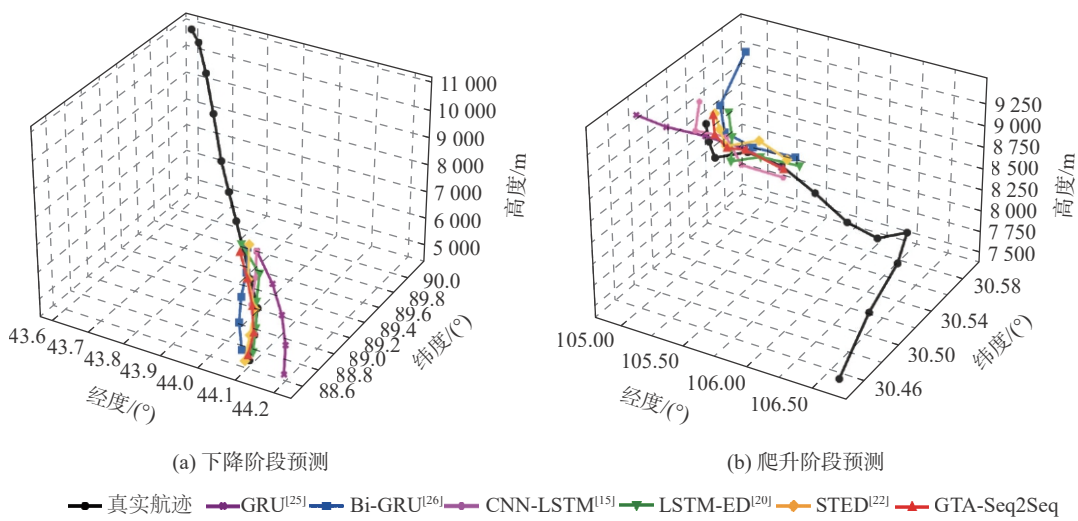


图 11　不同飞行状态下航迹误差比较

Fig. 11　Comparison of trajectory errors under different flight states

TPA 注意力机制模块, 解码器中移除了 FC 模块。所有的消融实验均在 p=7、s=5 的情况下进行, 并计算各个模型的 RMSE 和 MAE, 实验结果如表 3 所示, 加粗显示最优结果。

从表 3 可以看出, 无论移除哪个模块, 模型精度都会有一定的下降。进一步分析每个模块在整个模型中的作用。提取时间特征的 GRU 模块是为提取原始航迹数据中的时序模式。TCN 作为提取空间特征的基础模块, 能够有效地捕捉航迹数据的空间隐藏特征。在模型中引入 TPA 注意力机制, 考

表3 消融实验结果

Table 3 Results of ablation experiment

模型	预测步数	经度RMSE/(°)	经度MAE/(°)	纬度RMSE/(°)	纬度MAE/(°)	高度RMSE/m	高度MAE/m	时间RMSE/s	时间MAE/s
移除GRU模块的GTA-Seq2Seq	1	0.018 9	0.015 2	0.011 2	0.008 0	79.3	30.7	2.4	1.8
	2	0.021 4	0.016 5	0.016 3	0.010 5	120.6	43.8	2.7	2.0
	3	0.028 9	0.021 4	0.021 2	0.013 2	162.1	61.3	2.9	2.2
	4	0.034 2	0.023 9	0.025 2	0.016 0	191.5	76.9	3.0	2.3
	5	0.039 0	0.026 7	0.028 4	0.018 5	213.8	90.7	3.4	2.6
移除TCN模块的GTA-Seq2Seq	1	0.016 5	0.013 1	0.012 2	0.008 5	76.9	29.8	2.3	1.9
	2	0.023 6	0.016 6	0.017 8	0.011 5	137.7	53.4	2.4	2.0
	3	0.034 9	0.023 0	0.023 8	0.015 7	170.0	67.2	3.1	2.5
	4	0.044 8	0.028 7	0.029 4	0.020 3	182.4	76.4	3.9	3.1
	5	0.053 6	0.034 6	0.033 2	0.023 8	191.6	84.2	4.5	3.5
移除TPA模块的GTA-Seq2Seq	1	0.014 6	0.010 1	0.010 5	0.007 8	77.2	35.3	2.2	1.8
	2	0.016 1	0.011 4	0.015 5	0.011 9	117.7	45.6	2.3	1.9
	3	0.021 9	0.015 1	0.021 3	0.015 5	149.0	59.0	2.6	2.1
	4	0.027 6	0.019 2	0.025 9	0.018 4	169.9	73.3	2.9	2.3
	5	0.032 5	0.022 4	0.029 3	0.020 7	185.2	82.7	3.5	2.9
移除FC模块的GTA-Seq2Seq	1	0.015 6	0.010 7	0.011 0	0.007 5	77.5	38.6	2.5	1.9
	2	0.018 5	0.012 9	0.015 2	0.010 2	129.7	48.6	2.8	2.1
	3	0.020 5	0.014 9	0.019 0	0.012 2	147.0	64.5	3.0	2.3
	4	0.023 4	0.017 1	0.022 2	0.013 7	151.5	65.4	3.3	2.5
	5	0.028 3	0.020 2	0.024 9	0.015 1	158.6	68.5	3.5	2.7
GTA-Seq2Seq	1	**0.007 7**	**0.005 7**	**0.005 6**	**0.003 6**	**65.8**	**28.5**	**0.7**	**0.5**
	2	**0.013 9**	**0.008 9**	**0.009 7**	**0.005 8**	**96.2**	**38.3**	**0.9**	**0.7**
	3	**0.017 5**	**0.011 5**	**0.013 3**	**0.007 7**	**119.3**	**47.5**	**1.0**	**0.7**
	4	**0.021 2**	**0.014 2**	**0.016 5**	**0.009 7**	**131.1**	**55.3**	**1.1**	**0.8**
	5	**0.025 9**	**0.017 5**	**0.019 7**	**0.011 7**	**136.6**	**58.3**	**1.4**	**1.1**

虑不同特征对时间步的影响，通过对航迹数据在空间特征的全方面考虑，注意力机制能够更集中关注关键特征，忽略次要特征对模型训练过程的影响，进一步提高航迹预测性能。而解码器中FC通过线性变换将GRU提取的高维特征降维到实际的输出维度，确保模型能够生成对应于未来的航迹点具体数值。从消融实验结果看出，GTA-Seq2Seq的每个模块都在多步航迹预测中发挥着重要作用。此外，预测一个航迹点的平均耗时为0.03 s，远小于每个航迹点间隔60 s，证明GTA-Seq2Seq模型具有很好的实时性。

4 结 论

本文基于编码器-解码器架构，将GRU、TCN、TPA注意力机制多模块协同工作，提出了GTA-Seq2Seq航迹预测模型，该模型能够充分提取时空特征，实现高精度的航迹预测。通过实验验证本文模型的有效性，主要结论如下：

1）以编码器-解码器架构为基础改进的Seq2Seq结构通过GRU捕捉航迹数据中的时间依赖性。TCN-GRU提取航迹数据中的复杂空间特征，充分挖掘了航迹数据中飞机的运动规律。

2）提取空间特征时通过TPA注意力机制考虑不同特征的重要程度，可增加对关键特征的关注度，提高了模型预测的准确性。

3）在解码部分考虑了整个输入序列的信息，并通过迭代生成的方式输出序列，可缓解多步预测中误差随预测步长增加而带来的不稳定问题。

4）GTA-Seq2Seq模型与现有较为先进的航迹模型GRU模型、Bi-GRU模型、CNN-LSTM模型、LSTM-ED模型、STED模型的对比表明，GTA-Seq2Seq模型具有更好的预测能力，尤其是在复杂飞行场景中。

在未来工作中，可以加入速度、航向角、俯仰角等信息，进一步提取更多隐藏特征，同时，构建参数较少且精度更高的航迹预测模型。

参考文献（References）

[1] 中国民用航空局, 国家发展和改革委员会, 交通运输部. 中国民用航空发展第十三个五年规划[EB/OL]. (2017-04-05)[2024-08-28]. http://www.caac.gov.cn/XXGK/XXGK/FZGH/201704/t201704

05_43502.html.
Civil Aviation Administration of China, National Development and Reform Commission, Ministry of Transport. The 13th five-year plan for the development of civil aviation in China[EB/OL]. (2017-04-05)[2024-08-28]. http://www.caac.gov.cn/XXGK/XXGK/FZGH/201704/t20170405_43502.html(in Chinese).

[2] Ramasamy S, Sabatini R, Gardi A, et al. Next generation flight management system for real-time trajectory based operations[J]. Applied Mechanics and Materials, 2014, 629: 344-349.

[3] Zeng W L, Chu X, Xu Z F, et al. Aircraft 4D trajectory prediction in civil aviation: a review[J]. Aerospace, 2022, 9(2): 91.

[4] Hao S Q, Cheng S W, Zhang Y P. A multi-aircraft conflict detection and resolution method for 4-dimensional trajectory-based operation[J]. Chinese Journal of Aeronautics, 2018, 31(7): 1579-1593.

[5] 中国民用航空局空中交通管理局. 中国民航基于航迹运行(TBO)的推进进展: WP/462[EB/OL]. 2022[2026-10-18]. https://www.icao.int/sites/default/files/Meetings/a41/Documents/WP/wp_462_zh.pdf.
Air Traffic Management Bureau of Civil Aviation Administration of China. Progress of China civil aviation on trajectory-based operations(TBO): WP/462[EB/OL]. 2022[2026-10-18]. https://www.icao.int/sites/default/files/Meetings/a41/Documents/WP/wp_462_zh.pdf (in Chinese).

[6] Liu C Y, Zheng Q, Chang J C, et al. Summary and outlook of 4D track prediction methods[J]. Journal of Mechanical Engineering, Automation and Control Systems, 2020, 1(1): 46-55.

[7] 彭瑛, 胡明华, 张颖. 动态航迹推测方法[J]. 交通运输工程学报, 2005, 5(1): 61-65.
Peng Y, Hu M H, Zhang Y. Conjecture method of dynamic flying track[J]. Journal of Traffic and Transportation Engineering, 2005, 5(1): 61-65(in Chinese).

[8] 汤新民, 李腾, 陈强超, 等. 基于交互式多模型的短期 4D 航迹预测[J]. 武汉理工大学学报 (交通科学与工程版), 2020, 44(1): 39-45.
Tang X M, Li T, Chen Q C, et al. Short-term 4D trajectory prediction based on interactive multi-models[J]. Journal of Wuhan University of Technology (Transportation Science & Engineering), 2020, 44(1): 39-45(in Chinese).

[9] Wu Z J, Tian S, Ma L. A 4D trajectory prediction model based on the BP neural network[J]. Journal of Intelligent Systems, 2019, 29(1): 1545-1557.

[10] Shi Z Y, Xu M, Pan Q, et al. LSTM-based flight trajectory prediction[C]//Proceedings of the 2018 International Joint Conference on Neural Networks. Piscataway: IEEE Press, 2018: 1-8.

[11] Sahadevan D, M H P, Ponnusamy P, et al. Ground-based 4d trajectory prediction using bi-directional LSTM networks[J]. Applied Intelligence, 2022, 52(14): 16417-16434.

[12] 石庆研, 岳聚财, 韩萍, 等. 基于 LSTM-ARIMA 模型的短期航班飞行轨迹预测[J]. 信号处理, 2019, 35(12): 2000-2009.
Shi Q Y, Yue J C, Han P, et al. Short-term flight trajectory prediction based on LSTM-ARIMA model[J]. Journal of Signal Processing, 2019, 35(12): 2000-2009(in Chinese).

[13] Han P, Wang W Q, Shi Q Y, et al. A combined online-learning model with K-means clustering and GRU neural networks for trajectory prediction[J]. Ad Hoc Networks, 2021, 117: 102476.

[14] 韩萍, 张启, 石庆研, 等. 基于 DBSCAN-GRU 算法的终端区 4D 航迹预测[J]. 信号处理, 2023, 39(3): 439-449.
Han P, Zhang Q, Shi Q Y, et al. 4D trajectory prediction of terminal area based on DBSCAN-GRU algorithm[J]. Journal of Signal Processing, 2023, 39(3): 439-449(in Chinese).

[15] Ma L, Tian S. A hybrid CNN-LSTM model for aircraft 4D trajectory prediction[J]. IEEE Access, 2020, 8: 134668-134680.

[16] Bai S J, Kolter J Z, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [EB/OL]. (2018-04-19)[2024-08-28]. https://doi.org/10.48550/arXiv.1803.01271.

[17] 焦卫东, 杨蓓. 一种融合 MSC 和时空双重注意力的 TCN 航迹预测方法[J]. 北京航空航天大学学报, 2026, 52(1): 15-27.
Jiao W D, Yang B. TCN trajectory prediction method fusing MSC and spatio-temporal dual attention[J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(1): 15-27(in Chinese).

[18] 卢婷婷, 刘博, 李纯柱. 基于注意力 Seq2Seq 模型的终端区航空器航迹预测[J]. 科学技术与工程, 2024, 24(9): 3882-3895.
Lu T T, Liu B, Li C Z. Aircraft trajectory prediction within terminal area based on Seq2Seq-attention model[J]. Science Technology and Engineering, 2024, 24(9): 3882-3895(in Chinese).

[19] Tran P N, Nguyen H Q V, Pham D T, et al. Aircraft trajectory prediction with enriched intent using encoder-decoder architecture[J]. IEEE Access, 2022, 10: 17881-17896.

[20] Zeng W L, Quan Z B, Zhao Z Y, et al. A deep learning approach for aircraft trajectory prediction in terminal airspace[J]. IEEE Access, 2020, 8: 151250-151266.

[21] Zhang Z, Guo D Y, Zhou S Z, et al. Flight trajectory prediction enabled by time-frequency wavelet transform[J]. Nature Communications, 2023, 14: 5258.

[22] 石庆研, 张泽中, 韩萍. 基于时空特征融合的 Encoder-Decoder 多步 4D 短期航迹预测[J]. 信号处理, 2023, 39(11): 2037-2048.
Shi Q Y, Zhang Z Z, Han P. Multi-step 4D short-term trajectory prediction using encoder-decoder with spatio-temporal features fusion[J]. Journal of Signal Processing, 2023, 39(11): 2037-2048(in Chinese).

[23] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.

[24] Chung J, Gulcehre C, Cho K, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[EB/OL]. (2014-12-11)[2024-08-28]. https://arxiv.org/abs/1412.3555(in Chinese).

[25] 王文青. GRU 神经网络在航迹预测中的研究与应用[D]. 天津: 中国民航大学, 2021.
Wang W Q. Research and application of GRU neural network in trajectory prediction[D]. Tianjin: Civil Aviation University of China, 2021(in Chinese).

[26] Chen Z X, Wang L. Aircraft trajectory prediction model based on improved GRU structure[C]//Proceedings of the 2023 3rd International Conference on Consumer Electronics and Computer Engineering. Piscataway: IEEE Press, 2023: 225-228.

GTA-Seq2Seq multi-step 4D trajectory prediction model based on spatio-temporal feature extraction

SHI Qingyan，ZHAO Wantong，HAN Ping*

(Tianjin Key Laboratory for Advanced Signal Processing，Civil Aviation University of China，Tianjin 300300，China)

Abstract：Real-time flight path correction, conflict avoidance, and increased flight safety are all made possible by high-precision multi-step trajectory prediction. Traditional models usually face problems such as low multi-step prediction accuracy and difficulty in capturing the nonlinear relationship between spatial and temporal features in flight trajectories. Therefore, this paper proposes a multi-step 4D trajectory prediction model GTA-Seq2Seq that uses a gate recurrent unit (GRU), temporal convolutional network (TCN) and temporal pattern attention (TPA) mechanism in a sequence-to-sequence (Seq2Seq) model. The model is divided into an encoder part and a decoder part. The encoder extracts the time dependence in trajectory data by using GRU and combines the TCN-GRU network to extract the spatial features of trajectory data. To accomplish high-precision multi-step trajectory prediction, the spatial and temporal information are concatenated in the decoder section and sent into GRU. The experiment shows that the proposed model outperforms traditional models in terms of prediction accuracy. The fifth step prediction in the model reduces the root mean square error (RMSE) by 27.70% and the mean absolute error (MAE) by 23.82% compared to the optimal model—spatio-temporal encoder-decoder (STED) among the comparison models. In addition, the required number of parameters of the GTA-Seq2Seq model in the training process is reduced by 67.42% compared to STED model, improving the operational efficiency of the model.

Keywords：trajectory prediction；spatio-temporal features；temporal convolutional network；attention mechanism；encoder-decoder；sequence-to-sequence model

Received：2024-09-18；**Accepted**：2024-11-22；**Published Online**：2024-12-20 13：04

URL：link.cnki.net/urlid/11.2625.V.20241219.1708.001

Foundation item：Civil Aviation Safety Capacity Building Funds (KJZ49420210082)

* **Corresponding author**. E-mail：hanpingcauc@163.com

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0746

空间机动目标跟踪任务中IMM算法的稳态增强设计

张世源*，卢山，李晴
(上海航天控制技术研究所，上海 201109)

摘 要：用于跟踪空间非合作机动目标的相对导航技术旨在实时获取目标精确的轨道信息，提升航天器对于目标轨道机动的快速感知与精准决策能力，是航天器追逃博弈的基础。在目标机动序列未知的情况下，研究用以估计两星间相对运动状态的交互多模型（IMM）算法，构建了以无机动模型、匀加速机动模型、大偏差响应模型为子模型的IMM模型集。在此基础上，研究目标处于某一特定机动模式稳定运动（稳态模式）时影响IMM算法性能的因素，推导得到了稳态模式下匹配模型权值（稳态权值）的平衡点表达式，给出了稳态权值围绕平衡点震荡的变化规律，并由此阐明了模型转移概率、模型似然比对稳态权值大小及量测噪声敏感程度的影响机理，为IMM算法的稳态性能优化提供了理论依据。在上述分析的基础上，结合给定时间窗口内模型权值的发展趋势对模型转移概率进行实时修正，提出了稳态增强IMM（ES-IMM）算法。在空间机动目标跟踪过程中，ES-IMM算法能够提升稳态模式下匹配模型的权值，同时对量测噪声影响下的权值跳变进行抑制，增强IMM算法的稳态估计性能。仿真结果表明：在空间机动目标跟踪任务中的稳态区间，ES-IMM算法的估计精度明显优于传统IMM算法。

关 键 词：非合作航天器；机动目标跟踪；相对导航；交互多模型；卡尔曼滤波
中图分类号：V448.2
文献标志码：A **文章编号**：1001-5965(2026)11-3907-11

随着空间态势感知、空间博弈等新型太空任务的出现，对非合作机动目标相对运动状态的估计、跟踪、预测成为了当下的研究热点[1-4]。针对机动航天器的跟踪技术旨在提供更清晰的空间态势视图，并在目标轨道被人为改变(如发生异常接近或逃逸)时具有快速感知和反应的能力，是航天器进行轨道博弈、执行追逃策略的基础。

目前，实时跟踪空间目标的主要方法是基于相对传感器(光学相机、激光雷达等)实时获取与目标间的相对量测数据，通过数据融合与处理算法对目标的可观测及不可观测状态进行在线估计，从而实现相对导航。卡尔曼滤波器(Kalman filter, KF)[5-6]是该类研究的首选，扩展卡尔曼滤波(extended Kalman filter, EKF)[7-8]通过一阶泰勒级数近似将非线性连续动态系统近似为线性模型，将KF的应用范围扩展到非线性系统。上述传统滤波方法能够精确估计机动序列已知的合作航天器轨道状态[9-11]。由于非合作目标的机动序列未知，当目标在未知的时间和推力下进行多次机动时，传统滤波算法的跟踪性能会因为动态模型与实际机动之间的不匹配而下降，进而造成目标丢失。

交互多模型(interacting multiple model, IMM)算法[12-14]利用多个子模型描述目标的潜在运动状态，通过实时调整各子模型的权重来匹配目标在机动过程中的状态变化，克服了传统单模型滤波方法的局限性。IMM算法的核心内容可分为2个层面：构成模型集的子模型选择及各子模型间的信息交互过程设计。

收稿日期：2024-10-15；**录用日期**：2024-12-20；**网络出版时间**：2024-12-27 18:45
网络出版地址：link.cnki.net/urlid/11.2625.V.20241227.1300.003
*通信作者. E-mail：1663085217@qq.com

引用格式：张世源，卢山，李晴. 空间机动目标跟踪任务中IMM算法的稳态增强设计[J]. 北京航空航天大学学报，2026，52(11)：3907-3917. Zhang S Y，Lu S，Li Q. Steady-state enhancement design of IMM algorithm for space maneuvering target tracking[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3907-3917 (in Chinese).

在子模型选择层面，针对航天器的机动模式，全面、精炼地构建模型集是成功应用IMM算法的关键。Goff等[15]利用常值加速度(constant acceleration, CA)模型对目标的连续推力机动进行估计，并通过设置大小不同的过程噪声矩阵，在提升误差收敛速度的同时避免较大的过程噪声对加速度估计精度的影响，但该方法在目标处于无机动状态时的状态估计精度较低；Yin等[16]利用当前统计加加速度模型CS-Jerk(current statistics Jerk)对目标加速度模型的变化率进行建模，用以跟踪执行高强度机动的目标，但考虑到航天器的机动能力远低于飞机、导弹等航空器，该方法并不能有效提升模型精度，反而会显著增加计算成本；Goff等[17]分析了目标发生大小不同的脉冲机动时，KF估计误差跳变后重新收敛所需的最优协方差矩阵膨胀因子，并在此基础上选取一组膨胀因子作为模型集，以应对目标发生未知大小的脉冲机动，但该方法只能针对无机动和脉冲机动2种情况进行估计，无法处理目标发生连续推力机动的情况。

在信息交互过程层面，基于导航系统特性对传统IMM算法的数据融合过程进行改进，是进一步提升IMM算法性能的研究重点。Arroyo Cebeira等[18]针对子模型似然值高度不确定引起算法收敛慢的问题，通过量测值与量测预测值之间的马氏距离对模型转移概率[19]进行调整，以实现目标机动模式切换时算法的快速响应；Xie等[20]利用不同模型的似然值之比对目标机动模式的切换进行判定，改善了IMM算法的响应滞后现象。但上述算法均仅针对目标机动模式发生切换时IMM算法的动态响应能力进行优化，未对目标在某一特定机动模式下稳定运行(稳态模式)时IMM算法的估计精度(稳态性能)进行改进。

目前，对于IMM算法稳态性能的研究仍以定性分析为主。Xie等[20]指出量测噪声会影响稳态模式下模型权值(稳态权值)的稳定性，并试图通过引入过去时刻的模型信息来削弱这一影响；文献[21-23]基于马尔可夫过程对系统进行分析，认为引入上一时刻的后验信息对模型转移概率进行修正，能够使系统更好地反映真实状态。但上述研究均未能从数学证明的角度理清影响IMM算法稳态性能的关键因素，同时，也未通过理论推导阐明所提出的改进措施对于最终估计结果的作用机理，在一定程度上影响了该类算法的优化效果。

针对上述问题，本文进行的研究包含：在子模型选择层面，构建了包含无机动模型、均加速机动模型、大偏差响应模型在内的空间机动目标相对运动模型集，具备跟踪空间目标多种机动模式及状态突变的能力；在信息交互过程层面，给出了稳态权值的变化规律及其平衡点的数学表达式，并据此分析了影响IMM算法稳态性能的主要因素，提出了权值优化方案及其理论依据，得到一种稳态增强IMM(enhanced steady-state IMM, ES-IMM)算法。仿真结果表明，相较传统的IMM算法，ES-IMM算法的稳态估计性能显著提升。

1 模型集构建

1.1 相对运动状态方程

综合考虑模型精度与计算复杂度，为使IMM模型集在涵盖航天器相对运动状态包络的前提下尽可能精简，将当前航天器的在轨运动状态分为无机动模式、匀加速机动模式、变加速机动模式及不同机动模式之间发生切换时的状态突变。

文献[17]的模型集构建方式能够较好地跟踪目标状态突变，但不具备连续推力机动作用下的目标跟踪能力；文献[24]的模型集构建方式能够较好地跟踪处于无机动模式与匀加速机动模式的航天器，但对于目标状态突变与模型偏差的响应能力较差。由于航天器机动能力有限，轨道机动过程中机动加速度通常不会发生剧烈变化[25]，综合考虑上述文献所用模型集的优缺点，使用以下3类模型构建IMM模型集。

1.1.1 无机动模型

由于具备机动能力的空间非合作目标的轨道状态未知，以追踪星质心为原点建立航天器第二轨道坐标系，其中，z轴指向地心，x轴在轨道平面内垂直于z轴并指向航天器飞行方向，y轴与x轴和z轴构成右手直角坐标系。考虑目标未发生轨道机动的情况，当两星间距远小于追踪星轨道半径时，在近圆轨道假设下，两星的轨道相对运动方程能够线性近似为C-W方程[26]。C-W方程能够以较高精度匹配目标无机动模式下的两星相对状态，表示为

$$\dot{\boldsymbol{x}}_1=\boldsymbol{A}_1\boldsymbol{x}_1+\boldsymbol{B}_1\boldsymbol{u}_{\mathrm{C}}+\boldsymbol{w}_1 \tag{1}$$

式中：状态变量$\boldsymbol{x}_1=\left[x,y,z,\dot{x},\dot{y},\dot{z}\right]^{\mathrm{T}}$为目标星在追踪星轨道坐标系下的位置和速度；

$$\boldsymbol{A}_1=\begin{bmatrix}\boldsymbol{0}_{3\times3} & \boldsymbol{I}_{3\times3}\\ \begin{matrix}0&0&0\\0&-\omega^2&0\\0&0&3\omega^2\end{matrix} & \begin{matrix}0&0&2\omega\\0&0&0\\-2\omega&0&0\end{matrix}\end{bmatrix},\ \omega=\sqrt{\mu/R_{\mathrm{C}}^3}$$

为追踪星轨道角速度，R_{C}为追踪星轨道半径，μ为地球引力常数；$\boldsymbol{B}_1=\begin{bmatrix}\boldsymbol{0}_{3\times3} & \boldsymbol{I}_{3\times3}\end{bmatrix}^{\mathrm{T}}$；$\boldsymbol{u}_{\mathrm{C}}$为追踪星的控制加速度；$\boldsymbol{w}_1$为摄动力和模型误差引起的噪声，其协方差矩阵为$\boldsymbol{Q}_1$。

其离散状态空间表达式为

$$\boldsymbol{x}_{1,k}=\boldsymbol{\Phi}_1\boldsymbol{x}_{1,k-1}+\boldsymbol{\Gamma}_1\boldsymbol{u}_{\mathrm{C},k}+\boldsymbol{w}_{1,k} \tag{2}$$

式中: $\boldsymbol{\Phi}_1 \in \mathbf{R}^{6\times6}$为系统的状态转移矩阵; $\boldsymbol{\Gamma}_1 \in \mathbf{R}^{6\times3}$为系统的控制矩阵; 下标 k 表示 k 时刻。

1.1.2　匀加速机动模型

考虑目标执行常值连续推力下发生匀加速机动的情况, 将目标机动加速度 $\boldsymbol{u}_{\mathrm{T}}=\left[u_x,u_y,u_z\right]^{\mathrm{T}}$纳入状态变量, 即令 $\boldsymbol{x}_2=\left[x,y,z,\dot{x},\dot{y},\dot{z},u_x,u_y,u_z\right]^{\mathrm{T}}$。匀加速模型能够以较高精度匹配目标匀加速机动模式下的两星相对状态, 表示为

$$\dot{\boldsymbol{x}}_2=\boldsymbol{A}_2\boldsymbol{x}_2+\boldsymbol{B}_2\boldsymbol{u}_{\mathrm{C}}+\boldsymbol{w}_2 \tag{3}$$

式中: $\boldsymbol{A}_2=\left[\begin{array}{c|c}\boldsymbol{A}_1 & \boldsymbol{0}_{3\times3}\\ \hline & \boldsymbol{I}_{3\times3}\\ \hline \boldsymbol{0}_{3\times9} & \end{array}\right]$; $\boldsymbol{B}_2=\left[\boldsymbol{0}_{3\times3}\quad\boldsymbol{I}_{3\times3}\quad\boldsymbol{0}_{3\times3}\right]^{\mathrm{T}}$; $\boldsymbol{w}_2$为摄动力和模型误差引起的噪声, 其协方差矩阵为$\boldsymbol{Q}_2$。

其离散状态空间表达式为

$$\boldsymbol{x}_{2,k}=\boldsymbol{\Phi}_2\boldsymbol{x}_{2,k-1}+\boldsymbol{\Gamma}_2\boldsymbol{u}_{\mathrm{C},k}+\boldsymbol{w}_{2,k} \tag{4}$$

式中: $\boldsymbol{\Phi}_2\in\mathbf{R}^{9\times9}$为系统的状态转移矩阵, 且有 $\boldsymbol{A}_2=\left[\begin{array}{c|c|c}\boldsymbol{\Phi}_1 & \boldsymbol{\Phi}^{\mathrm{ra}} & \\ \hline & \boldsymbol{\Phi}^{\mathrm{rv}} & \\ \hline \boldsymbol{0}_{3\times6} & & \boldsymbol{I}_{3\times3}\end{array}\right]$; $\boldsymbol{\Gamma}_2\in\mathbf{R}^{9\times3}$为系统的控制矩阵。

其中,

$$\boldsymbol{\Phi}^{\mathrm{rv}}=\left[\begin{array}{cc}\boldsymbol{I}_{3\times3} & \boldsymbol{0}_{3\times3}\end{array}\right]\boldsymbol{\Phi}_{1,k}\left[\begin{array}{cc}\boldsymbol{0}_{3\times3} & \boldsymbol{I}_{3\times3}\end{array}\right]^{\mathrm{T}} \tag{5}$$

$$\boldsymbol{\Phi}^{\mathrm{ra}}=\left[\begin{array}{ccc}\dfrac{4-4\cos(\omega T)}{\omega^2}-\dfrac{3T^2}{2} & 0 & \dfrac{2T}{\omega}-\dfrac{2\sin(\omega T)}{\omega^2}\\ 0 & \dfrac{1-\cos(\omega T)}{\omega^2} & 0\\ \dfrac{2T}{\omega}-\dfrac{2\sin(\omega T)}{\omega^2} & 0 & \dfrac{1-\cos(\omega T)}{\omega^2}\end{array}\right] \tag{6}$$

式中: T为系统采样周期。

1.1.3　大偏差响应模型

目标处于变加速机动模式或机动模式切换状态时, 上述 2 类模型将严重偏离真实系统, 使算法无法准确估计目标状态。针对该类情况, 渐消卡尔曼滤波器(fading Kalman filter, FKF)[26-27]通过增大 KF 中状态预测协方差矩阵的取值, 提升当前量测数据在最终估计结果中的占比, 进而在模型失配的情况下保持对目标的跟踪。但该算法主要针对滤波过程中的参数变化进行调整, 而非对系统模型进行改进, 不适用于 IMM 算法模型集的构建。基于上述原因, 在匀加速机动模型的基础上引入较大的加速度过程噪声构成大偏差响应模型, 用于描述算法对于目标机动模式估计严重偏离真实系统的情况, 即可达到与 FKF 相同的效果。记该过程噪声为 $\boldsymbol{w}_3$, 对应的协方差矩阵为$\boldsymbol{Q}_3$, 满足

$$q_3^{ij}\gg q_2^{ij}\qquad i=j=7,8,9 \tag{7}$$

式中: q^{ij}表示矩阵$\boldsymbol{Q}$第 i 行 j 列的元素; 下标 2、3 分别表示匀加速机动模型、大偏差响应模型。

则模型 3 的相对运动状态方程可表示为

$$\dot{\boldsymbol{x}}_3=\boldsymbol{A}_3\boldsymbol{x}_3+\boldsymbol{B}_3\boldsymbol{u}_{\mathrm{C}}+\boldsymbol{w}_3 \tag{8}$$

式中: 状态变量 $\boldsymbol{x}_3=\left[x,y,z,\dot{x},\dot{y},\dot{z},u_x,u_y,u_z\right]^{\mathrm{T}}$; $\boldsymbol{A}_3=\boldsymbol{A}_2$; $\boldsymbol{B}_3=\boldsymbol{B}_2$。

其离散状态空间表达式为

$$\boldsymbol{x}_{3,k}=\boldsymbol{\Phi}_3\boldsymbol{x}_{3,k-1}+\boldsymbol{\Gamma}_3\boldsymbol{u}_{\mathrm{C},k}+\boldsymbol{w}_{3,k} \tag{9}$$

式中: $\boldsymbol{\Phi}_3=\boldsymbol{\Phi}_2$; $\boldsymbol{\Gamma}_3=\boldsymbol{\Gamma}_2$。

1.2　量测方程

定义观测量:

$$\left[\begin{array}{c}\rho\\ \beta\\ \alpha\end{array}\right]=\left[\begin{array}{c}\sqrt{x^2+y^2+z^2}\\ \arcsin\left(\dfrac{-z}{\sqrt{x^2+y^2+z^2}}\right)\\ \arctan\left(\dfrac{y}{x}\right)\end{array}\right] \tag{10}$$

式中: ρ、α和β分别为目标星相对追踪星的视线距、方位角和高低角。

建立观测方程:

$$\boldsymbol{z}_k=h(\boldsymbol{x}_k)+\boldsymbol{v}_k=\left[\begin{array}{c}\sqrt{x_k^2+y_k^2+z_k^2}\\ \arcsin\left(\dfrac{-z_k}{\sqrt{x_k^2+y_k^2+z_k^2}}\right)\\ \arctan\left(\dfrac{y_k}{x_k}\right)\end{array}\right]+\boldsymbol{v}_k \tag{11}$$

式中: $\boldsymbol{z}_k$为量测值; $h(\cdot)$为观测方程中的非线性函数; $\boldsymbol{v}_k$为量测噪声, 其协方差矩阵为$\boldsymbol{R}'$。

2　标准 IMM 算法

标准 IMM 算法包含模型输入交互、模型估计、模型权值更新和输出交互 4 部分, 从$k-1$时刻到k时刻的算法递推过程如下。由于模型集中有$r=3$个模型, 故滤波器采用 3 个 EKF 滤波器, 记为$E_m(m=1,2,3)$。

1) 输入交互。$k-1$时刻模型 j 的预测概率为

$$\bar{c}_j=\sum_{i=1}^{r}p_{ij}\mu_{i,k-1} \tag{12}$$

式中: p_{ij}表示从模型 i 到模型 j 的模型交互概率; $\mu_{i,k-1}$为$k-1$时刻模型 i 的发生概率。

计算$k-1$时刻模型 i 到模型 j 的混合概率:

$$\mu_{ij,k-1}=p_{ij}\mu_{i,k-1}/\bar{c}_j \tag{13}$$

设$k-1$时刻滤波器 $i(i=1,2,\cdots,r)$的状态估计值为$\hat{\boldsymbol{x}}_{i,k-1}$, 相应协方差矩阵为$\boldsymbol{P}_{i,k-1}$, 则交互计算后模型$j(j=1,2,\cdots,r)$的混合状态估计和相应的协方差矩阵分别为

$$\hat{\boldsymbol{x}}_{0j,k-1}=\sum_{i=1}^{r}\mu_{ij,k-1}\hat{\boldsymbol{x}}_{i,k-1} \tag{14}$$

$$\boldsymbol{P}_{0j,k-1}=\sum_{i=1}^{r}\mu_{ij,k-1}\left[\boldsymbol{P}_{i,k-1}+\left(\hat{\boldsymbol{x}}_{i,k-1}-\hat{\boldsymbol{x}}_{0j,k-1}\right)\left(\hat{\boldsymbol{x}}_{i,k-1}-\hat{\boldsymbol{x}}_{0j,k-1}\right)^{\mathrm{T}}\right] \tag{15}$$

2）模型估计。将$\hat{\boldsymbol{x}}_{0j,k-1}$和$\boldsymbol{P}_{0j,k-1}$作为输入代入滤波器中，更新$k$时刻的状态估计值$\hat{\boldsymbol{x}}_{j,k}$和协方差矩阵$\boldsymbol{P}_{j,k}$，具体计算流程如下：

$$\begin{cases}\hat{\boldsymbol{x}}_{j,k|k-1}=\boldsymbol{\Phi}_{j,k}\hat{\boldsymbol{x}}_{0j,k-1}\\ \boldsymbol{P}_{j,k|k-1}=\boldsymbol{\Phi}_{j,k-1}\boldsymbol{P}_{0j,k-1}\boldsymbol{\Phi}_{j,k-1}^{\mathrm{T}}+\boldsymbol{Q}_j\\ \boldsymbol{H}_{j,k}=\left.\dfrac{\partial h(\boldsymbol{x})}{\partial \boldsymbol{x}^{\mathrm{T}}}\right|_{\boldsymbol{x}=\hat{\boldsymbol{x}}_{j,k|k-1}}\\ \boldsymbol{S}_{j,k}=\boldsymbol{H}_{j,k}\boldsymbol{P}_{j,k|k-1}\boldsymbol{H}_{j,k}^{\mathrm{T}}+\boldsymbol{R}_k'\\ \boldsymbol{K}_{j,k}=\boldsymbol{P}_{j,k|k-1}\boldsymbol{H}_{j,k}^{\mathrm{T}}\boldsymbol{S}_{j,k}^{-1}\\ \boldsymbol{v}_{j,k}=\boldsymbol{z}_k-h\left(\hat{\boldsymbol{x}}_{j,k|k-1}\right)\\ \hat{\boldsymbol{x}}_{j,k}=\hat{\boldsymbol{x}}_{j,k|k-1}+\boldsymbol{K}_{j,k}\boldsymbol{v}_{j,k}\\ \boldsymbol{P}_{j,k}=\left(\boldsymbol{I}-\boldsymbol{K}_{j,k}\boldsymbol{H}_{j,k}\right)\boldsymbol{P}_{j,k|k-1}\end{cases} \tag{16}$$

式中：$\hat{\boldsymbol{x}}_{j,k|k-1}$为状态预测值；$\boldsymbol{P}_{j,k|k-1}$为状态预测协方差矩阵；$\boldsymbol{H}_{j,k}$为观测方程雅可比矩阵；$\boldsymbol{S}_{j,k}$为残差协方差矩阵；$\boldsymbol{K}_{j,k}$为增益矩阵；$\boldsymbol{v}_{j,k}$为残差。

3）模型权值更新。假设模型j的残差$\boldsymbol{v}_{j,k}$服从高斯分布，可以利用模型似然函数$\Lambda_{j,k}$来更新模型权值$\mu_{j,k}$，更新式为

$$\Lambda_{j,k}=\frac{1}{\sqrt{\left|2\pi\boldsymbol{S}_{j,k}\right|}}\exp\left(-\frac{1}{2}\boldsymbol{v}_{j,k}^{\mathrm{T}}\boldsymbol{S}_{j,k}^{-1}\boldsymbol{v}_{j,k}\right) \tag{17}$$

$$\mu_{j,k}=\frac{1}{c}\Lambda_{j,k}\bar{c}_j \tag{18}$$

式中：c为归一化常数，且$c=\sum_{i=1}^{r}\Lambda_{i,k}\bar{c}_i$。

4）输出交互。基于更新的模型权值，加权融合各模型的状态滤波值，得到k时刻的状态估计值$\hat{\boldsymbol{x}}_k$及其协方差矩阵$\boldsymbol{P}_k$：

$$\hat{\boldsymbol{x}}_k=\sum_{j=1}^{r}\mu_{j,k}\hat{\boldsymbol{x}}_{j,k} \tag{19}$$

$$\boldsymbol{P}_k=\sum_{j=1}^{r}\mu_{j,k}\left[\boldsymbol{P}_{j,k}+\left(\hat{\boldsymbol{x}}_{j,k}-\hat{\boldsymbol{x}}_k\right)\left(\hat{\boldsymbol{x}}_{j,k}-\hat{\boldsymbol{x}}_k\right)^{\mathrm{T}}\right] \tag{20}$$

3 IMM算法的稳态增强设计

由于空间非合作目标的机动模式及执行机动的时长未知，IMM模型集中包含了多种轨道相对运对模型来应对目标潜在的不同运动状态。但在实际的跟踪任务中，受航天器姿轨控制能力、动力系统热问题、结构器械疲劳问题的影响，目标的运动状态通常满足：①每一时刻仅处于一种机动模式；②机动模式的切换接近于瞬间完成；③目标的机动模式不会过于频繁地发生切换[28]。综合考虑以上3点可知，在非合作机动目标跟踪任务的绝大多数时间内，目标均在某一种机动模式下以稳定的运动规律飞行。与目标发生机动模式切换的突变状态相对应，称目标在连续时间内持续执行某一种机动模式的状态为稳态。

综上所述，目标处于稳态时的相对运动估计在极大程度上决定了跟踪任务整体的导航精度。故本节对影响标准IMM算法稳态估计精度的因素进行分析，并就提升IMM算法稳态估计能力提出解决方案。

3.1 匹配模型的稳态权值分析

当目标处于稳态时，假设IMM模型集中的子模型a与目标的真实机动模式相匹配。理想情况下，此刻模型a的权值应当无限逼近于1并保持稳定，但实际情况并非如此。针对该现象，对模型a稳态权值的变化规律进行分析。

将式(12)代入式(18)，模型a的权值表示为

$$\mu_{a,k}=\frac{\Lambda_{a,k}\sum_{i=1}^{r}p_{ia,k-1}\mu_{i,k-1}}{\sum_{i=1}^{r}\Lambda_{i,k}\sum_{j=1}^{r}p_{ji,k-1}\mu_{j,k-1}} \tag{21}$$

当IMM算法各子模型的权值趋于稳定，以下不等关系成立：

$$\begin{cases}\mu_{a,k-1}\gg\mu_{i,k-1} & i=1,2,\cdots,r\text{且}i\neq a\\ p_{ii,k-1}\gg p_{ij,k-1} & i,j=1,2,\cdots,r\text{且}i\neq j\end{cases} \tag{22}$$

根据式(22)所示的不等关系，略去式(21)中的二阶小量可以得到

$$\begin{aligned}\mu_{a,k}&\approx\Lambda_{a,k}p_{aa,k-1}\mu_{a,k-1}\Bigg/\left(\sum_{\substack{i=1\\i\neq a}}^{r}\Lambda_{i,k}p_{ii,k-1}\mu_{i,k-1}+\sum_{i=1}^{r}\Lambda_{i,k}p_{ai,k-1}\mu_{a,k-1}\right)=\mu_{a,k-1}\Bigg/\\&\left(\sum_{\substack{i=1\\i\neq a}}^{r}\frac{\Lambda_{i,k}p_{ii,k-1}}{\Lambda_{a,k}p_{aa,k-1}}\mu_{i,k-1}+\sum_{i=1}^{r}\frac{\Lambda_{i,k}p_{ai,k-1}}{\Lambda_{a,k}p_{aa,k-1}}\mu_{a,k-1}\right)=\\&\mu_{a,k-1}\Bigg/\left\{\sum_{i=1}^{r}\mu_{i,k-1}+\frac{1}{\Lambda_{a,k}p_{aa,k-1}}\left[\sum_{i=1}^{r}\left(\Lambda_{i,k}p_{ii,k-1}-\Lambda_{a,k}p_{aa,k-1}\right)\mu_{i,k-1}+\sum_{\substack{i=1\\i\neq a}}^{r}\Lambda_{i,k}p_{ai,k-1}\mu_{a,k-1}\right]\right\}\end{aligned} \tag{23}$$

由子模型权值的归一化关系可知：

$$\sum_{i=1}^{r}\mu_{i,k-1}=1 \tag{24}$$

则有

$$\mu_{a,k}\approx\mu_{a,k-1}\Bigg/\left\{1+\frac{1}{\Lambda_{a,k}p_{aa,k-1}}\left[\sum_{i=1}^{r}\left(\Lambda_{i,k}p_{ii,k-1}-\Lambda_{a,k}p_{aa,k-1}\right)\mu_{i,k-1}+\sum_{\substack{i=1\\i\neq a}}^{r}\Lambda_{i,k}p_{ai,k-1}\mu_{a,k-1}\right]\right\} \tag{25}$$

记

$$M_{a,k}=\sum_{i=1}^{r}\left(\Lambda_{a,k}p_{aa,k-1}-\Lambda_{i,k}p_{ii,k-1}\right)\mu_{i,k-1}\Bigg/\sum_{\substack{i=1\\i\neq a}}^{r}\Lambda_{i,k}p_{ai,k-1} \tag{26}$$

进一步, 可知对于$i=1,2,\cdots,r$且$i\neq a$, 当式(27)关系满足时, 式(28)成立:

$$\mu_{i,k-1}=\frac{\Lambda_{i,k}p_{ai,k-1}}{\Lambda_{a,k}p_{aa,k-1}-\Lambda_{i,k}p_{ii,k-1}}\mu_{a,k-1} \tag{27}$$

$$M_{a,k}=\mu_{a,k-1} \tag{28}$$

将式(27)代入式(24)中, 可得

$$\left(1+\sum_{\substack{i=1\\i\neq a}}^{r}\frac{\Lambda_{i,k}p_{ai,k-1}}{\Lambda_{a,k}p_{aa,k-1}-\Lambda_{i,k}p_{ii,k-1}}\right)\mu_{a,k-1}=1 \tag{29}$$

结合式(28), 解得

$$M_{a,k}=1\Bigg/\left(1+\sum_{\substack{i=1\\i\neq a}}^{r}\frac{p_{ai,k-1}}{\Pi_{ai,k}p_{aa,k-1}-p_{ii,k-1}}\right) \tag{30}$$

式中:

$$\Pi_{ai,k}=\Lambda_{a,k}/\Lambda_{i,k} \tag{31}$$

结合式(25)、式(30), 可知以下关系成立: ①当$\mu_{a,k-1}>M_{a,k}$, 则$\mu_{a,k}<\mu_{a,k-1}$; ②当$\mu_{a,k-1}=M_{a,k}$, 则$\mu_{a,k}=\mu_{a,k-1}$; ③当$\mu_{a,k-1}<M_{a,k}$, 则$\mu_{a,k}>\mu_{a,k-1}$。

由上述不等关系可知, 当$k-1$时刻模型 a 的权值大于M_a时, 下一时刻其权值将减小; 当$k-1$时刻模型 a 的权值小于M_a时, 下一时刻其权值将增大。即当模型 a 为系统匹配模型时, M_a为模型 a 的稳态权值平衡点, 当$\Pi_{ai,k}$稳定时, 模型 a 的权值将稳定在M_a附近。

由式(30)可知, 当转移概率矩阵为常数矩阵时, M_a的取值由模型似然比Π_{ai}决定, M_a随Π_{ai}的变化情况如图 1 所示。

由图 1 可知, 在$0<\Pi_{ai}<k_2$时, $M_a>1$并趋近于正无穷; 在$k_2<\Pi_{ai}<k_1$时, M_a由负无穷趋近于 0; 在$\Pi_{ai}>k_1$时, $M_a>0$并趋近于 1。其中, k_2为$\sum_{\substack{i=1\\i\neq a}}^{r}\frac{p_{ai,k-1}}{\Pi_{ai,k}p_{aa,k-1}-p_{ii,k-1}}=-1$时$\Pi_{ai,k}$的值, k_1表达式为

$$k_1=p_{ii,k-1}/p_{aa,k-1} \tag{32}$$

由上述分析可知, 模型转移概率的取值决定了模型 a 稳态权值趋近于 1 的程度。同时可以说明, 模型转移概率的存在限制了模型 a 稳态权值的大小, 使其无法无限逼近于 1。

由式(30)和图 1 可知, 当模型 a 为系统匹配模型时, 理论上Π_{ai}将大于 1 且远离 k_1, 此时M_a将趋近于 1。但由式(17)可知, 由于受量测噪声影响, Π_{ai}近似服从 F 分布[29], 这一不确定性使其实际取值存在较大可能不满足理论情况。其中, 在量测噪声影响下, 若Π_{ai}逼近于 k_1 或小于 k_1, M_a将急剧减小, 使模型 a 的稳态权值发生跳变, 进而影响 IMM 算法的稳态估计精度。

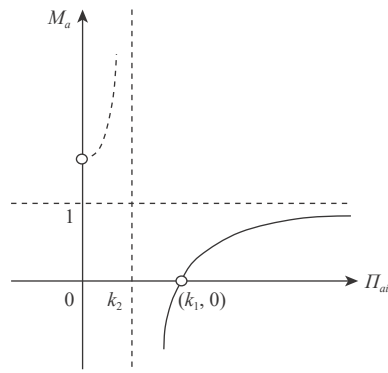


图 1　M_a变化趋势

Fig. 1　Variation trend of M_a

3.2　基于权值优化的 IMM 算法稳态增强方案

由 3.1 节分析可知, 在模型转移概率与模型似然比的综合作用下, 匹配子模型的稳态权值无法充分逼近于 1, 且易受量测噪声影响发生跳变, 进而将失配子模型较大的估计误差通过式(19)引入最终的估计结果, 严重影响 IMM 算法的稳态估计性能。

基于上述分析, 从以下两点着手进行 IMM 算法的稳态性能优化: ①增大匹配模型权值平衡点M_a的取值, 使模型与当前系统真实状态匹配时, 其权值能够更加趋近于 1, 提升 IMM 算法数据融合的准确性; ②令 k_1 点更加靠近图 1 中的坐标原点, 使模型与当前系统真实状态匹配时, 降低量测噪声影响下模型权值发生跳变的可能性。

由式(30)可知, M_a的取值由决定模型转移概率 p 决定, 进而影响了匹配模型权值趋近于 1 的程度。由式(32)易知, k_1 点的取值同样由 p 决定, 故

应从调整模型转移概率着手对目标处于稳态时的匹配模型权值进行优化，实现IMM算法稳态估计性能的提升。

令调整前的模型转移概率为 $p_{0,ij}(i,j=1,2,\cdots,r)$，以当前时刻的匹配模型 a 与失配模型 b 为例分析 $p_{0,ij}$ 对 M_a 的影响。假设当前时刻式(22)成立，则对于 $\Pi_{ai}>k_1$ 的区间，将式(30)重新整理为

$$M_a=1\Big/\left(1+\sum_{\substack{i=1\\ i\neq a}}^{r}\frac{p_{ai}}{\Pi_{ai}p_{aa}-p_{ii}}\right)=(\Pi_{ab}p_{aa}-p_{bb})\Big/\left[\left(1+\sum_{\substack{i=1\\ i\neq a,b}}^{r}\frac{p_{ai}}{\Pi_{ai}p_{aa}-p_{ii}}\right)(\Pi_{ab}p_{aa}-p_{bb})+p_{ab}\right] \tag{33}$$

令 $p^*=1+\sum\limits_{\substack{i=1\\ i\neq a,b}}^{r}\frac{p_{ai}}{\Pi_{ai}p_{aa}-p_{ii}}$，同理可得

$$M_{0,a}=\frac{\Pi_{ab}p_{0,aa}-p_{0,bb}}{p^*\left(\Pi_{ab}p_{0,aa}-p_{0,bb}\right)+p_{0,ab}} \tag{34}$$

则模型转移概率调整前后权值平衡点 M_a 的变化量为

$$\Delta M=M_a-M_{0,a}=\frac{(\Pi_{ab}p_{aa}-p_{bb})p_{0,ab}-\left(\Pi_{ab}p_{0,aa}-p_{0,bb}\right)p_{ab}}{\left[p^*(\Pi_{ab}p_{aa}-p_{bb})+p_{ab}\right]\left[p^*\left(\Pi_{ab}p_{0,aa}-p_{0,bb}\right)+p_{0,ab}\right]} \tag{35}$$

观察式(35)可知，若同时满足 $p_{aa}>p_{0,aa}$、$p_{bb}<p_{0,bb}$、$p_{0,ab}>p_{ab}$，则对于任意 Π_{ab}，有 $\Delta M>0$ 成立。同时，由式(32)可知，当上述关系成立时，同时满足 $k_1<k_{0,1}$。改善后的 M_a 随 Π_{ab} 变化的曲线如图2所示，易知优化①与优化②均实现。

根据上述分析，设计修正函数

$$\kappa_{j,k}=\left[\alpha_1\left(d_{j,k}+\alpha_2\right)^2+\alpha_3\right]^{\eta} \tag{36}$$

式中：α_1、α_2 为限幅系数，使 $\kappa_{j,k}>0$ 且关于 $d_{j,k}$ 单调递增；$\alpha_3=1-\alpha_1\alpha_2^3$；$\eta>0$ 为调节参数，用于调节修正的幅度。

同时有

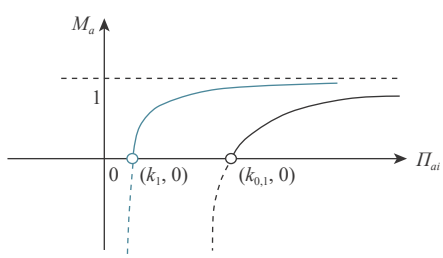


图2 调整后 M_a 变化趋势

Fig. 2 Adjusted variation trend of M_a

$$d_{j,k}=\frac{1}{n}\left(\mu_{j,k}-\mu_{j,k-n}\right) \tag{37}$$

式(37)表示在 n 个计算步长的时间窗口内求取模型权值变化的平均值。当某一子模型由非匹配模型转换为匹配模型时，其模型权值在一定时间内呈上升趋势，存在 $0<d_{a,k}<1$；当某一子模型由匹配模型转换为非匹配模型时，其模型权值在一定时间内呈下降趋势，存在 $-1<d_{i,k}<0$；当目标处于稳态模式时，存在 $d_{i,k}\approx 0$。

利用 $\kappa_{j,k}$ 对模型转移概率进行修正并进行归一化处理，修正后的模型转移概率为

$$p_{ij,k}=\kappa_{j,k}p_{ij,k-1}\Big/\sum_{j=1}^{r}\kappa_{j,k}p_{ij,k-1} \tag{38}$$

该函数的作用机理为：当模型 a 为匹配模型时，在其权值逐渐上升并趋于平衡状态的过程中，存在 $0<d_{a,k}<1$，使 $\kappa_{a,k}>1$，p_{aa} 增大。相应的，对于其他非匹配模型，存在 $-1<d_{i,k}<0$，使 $0<\kappa_{i,k}<1$，p_{ii} 和 $p_{ai}(i=1,2,\cdots,r$ 且 $i\neq a)$ 减小。在修正函数的作用下，匹配模型 a 的权值到达平衡状态时，p_{aa} 的取值较原先的设定值将增大，p_{ii} 的取值较原先的设定值将减小，符合式(35)给出的调整准则。则调整前后，系统状态满足：

$$\begin{cases}k_1<k_{0,1}\\ M_a>M_{0,a}\end{cases} \tag{39}$$

式中：$k_{0,1}$ 为调整前 k_1；$M_{0,a}$ 为调整前 M_a。

式(37)中，时间窗口存在的意义为：相较模型权值的实时动态变化，式(37)更加关注其在一定时间窗口内的整体发展趋势。受量测噪声影响，模型权值的上升、下降与稳定均为震荡的动态过程，相邻时刻模型权值的变化极有可能不符合模型与真实系统的匹配情况，将导致 $\kappa_{a,k}$ 对模型转移概率错误地调整。而在时间窗口的作用下，结合模型权值的发展趋势对模型转移概率进行调整，可以使模型参数 M_a 与 k_1 的修正过程更加准确与平滑。

综合3.1节与3.2节中的分析，可以将ES-IMM算法的设计思路分为算法修正与优化机制2部分。其中，算法修正部分利用给定时间窗口内模型权值的发展趋势判定各子模型与真实系统的匹配情况，并据此对模型转移概率进行调整，进而完成对IMM算法内部参数 M_a 与 k_1 的修正。其优化机制在于，通过增大 M_a 使匹配模型权值充分逼近于1，同时，通过减小 k_1 对量测噪声影响下的权值跳变进行抑制。ES-IMM算法整体设计思路如图3所示。

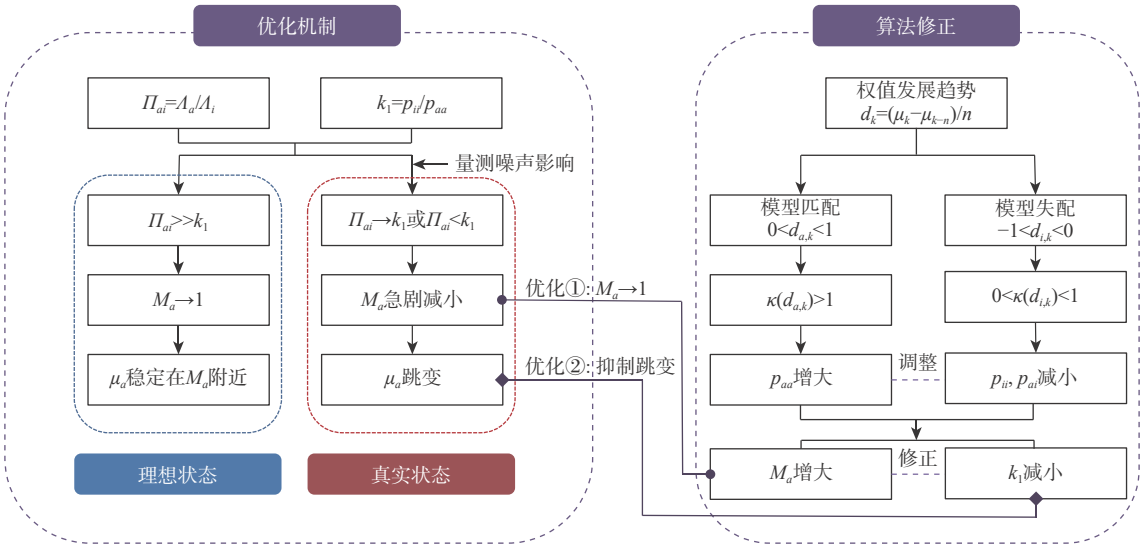


图 3　ES-IMM 算法设计流程

Fig. 3　Design flow chart of the ES-IMM algorithm

4　仿真校验

为验证本文算法的有效性, 将其应用于空间非合作机动目标的相对运动估计。假设追踪星与目标星均处于自由漂飞状态; 在无控运行 500 s 后作匀加速机动, 控制加速度为 $\boldsymbol{u}_1$, 持续运行至 1 000 s 后停止。具体仿真参数设置如表 1 所示。

过程噪声协方差矩阵为

$$\begin{cases}\boldsymbol{Q}_1=\mathrm{diag}\left(10^{-6},10^{-6},10^{-6},10^{-8},10^{-8},10^{-8}\right)\\ \boldsymbol{Q}_2=\mathrm{diag}\left(10^{-6},10^{-6},\ 10^{-6},\ 10^{-8},\ 10^{-8},\right.\\ \qquad\left.10^{-8},10^{-10},10^{-10},10^{-10}\right)\\ \boldsymbol{Q}_3=\mathrm{diag}\left(10^{-6},10^{-6},\ 10^{-6},\ 10^{-8},\ 10^{-8},\right.\\ \qquad\left.10^{-8},10^{-4},10^{-4},10^{-4}\right)\end{cases}\tag{40}$$

表 1　仿真参数设置

Table 1　Simulation parameter settings

初始相对位置/m	初始相对速度/(m·s^{-1})	初始模型权值	初始模型转移概率	机动加速度/(m·s^{-2})	采样周期/s	滤波时长/s	修正函数参数	时间窗口长度
$[2\,000,0,0]^{\mathrm{T}}$	$[0,0,0]^{\mathrm{T}}$	$\left[\frac{1}{3},\frac{1}{3},\frac{1}{3}\right]$	$\begin{bmatrix}0.98&0.01&0.01\\0.01&0.98&0.01\\0.01&0.01&0.98\end{bmatrix}$	$[0.05,0,0]^{\mathrm{T}}$	0.5	1 500	$\alpha_1=0.1,\alpha_2=2,\eta=3.5$	10

量测噪声协方差矩阵设置为

$$\boldsymbol{R}'=\mathrm{diag}\left((1/3)^2,0.05^2,0.05^2\right)\tag{41}$$

以测量单机测距误差的 3σ 值作为滤波器的初始位置估计误差, 以单机内部基于时间差分计算得到相对速度的 3σ 误差作为滤波器的初始速度估计误差, 则滤波器的初始状态估计值为

$$\hat{\boldsymbol{x}}_0=\begin{bmatrix}\boldsymbol{r}_0 & \dot{\boldsymbol{r}}_0\end{bmatrix}^{\mathrm{T}}+\left[1,1,1,10^{-2},10^{-2},10^{-2}\right]^{\mathrm{T}}\tag{42}$$

式中: $\boldsymbol{r}_0$ 为初始相对位置。

同时, 设置匀加速机动模型与大偏差响应模型的初始目标加速度估计值 $\hat{\boldsymbol{u}}_0=[0,0,0]^{\mathrm{T}}$ m/s^2。目标机动加速度变化如图 4 所示。

为分别验证 ES-IMM 算法对于提升匹配模型权值及抑制稳态权值跳变的效果, 分别给出单次仿真中标准 IMM 算法和 ES-IMM 算法的模型权值变化曲线, 以及 100 次蒙特卡罗仿真中标准 IMM 算法和 ES-IMM 算法模型权值包络曲线, 分别如图 5 和图 6 所示。

由图 5 可知, 相较于标准 IMM 算法, ES-IMM 算法在目标处于无机动或常值推力机动模式时, 其对应子模型的模型权值都更接近 1, 降低了失配模型误差在数据融合时引入最终估计结果的比例。由图 6 可知, 相较于标准 IMM 算法, ES-IMM 算法的模型权值的跳变频率及跳变幅值均显著降低, 提升算法在稳态时的稳定性。

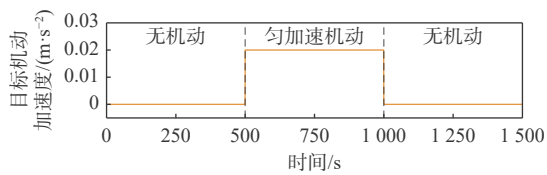
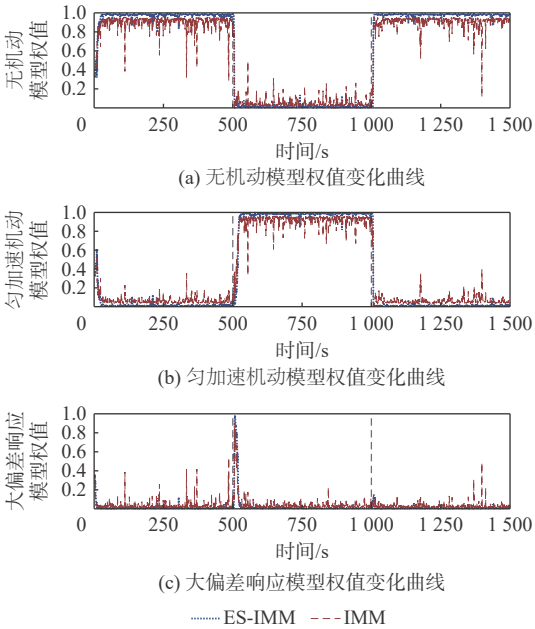


图 4　目标机动加速度

Fig. 4　Maneuvering acceleration of target



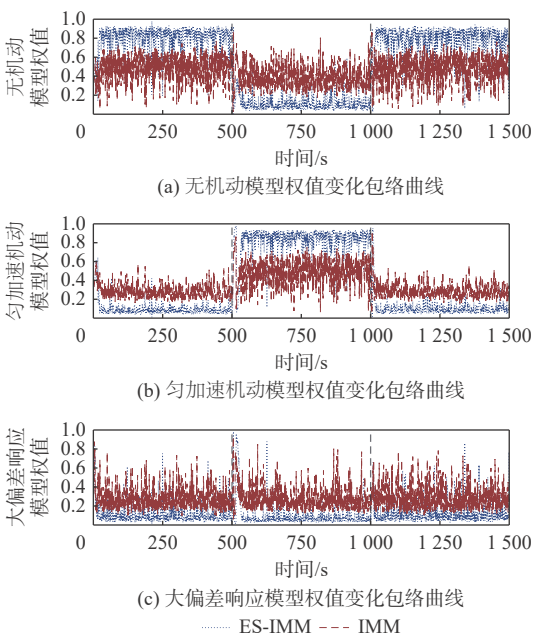
(a) 无机动模型权值变化曲线

(b) 匀加速机动模型权值变化曲线

(c) 大偏差响应模型权值变化曲线

图 5 单次仿真模型权值变化

Fig. 5 Change of model weights in single simulation



(a) 无机动模型权值变化包络曲线

(b) 匀加速机动模型权值变化包络曲线

(c) 大偏差响应模型权值变化包络曲线

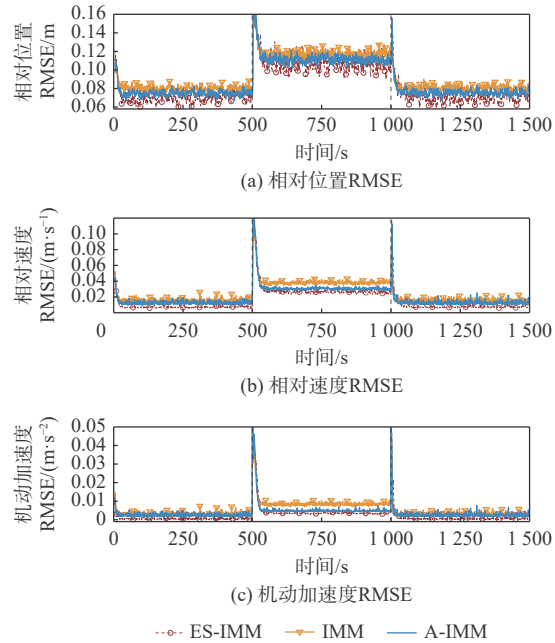
图 6 模型权值变化包络曲线

Fig. 6 Envelope curves of model weight change

进一步，将标准 IMM 算法、ES-IMM 算法与文献 [20-23] 中使用的自适应 IMM(adaptive IMM, A-IMM)算法的精度进行仿真对比。共进行 200 组蒙特卡罗仿真，使用均方根误差(root mean square error, RMSE)[4] 来衡量各滤波算法的精度。

相对位置、相对速度和机动加速度 RMSE 曲线如图 7 所示。

由图 7 可知，与标准 IMM 算法相比，在目标无机动或发生常值推力机动时，ES-IMM 算法对位置、速度和加速度均具有较高的估计精度。A-IMM



(a) 相对位置RMSE

(b) 相对速度RMSE

(c) 机动加速度RMSE

图 7 各算法 RMSE 曲线对比

Fig. 7 Comparison of RMSE curves for each algorithm

算法虽然较标准 IMM 算法的估计精度也有所提升，但其优化程度明显不如 ES-IMM 算法。产生上述结果的原因在于：

1）A-IMM 算法基于马尔可夫链对 IMM 算法进行定性分析，认为利用后验信息对模型转移概率进行修正有利于系统模型更好地逼近真实状态[30]。但 KF 建立在一阶马尔可夫过程的基础上，即当前时刻的系统状态仅由前一时刻的系统状态决定，而与更早的系统状态无关。故 A-IMM 算法仅利用了当前时刻与紧邻的上一时刻的后验信息对模型转移概率进行修正。如 3.2 节中所述，受量测噪声影响，相邻 2 个时刻之间的后验信息极有可能会错误地反映真实系统的变化，故这样的修正方式是不准确、不彻底的。

2）与 A-IMM 算法不同，基于 3.1 节中对 IMM 算法稳态性能影响因素的理论分析，ES-IMM 算法利用时间窗口内模型权值的发展趋势对模型转移概率进行调整，实现了对模型稳态权值的修正，进而降低了算法对于量测噪声的敏感性，这一过程更加准确、彻底。

采用时间平均 RMSE(time-averaged RMSE, TARMSE)定量评价滤波算法的精度，相对位置 $\boldsymbol{r}_k$ 的 TARMSE 表达式如式(43)所示。同理可得速度、加速度对应公式。仿真结果如表 2 所示。

$$E_{\mathrm{TARMSE}}(\boldsymbol{r}_k)=\sqrt{\frac{1}{N_{\mathrm{M}}}\frac{1}{N_{\mathrm{S}}}\sum_{i'=1}^{N_{\mathrm{M}}}\sum_{k=N_{\mathrm{ST}}}^{N_{\mathrm{SP}}}\left(e_{x,k}^{i'}\right)^2+\left(e_{y,k}^{i'}\right)^2+\left(e_{z,k}^{i'}\right)^2} \tag{43}$$

式中：N_{M} 为蒙特卡罗仿真次数；N_{ST} 和 N_{SP} 分别为

表 2　滤波算法性能比较

Table 2　Performance comparison of filter algorithms

算法	相对位置/m		相对速度/(m·s^{-1})		加速度/(m·s^{-2})	
	无机动	匀加速机动	无机动	匀加速机动	无机动	匀加速机动
标准IMM	0.079 8	0.116 8	0.015 2	0.038 1	0.003 1	0.008 4
A-IMM	0.074 7	0.111 5	0.012 7	0.030 4	0.002 6	0.004 8
ES-IMM	0.069 9	0.107 6	0.007 2	0.027 0	0.000 7	0.003 5

TARMSE 计算开始和结束时刻; $N_S = N_{SP} - N_{ST} + 1$; $e^{i'}_{x,k}$、$e^{i'}_{y,k}$和$e^{i'}_{z,k}$分别为第 i'次蒙特卡罗仿真中 k 时刻 x 轴、y 轴和 z 轴相对位置的估计误差。

由表 2 可知, 在无机动区间中, ES-IMM 算法的位置、速度、加速度误差分别为标准 IMM 算法的 87.6%、47.4%、22.6%; 分别为 A-IMM 算法的 93.6%、56.7%、26.9%。在常值推力机动区间中, ES-IMM 算法的位置、速度、加速度误差分别为标准 IMM 算法的 92.1%、70.9%、41.7%, 分别为 A-IMM 算法的 96.5%、88.8%、72.9%。ES-IMM 算法精度提升明显。

鉴于本文的应用背景与模型集设置情况, 此处仅就无机动模式与匀加速机动 2 类目标的稳态模式进行了仿真验证。但 ES-IMM 算法的适用性并不局限于空间目标跟踪与上述 2 类稳态模式。在不同的应用背景下(如地面车辆与航空器的跟踪任务), 若使用的模型集包含更多的目标运动子模型(如匀速转弯(constant turn, CT)模型、当前统计(current statistics, CS)模型等), 只要机动目标处于某一子模型所描述的运动状态下稳定运行, ES-IMM 算法均能够提升算法的稳态估计性能, 具有普遍适用性。

5　结　论

本文提出了 ES-IMM 算法, 进行了理论推导, 提高了空间机动目标跟踪任务中 IMM 算法的稳态估计精度。主要工作包括以下几个方面:

1) 基于航天器的在轨运动状态与机动能力, 构建了以无机动模型、匀加速机动模型、大偏差响应模型为子模型的 IMM 模型集, 以较低的模型复杂度描述了与机动目标间的相对运动包络。

2) 揭示了稳态模式下匹配模型权值的变化规律, 给出了稳态权值平衡点的数学表达式, 阐明了模型转移概率及模型似然比对稳态权值的影响, 提出了 IMM 算法稳态估计性能的增强方案。

3) 利用模型权值在给定时间窗口内的发展趋势, 设计了模型转移概率的修正函数, 并提出 ES-IMM 算法, 实现了稳态模式下匹配模型权值的提升, 同时, 能够对量测噪声影响下的权值跳变进行抑制。

4) 仿真结果表明, 空间机动目标跟踪任务中, 相较标准 IMM 算法与 A-IMM 算法, 经稳态权值优化的 ES-IMM 算法精度提升明显。

参考文献（References）

[1] Zhu W S, She Y C, Hu J Q, et al. A hybrid relative navigation algorithm for a large-scale free tumbling non-cooperative target[J]. Acta Astronautica, 2022, 194: 114-125.

[2] Maestrini M, De Luca M A, Di Lizia P. Relative navigation strategy about unknown and uncooperative targets[J]. Journal of Guidance, Control, and Dynamics, 2023, 46(9): 1708-1725.

[3] Barbier T, Gao Y. Relative visual navigation around an unknown and uncooperative spacecraft[J]. Acta Astronautica, 2023, 206: 144-155.

[4] 卢山, 张世源. 非合作航天器相对运动估计的混合滤波器设计方法[J]. 宇航学报, 2023, 44(5): 764-773.
Lu S, Zhang S Y. Hybrid filter design for relative motion estimation of non-cooperative spacecraft[J]. Journal of Astronautics, 2023, 44(5): 764-773(in Chinese).

[5] Kalman R E. A new approach to linear filtering and prediction problems[J]. Journal of Basic Engineering, 1960, 82(1): 35-45.

[6] Zhang L F, Wang S P, Selezneva M S, et al. A new adaptive Kalman filter for navigation systems of carrier-based aircraft[J]. Chinese Journal of Aeronautics, 2022, 35(1): 416-425.

[7] Fernandes M R, Magalhães G M, Zúñiga Y R C, et al. GNSS/MEMS-INS integration for drone navigation using EKF on lie groups[J]. IEEE Transactions on Aerospace and Electronic Systems, 2023, 59(6): 7395-7408.

[8] Guo Y H, Vouch O, Zocca S, et al. Enhanced EKF-based time calibration for GNSS/UWB tight integration[J]. IEEE Sensors Journal, 2023, 23(1): 552-566.

[9] Fraser C T, Ulrich S. Adaptive extended Kalman filtering strategies for spacecraft formation relative navigation[J]. Acta Astronautica, 2021, 178: 700-721.

[10] 卢山, 张世源. 针对 UNGM 模型的特性分析与滤波算法设计研究[J]. 西北工业大学学报, 2023, 41(2): 293-302.
Lu S, Zhang S Y. Characteristic analysis and filtering algorithm design for UNGM model[J]. Journal of Northwestern Polytechnical University, 2023, 41(2): 293-302(in Chinese).

[11] Xue C, Huang Y L, Zhao C, et al. A Gaussian-generalized-inverse-Gaussian joint-distribution-based adaptive MSCKF for visual-inertial odometry navigation[J]. IEEE Transactions on Aerospace and Electronic Systems, 2023, 59(3): 2307-2328.

[12] Blom H A P, Bar-Shalom Y. The interacting multiple model al-

gorithm for systems with Markovian switching coefficients[J]. IEEE Transactions on Automatic Control, 1988, 33(8): 780-783.

[13] Matei R S, Bar-Shalom Y, Willett P. Multiple-model estimators for tracking sharply maneuvering ground targets[J]. IEEE Transactions on Aerospace and Electronic Systems, 2018, 54(3): 1404-1414.

[14] Zhou G J, Zhu B, Ye X P. Switch-constrained multiple-model algorithm for maneuvering target tracking[J]. IEEE Transactions on Aerospace and Electronic Systems, 2023, 59(4): 4414-4433.

[15] Goff G M, Black J T, Beck J A. Orbit estimation of a continuously thrusting spacecraft using variable dimension filters[J]. Journal of Guidance, Control, and Dynamics, 2015, 38(12): 2407-2420.

[16] Yin J Q, Yang Z, Luo Y Z. Adaptive tracking method for non-cooperative continuously thrusting spacecraft[J]. Aerospace, 2021, 8(9): 244.

[17] Goff G M, Black J T, Beck J A. Tracking maneuvering spacecraft with filter-through approaches using interacting multiple models[J]. Acta Astronautica, 2015, 114: 152-163.

[18] Arroyo Cebeira A, Asensio Vicente M. Adaptive IMM-UKF for airborne tracking[J]. Aerospace, 2023, 10(8): 698.

[19] Jilkov V P, Li X R. Online Bayesian estimation of transition probabilities for Markovian jump systems[J]. IEEE Transactions on Signal Processing, 2004, 52(6): 1620-1630.

[20] Xie G, Sun L L, Wen T, et al. Adaptive transition probability matrix-based parallel IMM algorithm[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2021, 51(5): 2980-2989.

[21] Zhang Z X, Shu L Z, Zhang K K, et al. Orbit determination and thrust estimation for noncooperative target using angle-only measurement[J]. Space: Science & Technology, 2023, 3: 73.

[22] 戴定成, 姚敏立, 蔡宗平, 等. 改进的马尔可夫参数自适应IMM算法[J]. 电子学报, 2017, 45(5): 1198-1205.
Dai D C, Yao M L, Cai Z P, et al. Improved adaptive Markov IMM algorithm[J]. Acta Electronica Sinica, 2017, 45(5): 1198-1205(in Chinese).

[23] 郭志, 董春云, 蔡远利, 等. 时变转移概率IMM-SRCKF机动目标跟踪算法[J]. 系统工程与电子技术, 2015, 37(1): 24-30.
Guo Z, Dong C Y, Cai Y L, et al. Time-varying transition probability based IMM-SRCKF algorithm for maneuvering target tracking[J]. Systems Engineering and Electronics, 2015, 37(1): 24-30(in Chinese).

[24] 王常虹, 张大力, 夏红伟, 等. GEO混合推力机动目标跟踪IMM算法[J]. 宇航学报, 2023, 44(3): 443-453.
Wang C H, Zhang D L, Xia H W, et al. An IMM algorithm for tracking GEO maneuvering target with hybrid thrust[J]. Journal of Astronautics, 2023, 44(3): 443-453(in Chinese).

[25] 郭延宁, 李高健, 于永彬. 基于改进蜣螂优化的GEO轨道多脉冲追逃博弈[J]. 中国空间科学技术 (中英文), 2024, 44(4): 1-10.
Guo Y N, Li G J, Yu Y B. Multi-impulse pursuit-evasion game in GEO based on improved dung beetle optimization[J]. Chinese Space Science and Technology, 2024, 44(4): 1-10(in Chinese).

[26] Clohessy W H, Wiltshire R S. Terminal guidance system for satellite rendezvous[J]. Journal of the Aerospace Sciences, 1960, 27(9): 653-658.

[27] Zhang A, Bao S D, Gao F, et al. A novel strong tracking cubature Kalman filter and its application in maneuvering target tracking[J]. Chinese Journal of Aeronautics, 2019, 32(11): 2489-2502.

[28] Gao B B, Li W M, Hu G G, et al. Mahalanobis distance-based fading cubature Kalman filter with augmented mechanism for hypersonic vehicle INS/CNS autonomous integration[J]. Chinese Journal of Aeronautics, 2022, 35(5): 114-128.

[29] Hanlon P D, Maybeck P S. Characterization of Kalman filter residuals in the presence of mismodeling[J]. IEEE Transactions on Aerospace and Electronic Systems, 2000, 36(1): 114-131.

[30] 许登荣, 程水英, 包守亮. 自适应转移概率交互式多模型跟踪算法[J]. 电子学报, 2017, 45(9): 2113-2120.
Xu D R, Cheng S Y, Bao S L. Interacting multiple model algorithm based on adaptive transition probability[J]. Acta Electronica Sinica, 2017, 45(9): 2113-2120(in Chinese).

Steady-state enhancement design of IMM algorithm for space maneuvering target tracking

ZHANG Shiyuan*，LU Shan，LI Qing

(Shanghai Aerospace Control Technology Institute，Shanghai 201109，China)

Abstract：The relative navigation system for monitoring non-cooperative maneuvering targets in space seeks to acquire precise real-time orbital data and enhance spacecraft's rapid situational awareness and accurate decision-making for target orbital maneuvers, forming the foundation of the spacecraft pursuit-evasion strategy. The research examines the interacting multiple model (IMM) algorithm for assessing the relative motion state of an unidentified target throughout a sequence of maneuvers, and establishes a model set that comprises a non-cooperative model, a uniform acceleration maneuvering model, and a big deviation response model. Based on the designed model set, the estimation performance factors of IMM are analyzed when the target is in a stable motion of a specific maneuvering mode (steady-state mode). The expression for the equilibrium point of matching model weights (the steady-state weights) in a steady-state mode is established, and the pattern of change of steady-state weights around the equilibrium point is presented. Besides, the influence mechanism of model transition probability and model likelihood ratio on the size of steady-state weights and the sensitivity of measurement noise is clarified. The above analysis provides a theoretical basis for the steady-state performance analysis and optimization of IMM. Based on the above analysis, the correction of the model transition probability is taken in real-time, combined with the development trend of model weights in a given time window. Then, the enhanced steady-state IMM (ES-IMM) is proposed. It not only boosts the weight of the matching model in steady-state estimate but also mitigates weight fluctuations caused by measurement noise, hence improving the steady-state estimation efficacy of IMM in tracking space maneuvering targets. The simulation results show that the estimation accuracy of ES-IMM is better than that of standard IMM in the steady-state interval of space maneuvering target tracking task.

Keywords：non-cooperative spacecraft; maneuvering target tracking; relative navigation; interacting multiple model; Kalman filter

Received：2024-10-15；**Accepted**：2024-12-20；**Published Online**：2024-12-27 18：45

URL：link.cnki.net/urlid/11.2625.V.20241227.1300.003

* **Corresponding author**. E-mail：1663085217@qq.com

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2025.0356

上下文注意力引导的航拍图像语义分割算法

刘露露[1,*]，谢荣磊[2]，姬嘉驰[3]

(1. 北京航空航天大学杭州创新研究院，杭州 310051；2. 中国航天科工飞航技术研究院，北京 100074；
3. 北京航空航天大学 航空科学与工程学院，北京 100191)

摘 要：航拍图像语义分割算法在土地利用、环境监测、资源调查、城市规划等领域具有重要的研究和应用价值。针对高分辨率航拍图像中地物关系复杂、目标尺度多变、类内差异大、类间相似高的问题，提出上下文注意力引导的语义分割算法。在模型的编码阶段引入协同注意力模块，采用空间与通道多维度特征提取的方式，对全局的上下文特征信息进行挖掘，提升模型的特征表征能力。在模型的解码阶段构建全局-局部特征融合模块，利用全局与局部平行支路的方式，实现语义信息和细节特征的提取，并借助十字语义交互模块进行特征融合，提升模型对类别边缘的辨别能力。实验结果表明：所提算法在UAVID数据集上的平均交并比（MIoU）达到了71.0%，在速度与精度上显著优于对比算法。

关 键 词：语义分割；航拍图像；注意力机制；深度学习；特征融合
中图分类号：V279+.2
文献标志码：A **文章编号**：1001-5965(2026)11-3918-11

随着传感器技术的不断进步，在全球范围内拍摄了越来越多的高分辨率航拍图像，这些图像包含了丰富的空间细节和潜在的语义内容，在资源勘探[1]、环境保护[2]、城市规划[3]等领域发挥着重要作用。语义分割作为计算机视觉领域的重要研究方向，可以对图像中的类别进行像素级分类，是满足海量航拍图像快速解译需求的关键算法。然而，航拍图像普遍具有杂波干扰强、地物关系多、目标尺度与方向多变的特点，如何有效提取高分辨率航拍图像中目标间的语义关系、准确预测类别标签仍然是一个亟待解决的问题。

近些年来，随着以深度学习为代表的人工智能技术的发展，卷积神经网络(convolutional neural network, CNN)逐渐成为解决语义分割算法所面临困难的关键技术。Long等[4]提出了全卷积网络(fully convolutional network, FCN)的语义分割算法。该算法对现有的CNN架构进行修改，将所有的全连接层替换为卷积层，从而解决网络输入输出图像尺寸大小不固定的问题。随后，Noh等[5]将转置卷积引入到图像语义分割任务中，构建了一个含有普通卷积层特征编码器和转置卷积层特征解码器的全新语义分割架构。Badrinarayanan等[6]也提出了一种用于图像语义分割的卷积编码器-解码器的结构，被称为SegNet。SegNet的创新之处是其解码器采用的是上采样操作来增加输入特征的分辨率，并利用稀疏映射生成密集的特征映射来完成图像的分割。Ronneberger等[7]在前述基础上提出了U-Net网络，其由2部分组成，一部分用来捕获上下文信息，另一部分用来恢复特征的尺度。尽管这些结构在自然图像上表现良好，但对于高分辨率航拍图像存在两方面不足：①航拍图像中目标尺度跨度极大，单一分辨率的编码-解码难以对极小目标与大尺度地物同时做出精确分割；②高分辨率下的内存与计算开销显著增加，直接将这些网络放大以提升

收稿日期：2025-06-09；录用日期：2025-08-06；网络出版时间：2025-08-29 16:00
网络出版地址：link.cnki.net/urlid/11.2625.V.20250829.1511.001
基金项目：江淮前沿技术协同创新中心追梦基金 (2023-ZM01X008)
*通信作者. E-mail：liu_lulu@buaa.edu.cn

引用格式：刘露露，谢荣磊，姬嘉驰. 上下文注意力引导的航拍图像语义分割算法[J]. 北京航空航天大学学报，2026，52(11)：3918-3928.
Liu L L，Xie R L，Ji J C. Semantic segmentation algorithms of aerial images via context-aware attention guidance[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3918-3928 (in Chinese).

分辨率常常不可行。为解决 FCN 全局上下文信息利用不充分的问题, Liu 等[8] 提出了名为 ParseNet 的模型。ParseNet 首先利用全局平均池化与归一化操作完成上下文特征的提取; 然后, 采用反池化操作将其恢复至原始特征图的尺寸并与原始特征图组合在一起, 形成一个含有上下文全局特征信息的新特征图, 为后续语义分割结果的生成提供丰富的特征信息。为更好地学习一个场景的全局上下文特征, Zhao 等[9] 实现了一个多尺度的网络, 称为金字塔场景解析网络, 其可以克服卷积特征映射的表征空间分辨率较低的问题, 在高维特征表征上提取重要的亚像素定位信息, 以多尺度分析实现较好的分割效果。多尺度与全局上下文的引入确实提升了对场景结构的理解, 但在航拍图像中仍面临 2 类问题: ①局部细节(尤其是极小目标)可能在多尺度汇聚过程中被“平滑”或淹没, 导致定位不准; ②航拍图像常伴随类别不均衡(少数类别像素占比极低), 单纯的多尺度融合无法有效缓解类别偏倚对模型训练的影响。除此之外, Chen 等[10] 发现来自 FCN 最后一层的深层特征图中没有足够的细化信息来进行精确的目标分割, 因此, 提出了一种基于 CNN 和全连接条件随机场的语义分割算法。该算法通过插值对 CNN 的粗分割结果进行上采样, 并将粗分割结果输入给一个全连接条件随机场来细化分割的结果, 克服深层 CNN 的不良定位问题。Schwing 等[11] 提出了一种可以联合训练 CNN 和条件随机场的全连接深度神经网络, 并在数据实验中取得了良好的性能。Zheng 等[12] 受此启发也提出了一种端到端联合训练的 CNN 和条件随机场分割方法。Lin 等[13] 提出了一种基于上下文的条件随机场语义分割方法, 探索了图像中“区域+区域”和“区域+背景”的上下文关系, 并由此改善分割效果。条件随机场类的方法在边界细化上效果显著, 但其对噪声敏感、参数调整复杂, 并且作为后处理往往增加了推理流程的复杂性。在航拍图像中, 由于背景复杂且纹理相似, 简单的基于像素/邻域的平滑约束容易导致小目标被误融合或消失; 另外, 端到端联合训练的模型在大分辨率输入下的计算开销亦不容忽视。虽然上述分割算法在自然图像分割中表现优异, 但却缺乏对航拍图像语义分割任务特有问题的针对性分析(如地物尺度跨度大、类别分布不均衡、复杂背景干扰), 无法将传统视角图像上表现出色的性能直接迁移到高分辨率航拍图像中。

为解决航拍图像语义分割任务中类别分布不均衡、类内差异大、类间相似高导致分割精度低的问题, 本文提出了一种上下文注意力引导的航拍图像语义分割(简称 CAGNet)算法。其核心思想是通过编码端和解码端的协同注意力机制, 分别强化多尺度特征的语义关联与上下文感知能力。在编码阶段, 考虑到高分辨率航拍图像空间尺度大、类别目标尺寸差异大的特点, 本文结合注意力机制提出了协同注意力模块(collaborative attention module, CAM)用于提升编码阶段全局上下文特征信息的提取能力; 在解码阶段, 模型引入全局-局部特征融合模块(global-local feature fusion module, GLFFM), 在局部细节特征和全局语义特征上对编码器提取特征进行融合, 增强预测标签的语义辨别能力。

1　本文算法

1.1　网络结构

本文 CAGNet 算法总体框架如图 1 所示。该框架主要包含特征编码模块(feature encoding module, FEM)、CAM 与 GLFFM, 其中, FEM 利用 ResNet-18 提取多尺度的特征信息, CAM 从通道和空间 2 个维度对关键特征进行挖掘, GLFFM 以多尺度特征信息为输入建立特征的长距离依赖关系, 以增强算法在实际场景中的适用能力。

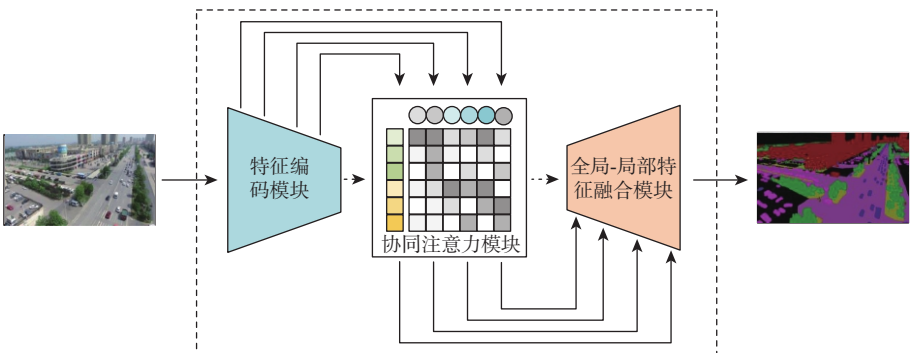


图 1　本文算法框架

Fig. 1　Framework of the proposed algorithm

1.2　协同注意力模块

考虑到航拍图像空间尺度大、各类目标尺寸差异大的特点, 本文结合注意力机制在计算机视觉任务中的出色表现, 提出了协同注意力模块, 如图 2

所示，协同注意力模块主要由协同通道注意力机制和协同空间注意力机制组成，其可以在空间和通道2个维度上对全局的上下文特征信息进行挖掘，从而提升模型特征信息的丰富程度，为后续的语义类别预测做准备。

在协同通道注意力机制中，如图3所示，输入的特征图$\boldsymbol{x}\in\mathbf{R}^{C\times H\times W}$，首先，经过池化操作和维度调整操作，从而转变成维度为$C\times H\times 1$和$C\times 1\times H$的特征图，其中，C为特征通道维度，H为特征高度，W为特征宽度；随后，将其输入一维卷积操作以学习相邻通道的依赖关系，再采用维度调整操作将它们的维度变成$C\times 1\times 1$；然后，分别采用Sigmoid函数对2个特征图进行激活，从而获得高度和宽度2个维度的通道权重；最后，对2个通道权重与原始特征图进行加权与融合操作，从而输出包含通道信息的特征图。

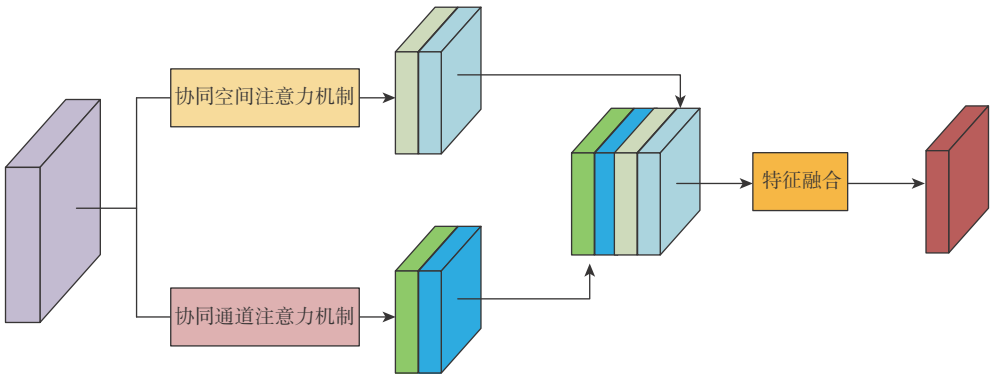


图2 协同注意力模块

Fig. 2 Collaborative attention module

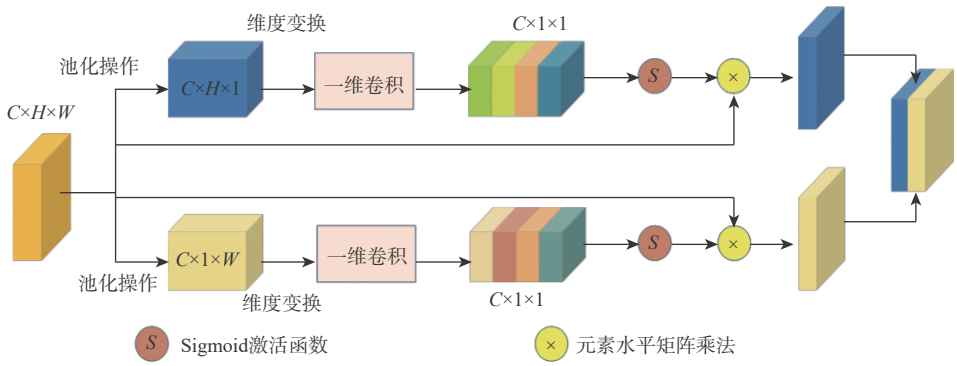


图3 协同通道注意力机制

Fig. 3 Collaborative channel attention mechanism

在协同空间注意力机制中，如图4所示，其中，GAP表示全局平均池化，GMP表示全局最大池化。首先，采用通道平均池化和通道最大池化来压缩特征图的通道信息；随后，利用拼接与卷积操作

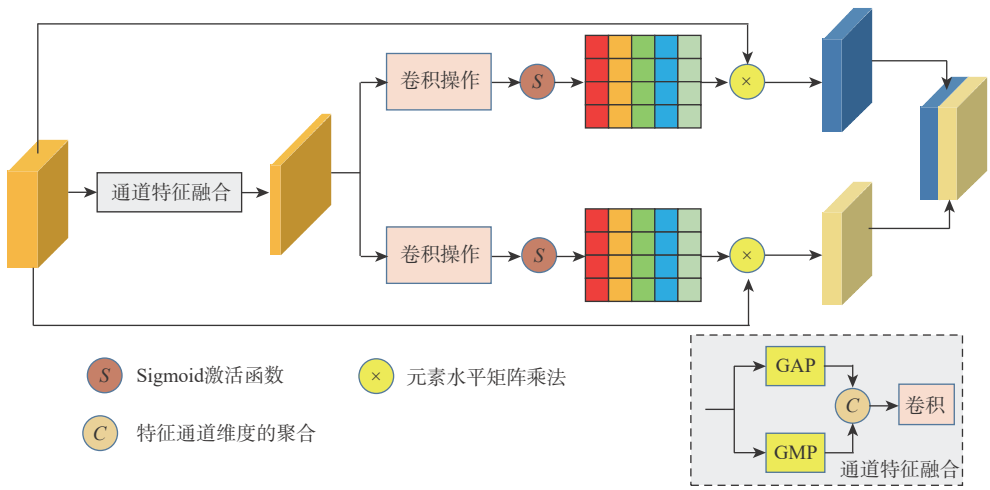


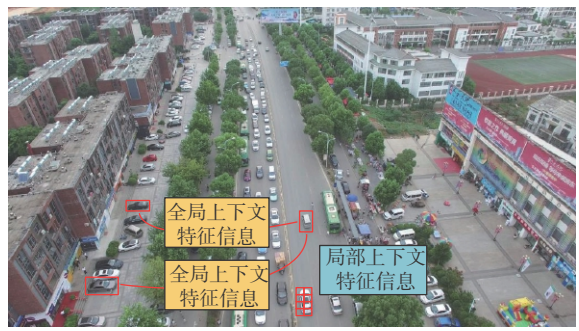
图4 协同空间注意力机制

Fig. 4 Collaborative spatial attention mechanism

对特征进行融合; 然后, 协同空间注意力分别采用与输入特征维度相对应高宽的卷积核来提取特征图的空间信息; 再利用Sigmoid函数获取特征图在宽度和高度 2 个维度的空间权重, 并最终将获得的 2 个空间权重与原始输入特征图进行加权, 得到 2 个空间特征加权的特征图; 最后, 所生成的融合特征图采用拼接和卷积操作进行最终的特征融合, 从而实现空间粒度信息的有效挖掘。

1.3　全局-局部特征融合模块

对于航拍图像语义分割任务, 如图 5 所示, 如果算法仅对局部信息进行建模, 则会导致每个像素的分类通常是模糊的, 而全局上下文信息则可以有效地解决这一问题使每个像素的分类变得更加清晰准确。此外, 复杂的人造物体经常出现在航拍图像中, 如果没有全局语义信息, 就很难实现精确的语义分割。基于上述分析, 如图 6 所示, 在全局-局部特征融合模块中, 全局与局部注意力机制构造了 2 个平行的分支从而实现对全局和局部上下文特征的融合。作为一种相对浅层的结构, 局部注意力分支使用了 2 个平行的卷积层(其卷积核大小分别为 3 和 1)来提取局部的上下文特征信息。随后, 在最终的十字形语义交互操作之前添加了 2 个批归一化操作, 以实现批次特征的融合。



京审字(2026)G第2978号

图 5　全局与局部上下文信息示意

Fig. 5　Illustration of global and local contextual information

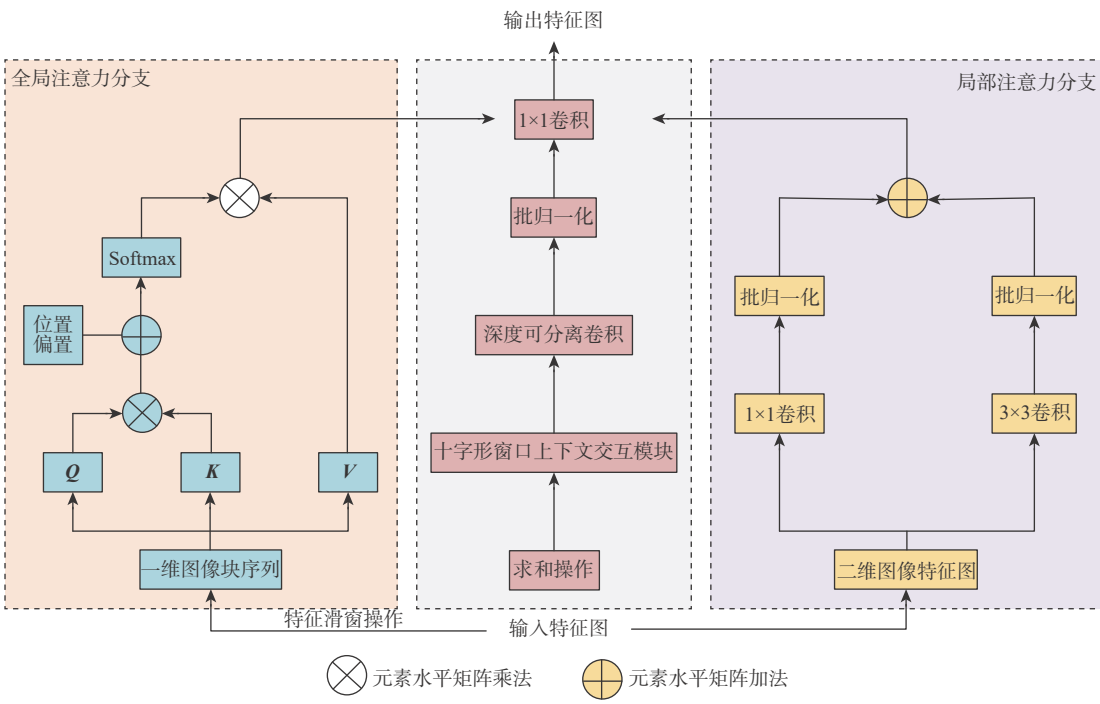


图 6　全局-局部特征融合模块

Fig. 6　Global-local feature fusion module

在全局特征分支中, GLFFM 利用基于窗口的多头自注意力来实现全局上下文信息捕获的能力。如图 7 所示, 首先, 使用一个标准的卷积将输入的二维特征图($\mathbf{R}^{B\times C\times H\times W}$)的通道维度扩展 3 倍。随后, 利用窗口分区操作将一维的序列($\mathbf{R}^{\left(3\times B\times \frac{H}{w}\times\frac{W}{w}\times h\right)\times(w\times w)\times\frac{C}{h}}$)切分为向量序列($\boldsymbol{Q},\boldsymbol{K},\boldsymbol{V}$), 其中, B 为特征批次尺寸, w 为窗口的尺寸, h 为多头注意力的数量, $\boldsymbol{Q}$ 为注意力机制的 Query 向量, $\boldsymbol{K}$ 为注意力机制的 Key 向量, $\boldsymbol{V}$ 为注意力机制的 Value 向量。具体而言, 这里将通道维度统一设置为 64, 滑窗尺寸和多头注意力的数量都设置为 8。然后, 全局特征分支利用多头自注意力机制捕获全局语义特征信息。

在常用的特征融合方式中通常引入求和或乘积操作来融合全局支路与局部支路所提取的特征信息, 这种方式虽然简单且不会增加模型的复杂度, 但却缺少对遥感图像空间一致性的考虑, 容易导致最终语义分割精度的恶化。由此, 在全局语义信息与局部细节特征融合的过程中, GLFFM 额外引入了十字语义交互模块。如图 8 所示, 十字语义

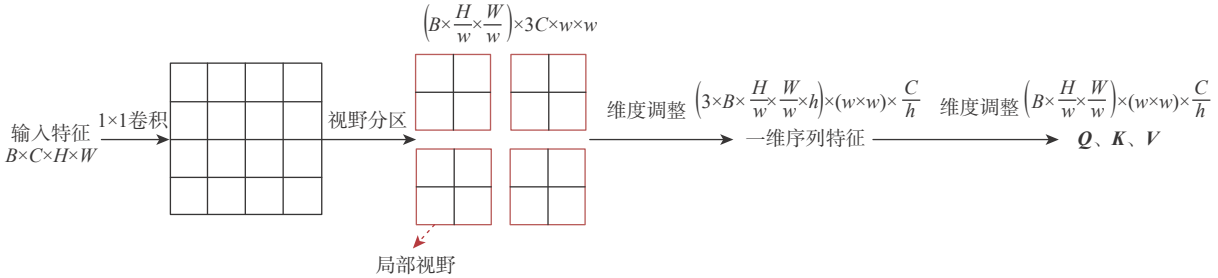


图 7 特征滑窗操作

Fig. 7 Feature sliding window operation

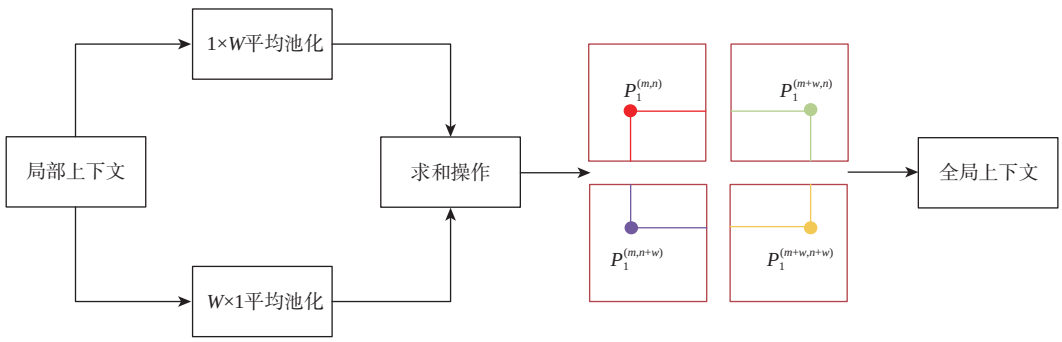


图 8 十字语义交互模块

Fig. 8 Crosswise semantic interaction module

交互模块首先通过一个水平的平均池化层和一个垂直的平均池化层分别生成 2 个特征图，随后，将 2 个特征图相加从而捕获跨视野的全局特征信息。其中，水平的平均池化层建立全局-局部之间水平方向关系的过程如式 (1) 所示。具体而言，对于视野 1 中的任意一点，其与视野 2 中点的依赖关系可以建模为式 (2)～式 (5)：

$$W_{\text{in1}} = H_{\text{p}}(W_{\text{in2}}) \tag{1}$$

$$P_1^{(m,n)} = \left(\sum_{i=0}^{w-m-1} P_1^{(m+i,n)} + \sum_{j=0}^{m} P_2^{(m+2-j,n)}\right)/w \tag{2}$$

$$P_1^{(m+i,n)} = D_i(P_1^{(m,n)}) \tag{3}$$

$$P_2^{(m+w-j,n)} = D_j(P_2^{(m+w,n)}) \tag{4}$$

$$P_1^{(m,n)} = \left(\sum_{i=0}^{w-m-1} D_i\left(P_1^{(m,n)}\right) + \sum_{j=0}^{m} D_2\left(P_2^{(m+w,n)}\right)\right)/w \tag{5}$$

式中：W_{ini} 为第 i 个视野的窗口特征；H_{p} 为水平池化操作；D表示自注意力操作，其可以建立一个局部视野内像素对之间的依赖关系。因此，对于任何一个在视野 1 中的其他点 $P_1^{(m+i,n)}$ 而言，其与点 $P_1^{(m,n)}$ 的跨视野交互关系都可以用式 (3) 进行建模。同样的，对于任何一个在视野 2 中的其他点 $P_2^{(m+w-j,n)}$，其与点 $P_2^{(m+w,n)}$ 的交互关系可以用式 (4) 建模。由此，式 (2) 也可以用式 (5) 来建模点 $P_1^{(m,n)}$ 与点 $P_2^{(m+w,n)}$ 的跨视野交互关系。实际上，上述跨视野像素点之间的交互也就是局部视野 1 与局部视野 2 在水平方向上的语义信息交互过程。与此类似，视野 1 和视野 3 或视野 2 与视野 4 之间的交互过程也可以通过垂直方向的池化层来实现。采用这种方式，十字语义交互模块可以在不同的视野上对全局与局部的语义信息进行建模，以捕获完整的上下文信息。

2 实验结果与分析

2.1 实验配置

本文选用深度学习框架 Pytorch V1.7.0 搭建航拍图像语义分割算法模型，操作系统为 Windows10，并行计算框架为 CUDA V10.1、CUDNN V8.0.3.33。硬件平台配置参数如下：CPU 为 Intel Core i7-9700 K，GPU 为 NVIDIA GTX 3090，内存 32 GB，显存 24 GB。

在算法训练过程中，本文构建了一个额外的辅助模块来优化各阶段 GLFFM 的参数训练。如图 1 所示，这种多头分割架构实际上在早前的研究工作中已经被证实是非常有效的。基于这种多头分割架构，本文采用一个损失函数和一个辅助损失函数共同训练语义分割算法模型。语义分割训练主损失函数 L_{p} 由一个交叉熵损失函数 L_{ce} 和一个 DICE 损失函数 L_{dice} 组成，具体如下：

$$L_{\text{ce}} = -\frac{1}{N}\sum_{n=1}^{N}\sum_{k=1}^{K} y_k^{(n)} \ln \tilde{y}_k^{(n)} \tag{6}$$

$$L_{\text{dice}} = 1 - \frac{2}{N}\sum_{n=1}^{N}\sum_{k=1}^{K} \frac{\tilde{y}_k^{(n)} y_k^{(n)}}{\tilde{y}_k^{(n)} y_k^{(n)}} \tag{7}$$

$$L_{\text{p}} = L_{\text{ce}} + L_{\text{dice}} \tag{8}$$

式中: N和K分别为样本数量和类别数量; $y^{(n)}$和$\tilde{y}^{(n)}$分别为真实语义标签的独立热编码和网络相应输出结果的Softmax(·)激活值; 而$\tilde{y}_k^{(n)}$则是样本对应类别的置信度值。对于辅助损失L_{aux}, 本文直接使用交叉熵损失函数进行计算, 如式 (6) 所示。具体而言, 辅助模块以 3 个阶段的 GLFFM 加权融合后的结果为输入, 利用一个3×3的卷积层、批归一化层、Relu激活函数, 以及一个1×1的卷积层和上采样层进行处理, 从而得到最终的辅助预测结果。此外, 为实现最优的损失组合方式, 还额外引入了一个值为 0.44 的尺度加权因子α。整个算法模型训练过程的损失计算式为

$$L = L_{\text{p}} + \alpha L_{\text{aux}} \tag{9}$$

航拍图像语义分割算法训练与性能评估的数据采用的是无人机语义分割数据集(unmanned aerial vehicle semantic segmentation dataset, UAVID)。该数据集具有空间分辨率高、空间差异性大、分类模糊、场景复杂的特点, 符合本文研究的主要内容场景。UAVID 共包含 42 个飞行序列的 420 张高分辨率图像(图像像素分辨率为 3 820 像素×2 160 像素与 4 096 像素×2 160 像素), 按照官方的分配方式, 其中, 200 张图像用于训练, 70 张图像用于验证, 150 张无标签的图像用于测试。数据格式上, 本文将图像统一填充并裁剪为 8 张像素分辨率为 1 024 像素×1 024 像素的图像。在训练过程中, 统一按照 0.5 的概率对图像进行随机水平翻转、随机亮度调整以增强数据分布。本文选用的优化器为 AdamW, 初始学习率设置为6×10^{-4}, 并使用余弦策略对学习率进行衰减, 整个训练周期为 30 个轮次, 每批次训练图像的数量 Batch Size 为 8。

2.2　评估指标

语义分割任务的结果可以分为: 真正例(true positive, TP)表示真实值与预测值相同且为正样本; 真负例(true negative, TN)表示真实值与预测值相同且为负样本; 假正例(false positive, FP)表示预测值为正样本, 而实际值为负样本; 假负例(false negative, FN)表示预测值为负样本, 而实际值为正样本。MIoU 是指平均交并比(mean intersection-over-union), 用于衡量模型在各个类别上的预测准确度。该指标将每个类别的交集和并集之比的平均值作为模型的评估指标。对于每个类别, 将预测的分割结果与真实标签进行比较, 计算出该类别的 IoU 值, 然后, 将所有类别的 IoU 值求平均便可得到平均交并比, 具体的计算如式 (10) 所示。此外, MIoU 的值越高, 则表示模型的性能越好, 表示模型能够更加准确地分割各个类别。

$$M_{\text{IoU}} = \frac{1}{k+1}\sum_{i=0}^{k}\frac{T_{\text{P}}}{F_{\text{N}}+F_{\text{P}}+T_{\text{P}}} \tag{10}$$

2.3　结果分析

本文选择最高有效位(most significant digit, MSD)[14]、交叉注意力网络(cross attention network, CANet)[15]、双注意力网络(dual attention network, DANet)[16]、SwiftNet[17]、BiSeNet[18]、多尺度注意力网络(multi-scale attention network, MANet)[19]、ABCNet[20]、SegFormer[21]、双边注意力网络(bilateral attention network, BANet)[22]、BoTNet[23]、CoaT[24]、Segmenter[25]、快速分割卷积神经网络(fast-segmentation convolutional neural network, Fast-SCNN)[26]、特征注意力网络(feature attention network, FANet)[27]、ShelfNet[28] 这 13 种算法作为对照算法, 在 UAVID 数据集上对本文 CAGNet 算法进行速度和精度 2 个维度的性能验证。如表 1 所示, 与速度最快、结构最轻量的算法 Fast-SCNN 相比, CAGNet 算法在 MIoU 指标上提高了 25.1%。同时, 与同样参数量的

表 1　不同算法的速度与精度对比

Table 1　Comparison of speed and accuracy for different algorithms

算法	内存量	参数量	复杂度	推理速度/(帧·s^{-1})	MIoU/%
Fast-SCNN[26]	619.4×10^6	1.1×10^6	3.4×10^9	222.7	45.9
Segmenter[25]	828.6×10^6	6.7×10^6	26.8×10^9	14.7	58.7
BiSeNet[18]	970.6×10^6	12.9×10^6	51.8×10^9	121.9	61.5
DANet[16]	611.1×10^6	12.6×10^6	39.6×10^9	189.4	60.6
FANet[27]	971.9×10^6	13.6×10^6	86.8×10^9	94.9	
ShelfNet[28]	579.0×10^6	14.6×10^6	46.7×10^9	141.4	47.0
SwiftNet[17]	835.8×10^6	11.8×10^6	51.6×10^9	138.7	61.1
MANet[19]	1 169.2×10^6	12.0×10^6	51.7×10^9	75.6	62.6
ABCNet[20]	1 105.1×10^6	14.0×10^6	62.9×10^9	102.2	63.8
Segformer[21]	933.2×10^6	13.7×10^6	63.3×10^9	31.3	66.0
BoTNet[23]	710.5×10^6	17.6×10^6	49.9×10^9	135.0	63.2
CoaT[24]	3 133.8×10^6	11.1×10^6	104.8×10^9	10.6	65.8
CAGNet	1 203.7×10^6	12.4×10^6	49.3×10^9	110.3	71.0

其他CNN算法相比，CAGNet实现了110.3帧/s的推理速度，且在MIoU指标上超过了其他算法7.2%以上。值得注意的是，CAGNet算法超过了最先进的基于混合空间变换网络的CoaT算法5.2%的MIoU，同时实现了10倍的速度提升。此外，本文CAGNet算法比使用Transformer网络的其他语义分割算法在MIoU指标上高出了12.3%，速度上提升了近7倍。基于以上分析，可以得出以下结论：无论是综合考虑航拍图像语义分割算法速度还是精度上的表现，本文CAGNet算法都是非常出色的。

为充分验证CAGNet算法的先进性，本文还找了12个实用有效的语义分割算法，并在UAVID官方提供的测试数据上进行了详细的比较。如表2所示，CAGNet算法不仅实现了最佳的MIoU性能71.0%，还在每个类别IoU上实现了出色的优势性能。具体而言，CAGNet算法不仅在MIoU指标上比最出色的CNN算法高出了7.2%的性能，还比基于混合空间变换网络的BANet算法和BoTNet算法分别高出了6.4%和7.8%。此外，尽管“人类”这一类别在航拍图像中属于极小的目标，且由于航拍角度的问题也会存在尺度变化比过大的情况，但是CAGNet算法却实现了34.8%的IoU值，远远高于其他算法。由此，可以充分说明，CAGNet算法在解决高分辨率航拍图像语义分割问题时具有出色的有效性与先进性。

表2 不同算型的类别精度对比

Table 2 Comparison of class-wise accuracy for different algorithms

算法	IoU/%								MIoU/%
	杂波	建筑	道路	树木	植被	移动汽车	静止汽车	人类	
MSD[14]	57.0	79.8	74.0	74.5	55.9	62.9	32.1	19.7	57.0
CANet[15]	66.0	86.6	62.1	79.3	78.1	47.8	68.3	19.9	63.5
DANet[16]	64.9	85.9	77.9	78.3	61.5	59.6	47.4	9.1	60.6
SwiftNet[17]	64.1	85.3	61.5	78.3	76.4	51.1	62.1	15.7	61.1
BiSeNet[18]	64.7	85.7	61.1	78.3	77.3	48.6	63.4	17.5	61.5
MANet[19]	64.5	85.4	77.8	77.0	60.3	67.2	53.6	14.9	62.6
ABCNet[20]	67.4	86.4	81.2	79.9	63.1	69.8	48.4	13.9	63.8
Segmenter[25]	64.2	84.4	79.8	76.1	57.6	59.2	34.5	14.2	58.7
SegFormer[21]	66.6	86.3	80.1	79.6	62.3	72.5	52.5	28.5	66.0
BANet[22]	66.7	85.4	80.7	78.9	62.1	69.3	52.8	21.0	64.6
BoTNet[23]	64.5	84.9	78.6	77.4	60.5	65.8	51.9	22.4	63.2
CoaT[24]	69.0	88.5	80.0	79.3	62.0	70.0	59.1	18.9	65.8
CAGNet	72.2	89.5	84.7	82.1	67.9	76.8	59.6	34.8	71.0

为更全面的对CAGNet算法效果进行全面的评估，本文将算法在UAVID数据集的验证集与测试集上的预测结果进行了可视化，通过可视化图像对模型的先进性与有效性进行了定性的评价。

CAGNet算法在UAVID数据集验证集上的可视化结果如图9所示，本文选取对航拍场景更具有代表性的三类图像作为输入图像，经过CAGNet算法推理后，将语义分割预测结果与真实标签采用相同的方式进行可视化。无论是对微小的地面车辆还是对极小的路边行人，又或者对尺度较大的地面植被和建筑物，CAGNet算法的预测结果较真值标签而言，都具有很好的识别与分割效果，唯一的瑕疵在于对形状不规则的植被覆盖区域的边界分割不够精确，容易出现错误的判定，但从全图的维度来衡量算法效果，已经能够充分证明，CAGNet算法在UAVID数据集所对应的航拍场景下可以十分完美地完成语义分割任务。

此外，CAGNet算法在UAVID数据集测试集上也能够在图像尺度对各困难类别进行准确的判定与分割。如图10所示，选取城市、乡村、野外等不同场景的图像作为测试样本，可以看出，CAGNet在如此复杂的航拍场景下依然实现了出色的语义分割效果。图10中，白框所框选的区域不仅存在复杂的地物关系还含有大量的杂波干扰，导致算法在这些地方的分割效果较真值标签有一定差异，但是在航拍图像智能分析任务中，可视化图像的分割效果与当前的技术要求相比已基本满足实际场景的任务需求。这一结论既证明了CAGNet算法在高分辨率航拍遥感图像语义分割场景下的出色能力，也反映出当下的算法可能在鲁棒性和领域泛化能力上存在不足，因而出现测试集未知遥感场景中分割精度有所下降的情况。

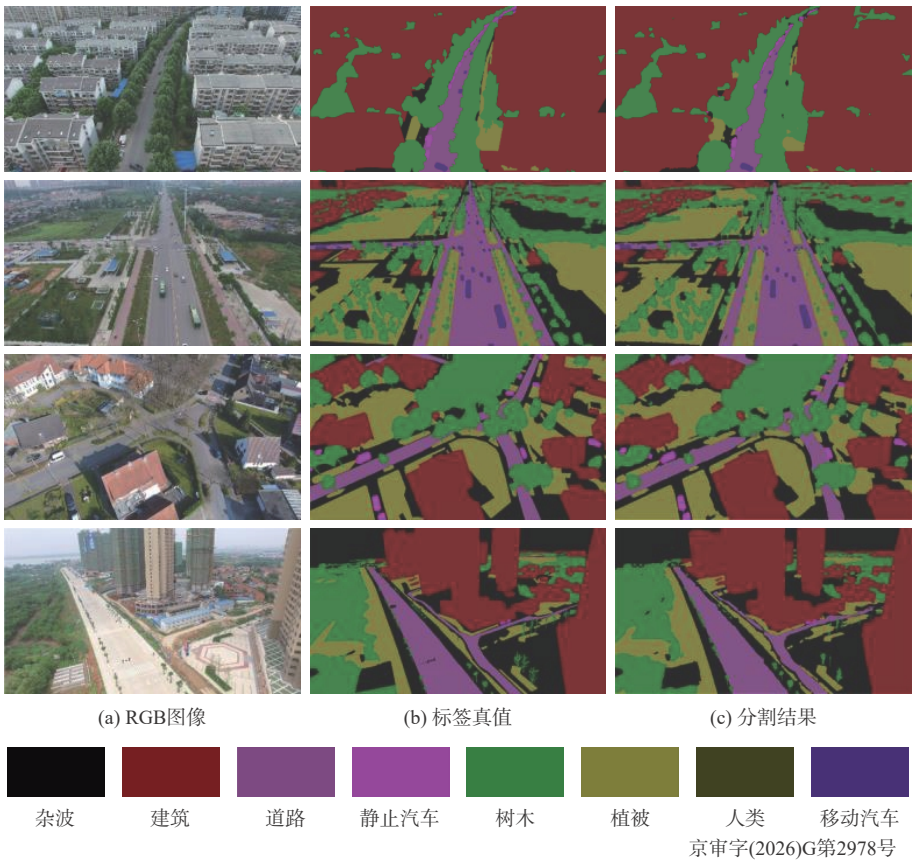


图 9　验证集可视化结果

Fig. 9　Visualization results of validation set

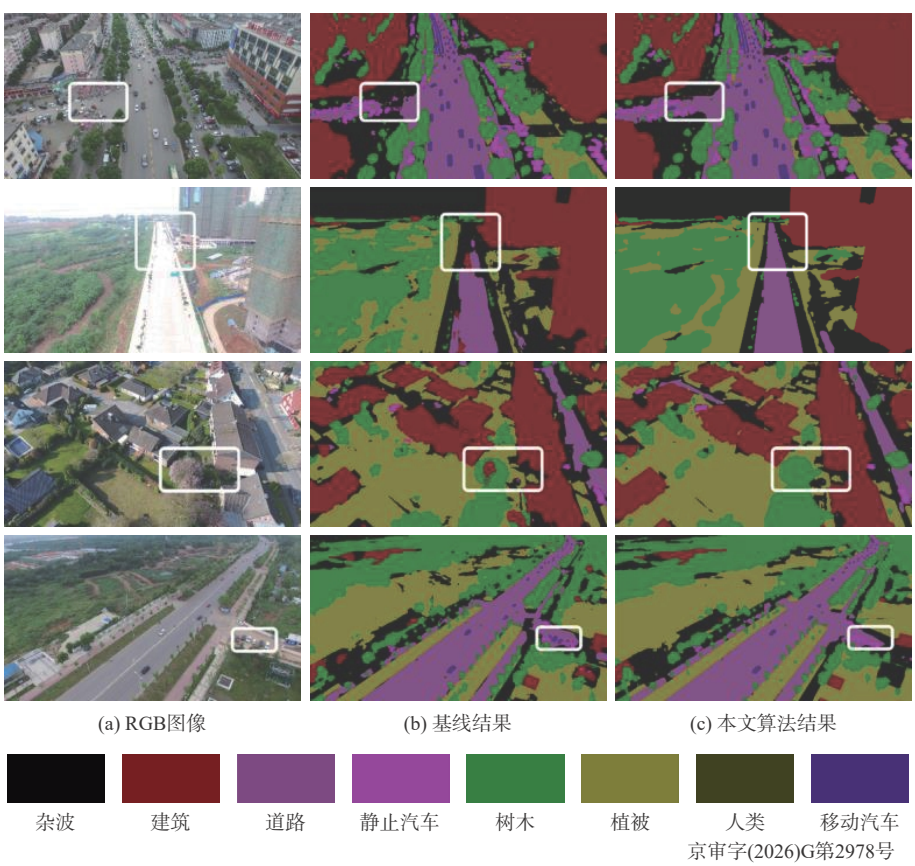


图 10　测试集可视化结果

Fig. 10　Visualization results of test set

如图 9 和图 10 所示，尽管 CAGNet 算法整体分割效果良好，但在形状不规则且纹理复杂的植被覆盖区域，边界精细化仍存在不足，这主要源于多尺度上下文融合过程中细粒度边缘信息在深层特征中被弱化的问题；为此计划在后续工作中引入边缘感知模块、基于梯度的边界损失或轻量级边界解码器以专门提升边界精度，进而改善本文 CAGNet 算法在复杂区域边界分割不精确的问题。

2.4 消融实验

为验证本文算法的有效性，利用 UAVID 数据集的训练集与测试集进行消融实验。在其他参数配置相同的情况下，共进行了 A、B、C、D 这 4 个方案的消融实验。其中，方案 A 使用 ResNet-18 作为特征编码模块，利用上采样模块将最深层特征图上采样成输入图像的大小，得到语义分割的结果；方案 B 在方案 A 的基础上引入 CAM 对高维语义特征进行挖掘，得到语义分割结果；方案 C 在方案 B 的基础上引入 GLFFM 对全局与局部特征进行交互融合，得到语义分割结果；方案 D 则是本文 CAGNet 算法。

如图 11 所示，与方案 A 相比，方案 B 引入了 CAM，在一定程度上增强 FEM 对航拍图像地物关系的建模能力，故 MIoU 提升了 0.7%。其次，方案 C 与方案 A 和方案 B 相比，方案 C 额外增加了 GLFFM，使得算法的分割性能和 MIoU 分别提升了 3.4% 和 2.7%。这组对比可以看出，语义分割模型的特征解码功能与编码提取功能同样重要，仅仅提升模型的特征编码能力无法显著提升其分割效果。随后，方案 D 与方案 C 相比，方案 D 的分割性能 MIoU 较方案 C 提升了 2.2%，可见，语义分割任务是逐像素判别的精确任务，同时提升模型远距离建模与语义交互能力会影响最终的分割效果。综上所述，本文提出的 CAM 与 GLFFM 在提升模型的分割性能上具有显著作用。

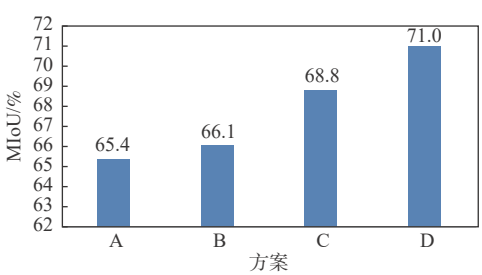


图 11 不同方案的消融实验

Fig. 11 Ablation study on different proposal

3 结 论

1）本文针对航拍图像地物关系复杂、目标尺度多变、类别分布失衡、杂波干扰较多的问题，提出了一种上下文注意力引导的航拍图像语义分割算法。

2）本文提出的协同注意力模块通过在空间和通道 2 个维度上对上下文特征信息进行挖掘，提升算法对不同类别间相似目标的判别能力。

3）本文提出的全局-局部特征融合模块利用全局与局部双分支网络，实现大感受野与小感受野之间语义信息的交互与融合，提升语义分割的精确度。

4）在真实航拍场景中采集的 UAVID 数据上开展的对比实验与消融实验的结果表明，本文 CAGNet 算法在速度与精度上均显著高于其他 15 种对比算法，并且提高了相同类别目标在各种尺寸下的分割精度，表现出算法在航拍图像语义分割任务上的先进性与有效性。

参考文献（References）

[1] Zhong H F, Sun H M, Han D N, et al. Lake water body extraction of optical remote sensing images based on semantic segmentation[J]. Applied Intelligence, 2022, 52(15): 17974-17989.

[2] Yuan Q Q, Shen H F, Li T W, et al. Deep learning in environmental remote sensing: achievements and challenges[J]. Remote Sensing of Environment, 2020, 241: 111716.

[3] Zhang Q L, Seto K C. Mapping urbanization dynamics at regional and global scales using multi-temporal DMSP/OLS nighttime light data[J]. Remote Sensing of Environment, 2011, 115(9): 2320-2329.

[4] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2015: 3431-3440.

[5] Noh H, Hong S, Han B. Learning deconvolution network for semantic segmentation[C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2016: 1520-1528.

[6] Badrinarayanan V, Kendall A, Cipolla R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481-2495.

[7] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[M]//Medical Image Computing and Computer-Assisted Intervention-MICCAI. Berlin: Springer, 2015: 234-241.

[8] Liu W, Rabinovich A, Berg A C. ParseNet: looking wider to see better[EB/OL]. (2015-06-15)[2025-06-02]. https://arxiv.org/abs/1506.04579.

[9] Zhao H S, Shi J P, Qi X J, et al. Pyramid scene parsing network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2017: 6230-6239.

[10] Chen L C, Papandreou G, Kokkinos I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs[EB/OL]. (2014-12-22)[2025-06-02]. https://arxiv.org/abs/1412.7062.

[11] Schwing A G, Urtasun R. Fully connected deep structured net-

works[EB/OL]. (2015-03-09)[2025-06-02]. https://arxiv.org/abs/1503.02351.

[12] Zheng S, Jayasumana S, Romera-paredes B, et al. Conditional random fields as recurrent neural networks[C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2016: 1529-1537.

[13] Lin G S, Shen C H, Van Den Hengel A, et al. Efficient piecewise training of deep structured models for semantic segmentation[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 3194-3203.

[14] Lyu Y, Vosselman G, Xia G S, et al. UAVid: a semantic segmentation dataset for UAV imagery[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 165: 108-119.

[15] Yang M Y, Kumaar S, Lyu Y, et al. Real-time semantic segmentation with context aggregation network[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021, 178: 124-134.

[16] Fu J, Liu J, Tian H J, et al. Dual attention network for scene segmentation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 3141-3149.

[17] Oršić M, Šegvić S. Efficient semantic segmentation with pyramidal fusion[J]. Pattern Recognition, 2021, 110: 107611.

[18] Yu C Q, Wang J B, Peng C, et al. BiSeNet: bilateral segmentation network for real-time semantic segmentation[C]//Proceedings of the European Conference on Computer Vision-ECCV. Berlin: Springer, 2018: 334-349.

[19] Li R, Zheng S Y, Zhang C, et al. Multiattention network for semantic segmentation of fine-resolution remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5607713.

[20] Li R, Zheng S Y, Zhang C, et al. ABCNet: attentive bilateral contextual network for efficient semantic segmentation of Fine-Resolution remotely sensed imagery[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2021, 181: 84-98.

[21] Xie E Z, Wang W H, Yu Z D, et al. SegFormer: simple and efficient design for semantic segmentation with transformers[J]. Advances in neural information processing systems, 2021, 34: 12077-12090.

[22] Wang L B, Li R, Wang D Z, et al. Transformer meets convolution: a bilateral awareness network for semantic segmentation of very fine resolution urban scene images[J]. Remote Sensing, 2021, 13(16): 3065.

[23] Srinivas A, Lin T Y, Parmar N, et al. Bottleneck transformers for visual recognition[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2021: 16514-16524.

[24] Xu W J, Xu Y F, Chang T, et al. Co-scale conv-attentional image transformers[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2022: 9961-9970.

[25] Strudel R, Garcia R, Laptev I, et al. Segmenter: transformer for semantic segmentation[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2022: 7242-7252.

[26] Poudel R P K, Liwicki S, Cipolla R. Fast-SCNN: fast semantic segmentation network[EB/OL]. (2019-02-12)[2025-06-03]. https://arxiv.org/abs/1902.04502.

[27] Hu P, Perazzi F, Heilbron F C, et al. Real-time semantic segmentation with fast attention[J]. IEEE Robotics and Automation Letters, 2021, 6(1): 263-270.

[28] Zhuang J T, Yang J L, Gu L, et al. ShelfNet for fast semantic segmentation[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision Workshop. Piscataway: IEEE Press, 2020: 847-856.

Semantic segmentation algorithms of aerial images via context-aware attention guidance

LIU Lulu[1,*], XIE Ronglei[2], JI Jiachi[3]

(1. Hangzhou Innovation Institute of Beihang University, Hangzhou 310051, China;
2. HIWING Technology Academy of CASIC, Beijing 100074, China;
3. School of Aeronautic Science and Engineering, Beihang University, Beijing 100191, China)

Abstract: Semantic segmentation algorithms for aerial images have significant research and application value in fields such as land use classification, environmental monitoring, resource surveying, and urban planning. To address the challenges posed by high-resolution aerial images—such as complex spatial relationships among objects, varying target scales, large intra-class variations, and high inter-class similarities—this paper proposes a context attention-guided semantic segmentation algorithm. In order to improve the network's ability to represent features, a collaborative attention module is added to the encoder stage of the model. This module pulls features from both spatial and channel dimensions. To efficiently extract both semantic information and detailed features, a global-local feature fusion module is built in the decoder stage using concurrent global and local branches. Furthermore, a crisscross semantic interaction module is employed to fuse multi-level features, improving the model's ability to distinguish object boundaries. Experimental results demonstrate that the proposed algorithm achieves a mean intersection-over-union(MIoU)of 71.0% on the UAVID dataset, significantly outperforming state-of-the-art algorithms in both accuracy and inference speed.

Keywords: semantic segmentation; aerial images; attention mechanism; deep learning; feature fusion

Received: 2025-06-09; **Accepted**: 2025-08-06; **Published Online**: 2025-08-29 16:00

URL: link.cnki.net/urlid/11.2625.V.20250829.1511.001

Foundation item: Jianghuai Frontier Technologies Collaborative Innovation Center Dream Pursuit Fund (2023-ZM01X008)

* **Corresponding author**. E-mail: liu_lulu@buaa.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0491

基于无迹模型预测静态规划的可回收火箭着陆段鲁棒制导方法

张永华[1, 2, 3]，王铮[1, 2, 3, 4, 5, *]，王时雨[6]，白云飞[6]，仇理宽[7]

(1. 西北工业大学 无人系统技术研究院，西安 710072；2. 无人飞行器技术全国重点实验室，西安 710072；3. 无人机技术集成攻关大平台，西安 710072；4. 西北工业大学 航天飞行动力学技术重点实验室，西安 710072；5. 西北机电工程研究所，咸阳 712099；6. 中国运载火箭技术研究院，北京 100076；7. 上海机电工程研究所，上海 201109)

摘　　要：针对可回收火箭大气层内存在不确定风场难以完成定点垂直软着陆的问题，提出基于无迹模型预测静态规划（UMPSP）的着陆段鲁棒制导方法。建立火箭推力与姿态耦合的动力学模型，在考虑未知不确定风场的前提下，根据无迹最优控制与模型预测静态规划 (MPSP) 理论求解出一组对原系统不确定风场参数不敏感的控制解，从而减小终端状态的误差分布，提高着陆精度；结合 UMPSP 算法特点，设计了一种快速解析制导方法以生成初始控制指令，有效提高了算法的求解效率。仿真结果表明：所提基于 UMPSP 的着陆段鲁棒制导方法能够在保证可回收火箭终端着陆精度的同时，对各种不确定风场具有较强的鲁棒性和较高的计算效率。

关 键 词：模型预测静态规划；可回收火箭；不确定风场；制导与控制；鲁棒制导
中图分类号：V448.1
文献标志码：A　　**文章编号**：1001-5965(2026)11-3929-12

可回收火箭技术聚焦于火箭组件的回收与再利用，因其可显著降低发射成本并提升任务执行的时效性，近年来已成为航天工程领域的研究热点[1]。该技术的核心优点及最终目的是减少一次性运载火箭在使用后抛弃昂贵箭体、发动机及电气设备所产生的资源浪费，通过复用这些关键部件来分摊成本，大幅度削减单次发射的开支[2]。在可回收火箭的动力着陆阶段，利用大气阻力和火箭发动机的反推力来减缓下降速度，从而确保火箭能够实现定点的垂直软着陆，这一阶段被认为是实现可回收火箭成功软着陆的关键技术挑战。然而，着陆过程中遭遇的环境干扰众多，特别是不可预知的风场变化，给着陆段制导算法设计与实施带来了复杂而严峻的挑战。

目前，大多数着陆段制导方法通过轨迹规划方法来完成制导任务，其通过综合考虑动力学模型、环境约束及目标函数等因素，生成满足多方面性能指标的最优或次优飞行路线，从而为复杂的着陆操作提供可靠指引。早期阿波罗登月[3]、嫦娥三号探月[4]等真实航天任务中多采用形式简洁直观且易于工程实现的解析制导方法，典型实例包括重力转弯制导方法[5]及近似最优解析制导[6]（如零控制位置/速度误差制导算法）。近年来，研究人员针对可回收火箭着陆段制导问题采用了更准确的动力学模型，同时，利用轨迹规划方法对其进行求解，取得了较大进展。凸优化方法作为轨迹规划方法中的重要分支，因其独特的理论优势和快速稳定的求解效率，逐渐在航天器动力下降领域获得了广泛应用，其对非凸问题进行凸化或近似凸化，将连续动态系统经离散化手段转化为有限维离散系统，继而利用

收稿日期：2024-06-28；**录用日期**：2024-08-16；**网络出版时间**：2024-09-14 17:07
网络出版地址：link.cnki.net/urlid/11.2625.V.20240914.1142.001
基金项目：国家自然科学基金 (62303378)；测试物理与数值数学科学技术国家重点实验室基金 (JP2022-800006000107-237,08-YY-2023-R11)；上海航天科技创新基金 (SAST2022-114)
* **通信作者**. E-mail：wz_nwpu@126.com

引用格式：*张永华，王铮，王时雨，等. 基于无迹模型预测静态规划的可回收火箭着陆段鲁棒制导方法 [J]. 北京航空航天大学学报，2026，52（11）：3929-3940. Zhang Y H，Wang Z，Wang S Y，et al. A robust guidance method for reusable rocket landing phase based on UMPSP[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：3929-3940（in Chinese）.*

成熟的求解工具实现高效求解[7-8]。文献[9-10]通过在每个迭代步骤中,对非线性系统动力学方程进行局部线性化或凸化,使原本的非凸优化问题转变为一系列凸优化问题,从而保证每个子问题都能在较短时间内找到全局最优解,显著减少了整个优化过程所需的迭代次数。文献[11-12]针对姿态与轨迹耦合下火箭的着陆问题,结合虚拟控制和信赖域方法,确保火箭在着陆过程中既稳定又精确地执行姿态调整和轨迹跟踪。文献[13]将导弹制导中经典的比例导引方法与凸优化相结合,简化了火箭着陆段的优化模型,提高了求解效率。目前,基于凸优化理论的轨迹规划方法已经被广泛应用于可回收火箭着陆段的制导规划中,然而上述方法普遍忽视了模型中不确定性因素的潜在影响,未能充分考虑外界扰动尤其是不确定风场对火箭着陆的干扰。此外,尽管凸优化方法提升了制导精度,满足了过程约束要求,但在求解效率方面仍存在一定的局限性。

模型预测静态规划(model predictive static programming, MPSP)算法[14]在解决带有终端约束的最优控制问题中有着较大的优势,其立足于数值积分,不需要直接对飞行器模型进行线性化,同时,算法收敛性较好,并不需要进行过多次积分运算,目前,在航天器变轨、飞行器轨迹跟踪及再入制导等领域,存在着广泛的研究和应用[15-18]。为提高MPSP算法在制导应用中的计算效率和精度,研究人员提出了多种改进算法:文献[19]针对导弹再入制导这一复杂问题,在连续时间框架内设计了一种广义MPSP算法,避免了传统MPSP算法对动力学方程的离散处理,从而提高了算法的求解精度。文献[20]则提出一种基于拟谱法的MPSP算法,用于导弹的制导,通过将控制变量表示为谱函数的形式,进一步降低了变量的维度。然而,以上MPSP算法均针对确定性问题,而没有考虑系统参数的不确定性,这在某些应用中可能限制了其发展[21]。为解决该问题,文献[22]提出无迹模型预测静态规划(unscented model predictive static programming, UMPSP)算法,将无迹最优控制思想与MPSP算法相结合,显著提升了终端状态的鲁棒性,已被应用于卫星的软着陆中[23-24]。

针对可回收火箭着陆段制导问题,现有方法多忽略绕质心运动,直接将火箭三轴加速度作为控制量进行规划设计。然而因火箭轨迹与姿态运动不能解耦,忽略火箭姿态动力学势必会对火箭的终端着陆精度与稳定性造成不利影响,与此同时,火箭着陆段由于未知不确定风场的存在,不考虑其影响会使系统存在模型偏差,当火箭接近目标着陆点时,在风干扰的影响下,终端状态无法稳定收敛,这可能导致控制量出现剧烈波动,从而无法可靠地实现定点垂直软着陆[25]。考虑到以上问题和需求,本文提出基于UMPSP的可回收火箭着陆段鲁棒制导方法。首先,建立火箭推力与姿态相互耦合的动力学模型,在考虑大气层内存在不确定风场和过程约束的前提下,根据无迹最优控制与MPSP算法理论求解出一组对原系统不确定风场参数不敏感的控制解;针对实际场景中的不确定风场完成Sigma点的构建;其次,结合UMPSP算法的特点,设计一种快速解析制导方法来为其提供初始控制解,进一步提高求解效率;最后,通过仿真表明,本文方法在未知且不确定的风场条件下提高了火箭的着陆精度,不仅展现了较强的鲁棒性,还保持了较高的计算效率。

1 火箭着陆段分析和建模

1.1 火箭动力学模型

为描述火箭预期着陆点的位置,建立以该点为原点的惯性参考坐标系。在该坐标系中,x轴位于当地的水平面内,并指向预先设定的方向;y轴在当地铅垂面内,以向上为正方向;z轴同样位于水平面内,其方向遵循右手法则确定。假设火箭的推力始终沿着其自身的轴体方向作用,并忽略地球的自转及地球的扁率,在火箭着陆阶段,考虑到推力与姿态之间的耦合关系,其运动方程可以表述为

$$\begin{cases} \dot{\boldsymbol{r}} = \boldsymbol{v} \\ \dot{\boldsymbol{v}} = \boldsymbol{g} + \dfrac{T}{m}\begin{bmatrix} \cos\varphi\cos\psi \\ \sin\varphi\cos\psi \\ -\sin\psi \end{bmatrix} + \dfrac{\boldsymbol{D}}{m} \\ \dot{m} = -T/V_{\mathrm{ex}} \\ \dot{\varphi} = \omega_{\varphi} \\ \dot{\psi} = \omega_{\psi} \end{cases} \tag{1}$$

式中:$\boldsymbol{r}=[r_x,r_y,r_z]^{\mathrm{T}}$为位置矢量;$\boldsymbol{v}=[v_x,v_y,v_z]^{\mathrm{T}}$为速度矢量;$\boldsymbol{g}$为重力加速度矢量;$T$为发动机推力;$m$为火箭质量;$\varphi$为俯仰角;$\psi$为偏航角;$\boldsymbol{D}$为气动阻力矢量;$V_{\mathrm{ex}}$为发动机排气速度,一般为常值;$\omega_{\varphi}$为俯仰角速度;$\omega_{\psi}$为偏航角速度。

气动阻力矢量$\boldsymbol{D}$可表示为

$$\boldsymbol{D} = -\frac{1}{2}\rho S C_D \|\boldsymbol{v}-\boldsymbol{v}_{\mathrm{w}}\|_2 (\boldsymbol{v}-\boldsymbol{v}_{\mathrm{w}}) \tag{2}$$

式中:ρ为大气密度;S为火箭气动等效面积;C_D为火箭阻力系数;$\boldsymbol{v}_{\mathrm{w}}$为风场速度矢量。

在火箭着陆规划过程中,选取状态向量为$\boldsymbol{x}=[r_x,r_y,r_z,v_x,v_y,v_z,m,\varphi,\psi]^{\mathrm{T}}$,控制向量为$\boldsymbol{u}=[T,\omega_{\varphi},\omega_{\psi}]^{\mathrm{T}}$。着陆段制导任务的初始时刻$t_0$给定,初始状态需满足相应的约束条件:

$$\begin{cases} \boldsymbol{r}(t_0)=\boldsymbol{r}_0 \\ \boldsymbol{v}(t_0)=\boldsymbol{v}_0 \\ m(t_0)=m_0 \\ \varphi(t_0)=\varphi_0 \\ \psi(t_0)=\psi_0 \end{cases} \tag{3}$$

火箭需要在给定的终端时刻t_f完成定点垂直软着陆, 终端状态需满足以下约束条件:

$$\begin{cases} \boldsymbol{r}(t_f)=\boldsymbol{0} \\ \boldsymbol{v}(t_f)=\boldsymbol{0} \\ \varphi(t_f)=\dfrac{\pi}{2} \\ \psi(t_f)=0 \end{cases} \tag{4}$$

1.2　风场不确定性与过程约束分析

在可回收火箭着陆段的实际任务中, 大气风场条件展现出了显著的随机性和复杂性。为在数学模型层面充分量化和表征这种不确定性, 利用文献 [26] 中的方法, 在风场模型中引入不确定参数, 这种不确定性可以通过定义随机变量或采用概率分布模型来表征, 从而更好地反映风场对火箭动态特性的影响。假设风场在z轴方向存在不确定性, 不确定风场 z 轴方向风速 $v_{w_z}=v_{w_z}(r_y,\boldsymbol{s})$, r_y 为 y 方向高度, $\boldsymbol{s}=[s_1,s_2,\cdots,s_d]^{\mathrm{T}}\in\mathbf{R}^d$为未知参数, d为未知参数的维度。具体有

$$v_{w_z}(r_y,\boldsymbol{s})=s_1 r_y^{*d-1}+s_2 r_y^{*d-2}+\cdots+s_d \tag{5}$$

式中: $r_y^*=(r_y-\mu)/\sigma$为标准化后的高度; μ和σ分别为实测风场数据中高度的均值和标准差, 均为已知的统计参数。

此外, 由于实际场景中y轴方向的风速对火箭着陆过程的动态响应和轨迹规划几乎不构成实质性影响, 因此, 假设y轴方向不存在风。对于x轴方向的风场, 假设风场参数已知, 满足:

$$v_{w_x}(r_y)=Kr_y+b \tag{6}$$

式中: v_{w_x}为 x 轴方向风速; K、b均为已知参数。

在火箭着陆过程中, 还需要考虑以下几种过程约束条件:

1) 推力幅值约束。如果设计的制导规划方法超出了火箭的控制能力和物理限制, 将无法满足安全和精确着陆的要求。为确保火箭能够在预定的着陆点实现稳定的垂直软着陆, 必须在制导规划的过程中对推力幅值施加严格的约束, 以适应火箭的实际状态, 即

$$0\leqslant T_{\min}\leqslant T\leqslant T_{\max} \tag{7}$$

式中: $T_{\min}$和$T_{\max}$分别为火箭推力的最小值与最大值, 在整个着陆阶段, 推力的设计值必须保持在这一限定范围内, 以确保火箭能够在可控状态下完成着陆任务。

该约束条件有助于避免因推力过大或过小而导致的不稳定情况, 从而保证火箭能够按照预定计划平稳着陆。

2) 最大角速度约束。在着陆段, 为降低对火箭姿态控制系统的要求, 需对姿态变化速度进行限幅, 以实现控制系统的稳定, 即

$$\begin{cases} |\omega_\varphi|\leqslant\omega_{\varphi\max} \\ |\omega_\psi|\leqslant\omega_{\psi\max} \end{cases} \tag{8}$$

式中: $\omega_{\varphi\max}$为最大俯仰角速度; $\omega_{\psi\max}$为最大偏航角速度。

3) 燃料剩余量约束。由于火箭在进入着陆阶段之前已经经历了包括起飞、加速及轨道调整在内的多个飞行阶段, 其剩余燃料量已显著减少。因此, 在制定着陆段的制导规划时, 为确保火箭有足够的燃料来进行精确的着陆控制, 同时, 避免因燃料不足而导致的任何潜在风险, 需要考虑燃料剩余量的约束:

$$\begin{cases} m(t_0)=m_{\mathrm{wet}} \\ m(t_f)\geqslant m_{\mathrm{dry}} \end{cases} \tag{9}$$

式中: $m(t_0)$为着陆段制导任务开始时刻火箭的总质量; m_{wet}为包含燃料的总质量; $m(t_f)$为着陆段制导任务结束时刻火箭的总质量; m_{dry}为在极限情况下火箭完全耗尽燃料后的总结构质量, 为着陆段制导任务过程中的质量下限。

从上述轨迹规划问题模型中可以看出, 着陆段制导任务的核心目标是在不确定风场的干扰作用下, 确保火箭能够同时满足过程约束和终端状态约束, 从而实现可回收火箭的垂直软着陆。这不仅要求火箭系统具有抵抗由外部环境引入的非确定性干扰的能力, 还需确保在整个着陆过程中, 火箭的各项参数(如速度、位置和姿态等)都严格遵守既定的约束条件, 才能保障火箭安全、精准地在预定地点实现垂直软着陆, 从而为后续的重复使用奠定坚实的基础。

2　UMPSP 数学推导

2.1　无迹最优控制

为解决系统参数的不确定性, 文献 [22] 提出了无迹最优控制的概念, 将无迹变换与最优控制概念相结合, 降低了系统不确定性对控制解的影响。

连续时间下的一般非线性系统可定义为

$$\dot{\boldsymbol{X}}(t)=f(\boldsymbol{X},\boldsymbol{U},\boldsymbol{p},t) \tag{10}$$

$$\boldsymbol{Y}(t)=h(\boldsymbol{X},t) \tag{11}$$

式中: $\boldsymbol{X}\in\mathbf{R}^n$、$\boldsymbol{U}\in\mathbf{R}^l$、$\boldsymbol{Y}\in\mathbf{R}^o$、$\boldsymbol{p}\in\mathbf{R}^{n_p}$分别为状态、

控制、输出和系统参数，n、l、o、n_p为参数维度。$t\in[t_0,t_{\mathrm{f}}]$为时间。

系统的状态被定义为

$$\boldsymbol{X}\triangleq[x_1,x_2,\cdots,x_n]^{\mathrm{T}}\in\mathbf{R}^n \tag{12}$$

无迹最优控制的目标是设计一种对原系统不确定参数不敏感的控制解，从而减小输出的误差散布，提高鲁棒性。根据无迹变换理论，可以通过有限的Sigma点来估计对概率分布函数应用非线性变换的结果。通过考虑参数的均值μ_p和协方差矩阵$\boldsymbol{P}_p$，Sigma点可以表示为

$$\begin{cases}p_0=\mu_p\\ p_j=\mu_p+\left(\sqrt{|\boldsymbol{P}_p|}\right)_j & j=1,2,\cdots,n_p\\ p_j=\mu_p-\left(\sqrt{|\boldsymbol{P}_p|}\right)_{j-n_p} & j=n_p+1,n_p+2,\cdots,2n_p\end{cases} \tag{13}$$

式中：p_j为第j个系统参数。

将这些Sigma点代入系统，则增广系统可以被定义为

$$\dot{\hat{\boldsymbol{X}}}=\begin{bmatrix}f(\boldsymbol{\chi}_1,\boldsymbol{U},t)\\ f(\boldsymbol{\chi}_2,\boldsymbol{U},t)\\ \vdots\\ f(\boldsymbol{\chi}_{n_\sigma},\boldsymbol{U},t)\end{bmatrix}=\hat{f}(\hat{\boldsymbol{X}},\boldsymbol{U},t) \tag{14}$$

式中：“^”表示估计值；Sigma点的个数$n_\sigma=2n_p+1$；$\boldsymbol{\chi}_{j+1}$对应每个特定的Sigma点，例如，$\boldsymbol{\chi}_1$表示$(\boldsymbol{X}(t_0),p_0)$。

需要特别指出的是，无迹最优控制中的“无迹”与无迹卡尔曼滤波(unscented Kalman filter, UKF)中的“无迹”有相似之处，都是为处理非线性系统的状态估计问题。但无迹最优控制更侧重于依据不确定状态来求解出一组满足终端状态的控制解，而UKF则主要用于状态估计。

2.2 UMPSP推导过程

依据MPSP设计理念[27]，非线性系统动力学以离散时间形式进行表示，可写为

$$\hat{\boldsymbol{X}}_{k+1}=F(\hat{\boldsymbol{X}}_k,\boldsymbol{U}_k) \tag{15}$$

式中：$k=1,2,\cdots,N$为离散的时间步。

利用式(12)和式(14)将每一步的输出$\hat{\boldsymbol{Y}}_k$定义为增广状态的平均值，有

$$\hat{\boldsymbol{Y}}_k=H\left(\hat{\boldsymbol{X}}_k\right)=\frac{1}{n_\sigma}\left[\sum_{i=1}^{n_\sigma}x_{1_i}(k),\sum_{i=1}^{n_\sigma}x_{2_i}(k),\cdots,\sum_{i=1}^{n_\sigma}x_{n_i}(k)\right]^{\mathrm{T}} \tag{16}$$

根据式(16)，增广系统在终端时间的输出可定义为

$$\hat{\boldsymbol{Y}}_N=\frac{1}{n_\sigma}\left[\sum_{i=1}^{n_\sigma}x_{1_i}(N),\sum_{i=1}^{n_\sigma}x_{2_i}(N),\cdots,\sum_{i=1}^{n_\sigma}x_{n_i}(N)\right]^{\mathrm{T}} \tag{17}$$

UMPSP本质为设计出一系列的控制解$\boldsymbol{U}_k(k=1,2,\cdots,N-1)$，使系统的终端输出$\hat{\boldsymbol{Y}}_N$等于终端期望值$\hat{\boldsymbol{Y}}_N^*$，这是规划过程中需满足的硬约束。给定一组初始猜测控制解$\boldsymbol{U}^i(i=0)$，通过计算系统动态方程可以得出该组控制解下的终端时刻输出误差，MPSP的基本思想是在每个时间步找到与先前控制解相比的控制增量$\mathrm{d}\boldsymbol{U}_k$以实现期望的目标。

为建立终端输出误差$\Delta\hat{\boldsymbol{Y}}_N=\hat{\boldsymbol{Y}}_N^*-\hat{\boldsymbol{Y}}_N$与控制增量$\mathrm{d}\boldsymbol{U}_k$之间的关系，使用泰勒展开并舍去高阶项(假设输出误差很小)，$\Delta\hat{\boldsymbol{Y}}_N$可表示为

$$\Delta\hat{\boldsymbol{Y}}_N\cong\mathrm{d}\hat{\boldsymbol{Y}}_N=\left(\frac{\partial\hat{\boldsymbol{Y}}_N}{\partial\hat{\boldsymbol{X}}_N}\right)\mathrm{d}\hat{\boldsymbol{X}}_N \tag{18}$$

将第N步的误差扩展到第$N-1$步：

$$\mathrm{d}\hat{\boldsymbol{Y}}_N=\left(\frac{\partial\hat{\boldsymbol{Y}}_N}{\partial\hat{\boldsymbol{X}}_N}\right)\left\{\left(\frac{\partial F_{N-1}}{\partial\hat{\boldsymbol{X}}_{N-1}}\right)\mathrm{d}\hat{\boldsymbol{X}}_{N-1}+\left(\frac{\partial F_{N-1}}{\partial\boldsymbol{U}_{N-1}}\right)\mathrm{d}\boldsymbol{U}_{N-1}\right\} \tag{19}$$

继续该过程直到$k=1$，则终端的输出误差可表示为

$$\begin{aligned}\mathrm{d}\hat{\boldsymbol{Y}}_N=&\left(\frac{\partial\hat{\boldsymbol{Y}}_N}{\partial\hat{\boldsymbol{X}}_N}\right)\left(\frac{\partial F_{N-1}}{\partial\hat{\boldsymbol{X}}_{N-1}}\right)\cdots\left(\frac{\partial F_1}{\partial\hat{\boldsymbol{X}}_1}\right)\mathrm{d}\hat{\boldsymbol{X}}+\\ &\left(\frac{\partial\hat{\boldsymbol{Y}}_N}{\partial\hat{\boldsymbol{X}}_N}\right)\left(\frac{\partial F_{N-1}}{\partial\hat{\boldsymbol{X}}_{N-1}}\right)\cdots\left(\frac{\partial F_1}{\partial\boldsymbol{U}_1}\right)\mathrm{d}\boldsymbol{U}_1+\cdots+\\ &\left(\frac{\partial\hat{\boldsymbol{Y}}_N}{\partial\hat{\boldsymbol{X}}_N}\right)\left(\frac{\partial F_{N-1}}{\partial\boldsymbol{U}_{N-1}}\right)\mathrm{d}\boldsymbol{U}_{N-1}\end{aligned} \tag{20}$$

由于绝大多数情况下系统的初始条件均已知$\left(\mathrm{d}\hat{\boldsymbol{X}}=\boldsymbol{0}\right)$，因此，式(20)可化简为

$$\begin{cases}\mathrm{d}\hat{\boldsymbol{Y}}_N=\sum_{i=1}^{N-1}\boldsymbol{B}_i\mathrm{d}\boldsymbol{U}_i\\ \boldsymbol{B}_i=\begin{cases}\left(\frac{\partial\hat{\boldsymbol{Y}}_N}{\partial\hat{\boldsymbol{X}}_N}\right)\left(\frac{\partial F_{N-1}}{\partial\hat{\boldsymbol{X}}_{N-1}}\right)\cdots\left(\frac{\partial F_1}{\partial\boldsymbol{U}_1}\right) & i=1,2,\cdots,N-2\\ \left(\frac{\partial\hat{\boldsymbol{Y}}_N}{\partial\hat{\boldsymbol{X}}_N}\right)\left(\frac{\partial F_{N-1}}{\partial\boldsymbol{U}_{N-1}}\right) & i=N-1\end{cases}\end{cases} \tag{21}$$

下一步目标为最小化终端时刻下协方差矩阵的迹$\mathrm{tr}\left(\boldsymbol{P}_{\hat{\boldsymbol{X}}(t_{\mathrm{f}})}\right)$，从而减小终端状态的总体误差散布，提高制导方法对不确定参数的鲁棒性。

为用控制增量$\mathrm{d}\boldsymbol{U}_k$表示增广系统协方差矩阵的迹，定义新变量$\hat{\boldsymbol{Z}}_N$表示终端时刻下系统的增广状态$\hat{\boldsymbol{X}}_N$和增广状态的平均值$\overline{\boldsymbol{X}}_N$之间的误差：

$$\hat{\boldsymbol{Z}}_N=[\hat{\boldsymbol{X}}_N-\overline{\boldsymbol{X}}_N] \tag{22}$$

式中：$\hat{\boldsymbol{X}}_N\triangleq[\boldsymbol{\chi}_1(N),\boldsymbol{\chi}_2(N),\cdots,\boldsymbol{\chi}_{n_\sigma}(N)]^{\mathrm{T}}$；$\overline{\boldsymbol{X}}(N)\triangleq\sum_{i=1}^{n_\sigma}\boldsymbol{\chi}_i(N)/n_\sigma$，将$\overline{\boldsymbol{X}}_N\triangleq\left[\overline{\boldsymbol{X}}(N),\overline{\boldsymbol{X}}(N),\cdots,\overline{\boldsymbol{X}}(N)\right]^{\mathrm{T}}$，因此，终端时间处增广系统的协方差矩阵迹可表示为

$[\hat{\boldsymbol{Z}}_N^{\mathrm{T}}\boldsymbol{Q}\hat{\boldsymbol{Z}}_N]/n_\sigma^2$, $\boldsymbol{Q}$为正定矩阵。

为建立终端时刻下$\hat{\boldsymbol{Z}}_N$与控制增量$\mathrm{d}\boldsymbol{U}_k$之间的关系, 使用泰勒展开并舍去高阶项, $\hat{\boldsymbol{Z}}_N$可表示为

$$\hat{\boldsymbol{Z}}_N = \hat{\boldsymbol{Z}}_N^* + \Delta\hat{\boldsymbol{Z}}_N \simeq \hat{\boldsymbol{Z}}_N^* + \left[\frac{\partial\hat{\boldsymbol{Z}}_N}{\partial\hat{\boldsymbol{X}}_N}\right]\mathrm{d}\hat{\boldsymbol{X}}_N \tag{23}$$

式中: "*" 表示期望值。

由于 UMPSP 的目标是使终端时刻的协方差矩阵的迹达到最小, 因此, 将期望值$\hat{\boldsymbol{Z}}_N^*$设为 0, 式 (23) 化简为

$$\hat{\boldsymbol{Z}}_N = \left[\frac{\partial\hat{\boldsymbol{Z}}_N}{\partial\hat{\boldsymbol{X}}_N}\right]\mathrm{d}\hat{\boldsymbol{X}}_N \tag{24}$$

与式 (21) 的处理方式类似, 最终可将$\hat{\boldsymbol{Z}}_N$表示为

$$\begin{cases}\hat{\boldsymbol{Z}}_N = \displaystyle\sum_{i=1}^{N-1}\hat{\boldsymbol{B}}_i\mathrm{d}\boldsymbol{U}_i \\ \hat{\boldsymbol{B}}_i = \begin{cases}\left[\dfrac{\partial\hat{\boldsymbol{Z}}_N}{\partial\hat{\boldsymbol{X}}_N}\right]\left[\dfrac{\partial\boldsymbol{F}_{N-1}}{\partial\hat{\boldsymbol{X}}_{N-1}}\right]\cdots\left[\dfrac{\partial\boldsymbol{F}_1}{\partial\boldsymbol{U}_1}\right] & i=1,2,\cdots,N-2 \\ \left[\dfrac{\partial\hat{\boldsymbol{Z}}_N}{\partial\hat{\boldsymbol{X}}_N}\right]\left[\dfrac{\partial\boldsymbol{F}_{N-1}}{\partial\boldsymbol{U}_{N-1}}\right] & i=N-1\end{cases}\end{cases} \tag{25}$$

为最小化系统的控制$\boldsymbol{U}^{i+1}=\boldsymbol{U}^i+\mathrm{d}\boldsymbol{U}$和终端时刻协方差矩阵的迹$[\hat{\boldsymbol{Z}}_N^{\mathrm{T}}\boldsymbol{Q}\hat{\boldsymbol{Z}}_N]/n_\sigma^2$, 根据最优控制理论, 将代价函数设计为

$$J = \frac{1}{2}\sum_{k=1}^{N-1}\left(\boldsymbol{U}_k^i+\mathrm{d}\boldsymbol{U}_k\right)^{\mathrm{T}}\boldsymbol{R}_k\left(\boldsymbol{U}_k^i+\mathrm{d}\boldsymbol{U}_k\right)+\frac{1}{2}\left(\hat{\boldsymbol{Z}}_N^{\mathrm{T}}\boldsymbol{Q}\hat{\boldsymbol{Z}}_N\right) \tag{26}$$

式中: $\boldsymbol{R}_k$为正定矩阵。

将式 (25) 代入式 (26) 可得:

$$J = \frac{1}{2}\sum_{k=1}^{N-1}\left(\boldsymbol{U}_k^i+\mathrm{d}\boldsymbol{U}_k\right)^{\mathrm{T}}\boldsymbol{R}_k\left(\boldsymbol{U}_k^i+\mathrm{d}\boldsymbol{U}_k\right)+\frac{1}{2}\left(\sum_{k=1}^{N-1}\hat{\boldsymbol{B}}_k\mathrm{d}\boldsymbol{U}_k\right)^{\mathrm{T}}\boldsymbol{Q}\left(\sum_{k=1}^{N-1}\hat{\boldsymbol{B}}_k\mathrm{d}\boldsymbol{U}_k\right) \tag{27}$$

同时, 利用式 (21) 将终端状态误差$\Delta\hat{\boldsymbol{Y}}_N=\hat{\boldsymbol{Y}}_N^*-\hat{\boldsymbol{Y}}_N$作为等式约束, 写为

$$\sum_{k=1}^{N-1}\boldsymbol{B}_k\mathrm{d}\boldsymbol{U}_k = \mathrm{d}\hat{\boldsymbol{Y}}_N \tag{28}$$

最终构造增广状态下的拉格朗日函数为

$$\overline{J} = \frac{1}{2}\sum_{k=1}^{N-1}\left(\boldsymbol{U}_k^i+\mathrm{d}\boldsymbol{U}_k\right)^{\mathrm{T}}\boldsymbol{R}_k\left(\boldsymbol{U}_k^i+\mathrm{d}\boldsymbol{U}_k\right)+\frac{1}{2}\left(\sum_{k=1}^{N-1}\hat{\boldsymbol{B}}_k\mathrm{d}\boldsymbol{U}_k\right)^{\mathrm{T}}\boldsymbol{Q}\left(\sum_{k=1}^{N-1}\hat{\boldsymbol{B}}_k\mathrm{d}\boldsymbol{U}_k\right)+\boldsymbol{\lambda}^{\mathrm{T}}\left(\mathrm{d}\hat{\boldsymbol{Y}}_N-\sum_{k=1}^{N-1}\boldsymbol{B}_k\mathrm{d}\boldsymbol{U}_k\right) \tag{29}$$

针对变量$\mathrm{d}\boldsymbol{U}_1,\mathrm{d}\boldsymbol{U}_2,\cdots,\mathrm{d}\boldsymbol{U}_{N-1}$和$\boldsymbol{\lambda}$, 其最优必要条件为

$$\begin{cases}\dfrac{\partial\overline{J}}{\partial\mathrm{d}\boldsymbol{U}_k}=\boldsymbol{0} \\ \dfrac{\partial\overline{J}}{\partial\boldsymbol{\lambda}}=\boldsymbol{0}\end{cases} \tag{30}$$

将式 (30) 展开为

$$-\boldsymbol{R}_j\boldsymbol{U}_j^i = \boldsymbol{R}_j\mathrm{d}\boldsymbol{U}_j+\sum_{k=1}^{N-1}\hat{\boldsymbol{B}}_j^{\mathrm{T}}\boldsymbol{Q}\hat{\boldsymbol{B}}_k\mathrm{d}\boldsymbol{U}_k-\boldsymbol{B}_j^{\mathrm{T}}\boldsymbol{\lambda} \tag{31}$$

式中: $j=1,2,\cdots,N-1$。

将其改写为矩阵形式:

$$\begin{bmatrix}\boldsymbol{A}_{11}+\boldsymbol{R}_1 & \cdots & \boldsymbol{A}_{1(N-1)} & -\boldsymbol{B}_1^{\mathrm{T}} \\ \vdots & \ddots & \vdots & \vdots \\ \boldsymbol{A}_{(N-1)1} & \cdots & \boldsymbol{A}_{(N-1)(N-1)}+\boldsymbol{R}_{(N-1)} & -\boldsymbol{B}_{N-1}^{\mathrm{T}} \\ \boldsymbol{B}_1 & \cdots & \boldsymbol{B}_{(N-1)} & \boldsymbol{0}\end{bmatrix}\begin{bmatrix}\mathrm{d}\boldsymbol{U}_1^i \\ \mathrm{d}\boldsymbol{U}_2^i \\ \vdots \\ \mathrm{d}\boldsymbol{U}_{N-1}^i \\ \boldsymbol{\lambda}\end{bmatrix}=\begin{bmatrix}\boldsymbol{b}_1 \\ \boldsymbol{b}_2 \\ \vdots \\ \boldsymbol{b}_{N-1} \\ \mathrm{d}\hat{\boldsymbol{Y}}_N\end{bmatrix} \tag{32}$$

式中:

$$\begin{cases}\boldsymbol{A}_{jk}=\hat{\boldsymbol{B}}_j^{\mathrm{T}}\boldsymbol{Q}\hat{\boldsymbol{B}}_k \\ \boldsymbol{b}_k=-\boldsymbol{R}_k\boldsymbol{U}_k^i\end{cases} \tag{33}$$

通过求解式 (32) 可以得到控制增量$\mathrm{d}\boldsymbol{U}$, 从而更新下一次迭代的控制解:

$$\boldsymbol{U}^{i+1}=\boldsymbol{U}^i+\mathrm{d}\boldsymbol{U} \tag{34}$$

以上是一个完整的控制更新过程。为保证 UMPSP 算法中保留泰勒展开一阶项, 忽略高次项, 不会造成模型失真, 从而影响控制效果, 通常情况下要求控制解$\boldsymbol{U}_k$的步长取值较小, 从而保证用$\mathrm{d}\boldsymbol{Y}$代替$\Delta\boldsymbol{Y}$时误差较小。正因如此, UMPSP 算法通常需要迭代一定次数才可确保最终轨迹在允许误差范围内达到期望值。

3　着陆段制导律设计

3.1　快速解析制导方法

利用 UMPSP 算法进行制导律设计时, 需要对初始控制解进行猜测, 由火箭在动力下降阶段的运动方程式 (1) 可知, 火箭推力与姿态不能解耦, 因此, 现有解析制导方法均不能在严格满足终端约束的条件下实现着陆段制导。由于 UMPSP 算法较为

高效，对终端大偏差具有一定的鲁棒性，因此，并不需要严格满足终端位置、姿态约束的全程控制量初值，只需要提供大致的控制解形式使火箭尽可能满足终端约束。

针对以上问题，结合 UMPSP 算法自身特点，设计一种快速解析制导方法以生成初始控制指令。

根据火箭初始位置与初始速度计算出待飞时间t_{go}，将其定义为

$$t_{\mathrm{go}}=\sqrt{|\boldsymbol{r}_0^2|}\Big/\left(2\sqrt{|\boldsymbol{v}_0^2|}\right) \tag{35}$$

为优先使终端火箭满足姿态要求，将俯仰角速度ω_φ和偏航角速度ω_ψ设计为

$$\begin{cases}\omega_\varphi=\dfrac{\pi-\varphi_0}{2t_{\mathrm{go}}}\\ \omega_\psi=\dfrac{\psi_0}{t_{\mathrm{go}}}\end{cases} \tag{36}$$

通过以上设计，控制向量$\boldsymbol{u}$简化为只与推力T相关，利用近似最优解析制导方法[28]得出推力加速度矢量为

$$\begin{cases}\boldsymbol{a}=k_{\mathrm{r}}\dfrac{\boldsymbol{Z}_{\mathrm{em}}}{t_{\mathrm{go}}^2}-k_{\mathrm{v}}\dfrac{\boldsymbol{Z}_{\mathrm{ev}}}{t_{\mathrm{go}}}\\ \boldsymbol{Z}_{\mathrm{em}}=\boldsymbol{0}-\left(\boldsymbol{r}_0+\boldsymbol{v}t_{\mathrm{go}}+\dfrac{1}{2}\boldsymbol{g}t_{\mathrm{go}}^2\right)\\ \boldsymbol{Z}_{\mathrm{ev}}=\boldsymbol{0}-(\boldsymbol{v}_0+\boldsymbol{g}t_{\mathrm{go}})\end{cases} \tag{37}$$

式中：k_{r}与k_{v}为增益系数；$\boldsymbol{a}$为推力加速度矢量，最终令推力$T=m\|\boldsymbol{a}\|_2/3$。

3.2 不确定风场 Sigma 点构建

针对实际场景中的不确定风场，一般可将式 (5) 写为二次多项式形式：

$$v_{w_z}(r_y,\boldsymbol{s})=s_1r_y^{*2}+s_2r_y^*+s_3 \tag{38}$$

利用事先测量的风场数据得到z轴风场的标称值$\boldsymbol{\mu}_{\mathrm{w}}$与方差$\boldsymbol{\sigma}_{\mathrm{w}}^2$，同时，根据无迹变换理论可以完成风场不确定参数的表示：

$$\begin{cases}s_{11}=\mu_{\mathrm{w}1}\\ s_{12}=\mu_{\mathrm{w}1}+\sqrt{\sigma_{\mathrm{w}1}^2}\\ s_{13}=\mu_{\mathrm{w}1}-\sqrt{\sigma_{\mathrm{w}1}^2}\\ s_{21}=\mu_{\mathrm{w}2}\\ s_{22}=\mu_{\mathrm{w}2}+\sqrt{\sigma_{\mathrm{w}2}^2}\\ s_{23}=\mu_{\mathrm{w}2}-\sqrt{\sigma_{\mathrm{w}2}^2}\\ s_{31}=\mu_{\mathrm{w}3}\\ s_{32}=\mu_{\mathrm{w}3}+\sqrt{\sigma_{\mathrm{w}3}^2}\\ s_{33}=\mu_{\mathrm{w}3}-\sqrt{\sigma_{\mathrm{w}3}^2}\end{cases} \tag{39}$$

式中：$\mu_{\mathrm{w}1}$、$\mu_{\mathrm{w}2}$、$\mu_{\mathrm{w}3}$分别为s_1、s_2、s_3的标称值，$\sigma_{\mathrm{w}1}^2$、$\sigma_{\mathrm{w}2}^2$、$\sigma_{\mathrm{w}3}^2$分别为s_1、s_2、s_3的方差。

利用这些风场参数，以确定形式表达风场参数不确定的初始条件，则火箭着陆问题的 Sigma 点可构建为

$$\begin{cases}\boldsymbol{\chi}_1\triangleq(\boldsymbol{X}_0,s_{11},s_{21},s_{31})\\ \boldsymbol{\chi}_2\triangleq(\boldsymbol{X}_0,s_{12},s_{21},s_{31})\\ \boldsymbol{\chi}_3\triangleq(\boldsymbol{X}_0,s_{13},s_{21},s_{31})\\ \boldsymbol{\chi}_4\triangleq(\boldsymbol{X}_0,s_{11},s_{22},s_{31})\\ \boldsymbol{\chi}_5\triangleq(\boldsymbol{X}_0,s_{11},s_{23},s_{31})\\ \boldsymbol{\chi}_6\triangleq(\boldsymbol{X}_0,s_{11},s_{21},s_{32})\\ \boldsymbol{\chi}_7\triangleq(\boldsymbol{X}_0,s_{11},s_{21},s_{33})\end{cases} \tag{40}$$

对于不同 Sigma 点下的火箭动力学模型，控制解$\boldsymbol{U}$都相同，因此，可以找到针对不确定风场参数最具鲁棒性的$\boldsymbol{U}$，与此同时，终端的状态误差被定义为

$$\hat{\boldsymbol{Y}}_N=\frac{1}{7}\sum_{i=1}^{7}\boldsymbol{\chi}_i(N)\to\hat{\boldsymbol{Y}}_N^* \tag{41}$$

通过代价函数 (26) 的设计，UMPSP 算法会在终端时刻协方差矩阵的迹最小的同时，最小化控制解。

图 1 为基于 UMPSP 的火箭着陆段鲁棒制导方法的实现流程。

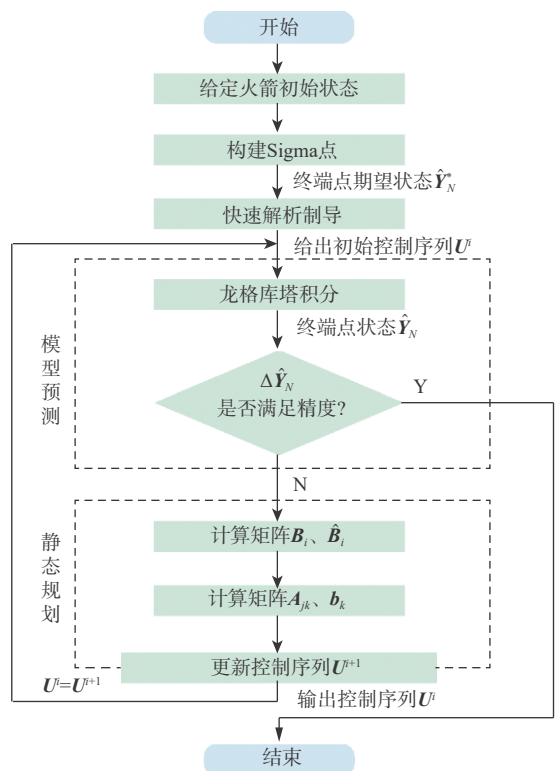


图 1 基于 UMPSP 的火箭着陆段鲁棒制导实现流程

Fig. 1 Implementation process of robust guidance for rocket landing phase based on UMPSP

4 仿真结果与分析

为验证本文方法的有效性，进行了 2 种算例仿真。仿真平台相关参数为：AMD 7840HS 3.80 GHz 处理器，Window11 操作系统，matlab23b 作为仿真

软件。仿真算例参照文献 [29], 选择 Falcon9 V1.2 发射 600 km 圆轨道任务场景, 假设发动机具有连续任意大小可调节的推力, 最大俯仰角速度$\omega_{\varphi\max}=10(°)/s$; 最大偏航角速度$\omega_{\psi\max}=10(°)/s$。

对仿真所使用的风场模型进行说明, 风场的不确定性模型采用文献 [26] 实际测量的风场数据, 风场均值$\boldsymbol{\mu}_w=[-0.073,4.460,5.230]^T$, 风场方差$\boldsymbol{\sigma}_w^2=[0.83,1.20,2.66]^T$, 用于高度标准化的高度数据均值$\mu=2\,234$, 标准差$\sigma=1\,635$, x轴风场参数$K=2.16\times10^{-3}$, $b=0.35$, 最终火箭一子级着陆段仿真参数设置如表 1 所示, 仿真所采用的标称风场与 Sigma 点风场如图 2 所示。

表 1　仿真参数值

Table 1　Simulation parameter values

最大推力/kN	发动机排气速度/(m·s^{-1})	火箭含燃料总质量/kg	火箭完全耗尽燃料的总结构质量/kg	火箭气动参考面积/m^2	大气密度/(kg·m^{-3})	火箭阻力系数	终端收敛精度
845.2	2 765.475	38 963	27 215	10.51	1.29	0.3	[2 m,2 m,2 m/s,2 m/s,2 m/s,1°,1°]

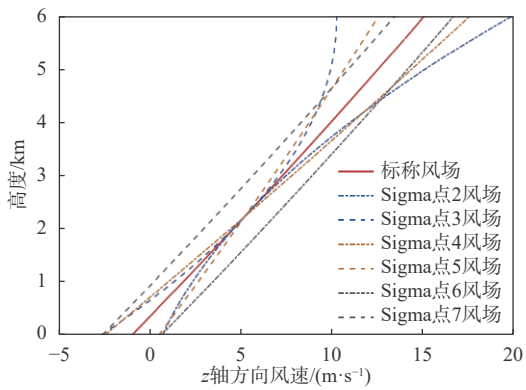


图 2　z方向标称风场与 Sigma 点风场

Fig. 2　Nominal wind field and Sigma point wind field in the z direction

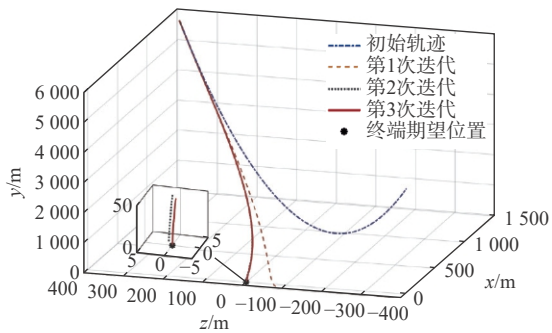


图 3　基于 UMPSP 制导方法的火箭着陆段迭代轨迹

Fig. 3　Iterative trajectory of rocket landing phase based on UMPSP guidance method

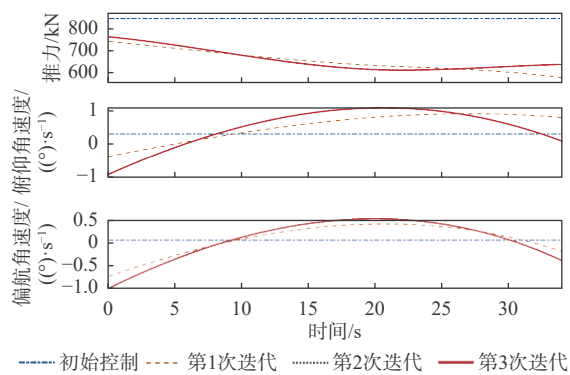


图 4　算例 1 基于 UMPSP 制导方法的火箭着陆段控制-时间曲线

Fig. 4　Control-time curves of rocket landing phase based on UMPSP guidance method in example 1

4.1　算例 1

对本文基于 UMPSP 与基于 MPSP 的制导方法进行对比, 分别进行仿真验证。火箭的初始位置设为$\boldsymbol{r}_0=[1\,530,5\,673,400]^T$ m, 火箭的初始速度设为$\boldsymbol{v}_0=[-140,-353,-40]^T$ m/s, 初始俯仰角设为$\varphi=72°$, 偏航角设为$\psi=-3°$, 由于着陆段的高度较低且变化范围较小, 重力加速度被设定为一个常值矢量$\boldsymbol{g}=[0,-9.806\,65,0]^T$ m/s^2, 控制解$\boldsymbol{U}_k$与龙格库塔积分步长设为0.1 s, 权重矩阵$\boldsymbol{R}_k$根据控制量推力与角速度之间的数值大小关系设置为$\boldsymbol{R}_k=\mathrm{diag}\{1\times10^{-7},1\times10^{7},1\times10^{7}\}$, 推力大小约束、最大角速度约束均在积分过程中实现, 得到基于 UMPSP 的仿真结果如图 3～图 6 所示。

从仿真结果曲线可以看出, 控制曲线、状态曲线平滑连续, 对火箭执行机构压力较小。如图 4 所示, 利用快速解析制导方法计算出的初始控制解, UMPSP 算法仅迭代 3 次便满足了终端约束要求, 单次迭代仅需 0.803 s, 计算效率优秀; 着陆段火箭质量、俯仰角、偏航角如图 5 所示、速度如图 6 所示, 在火箭飞行末端姿态为垂直状态, 速度降为 0, 实现了火箭的定点垂直软着陆。

根据风场数据的统计特性生成 100 组随机风场, 如图 7 所示, 分别利用 UMPSP 和 MPSP 生成的控制解进行仿真, 仿真结果如图 8～图 10 与表 2 和表 3 所示。

图 8～图 10 展示了 2 种方法下控制对比和终端状态偏差对比。表 2 和表 3 分别列出了 2 种方法下终端状态偏差的均值对比和标准差对比。其中, 图 9 和图 10 右侧标注的数值为 2 种制导方法在 100 组随机风场条件下的最大终端偏差。UMPSP 与 MPSP 制导方法的最大位置偏差分别为 8.041 3 m 和 15.058 2 m, 最大速度偏差分别为 0.290 8 m/s 和

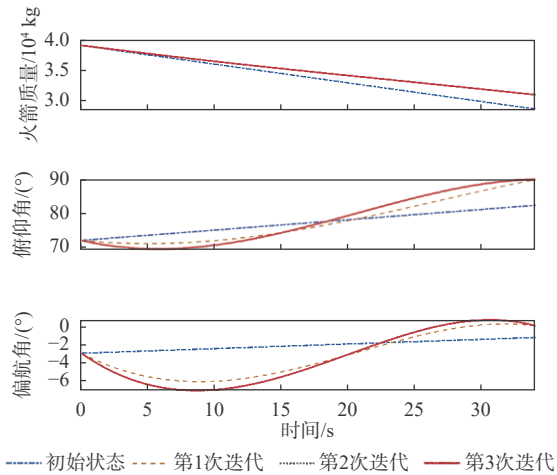


图5 算例1基于UMPSP制导方法的火箭着陆段状态-时间曲线

Fig. 5 State-time curves of rocket landing phase based on UMPSP guidance method in example 1

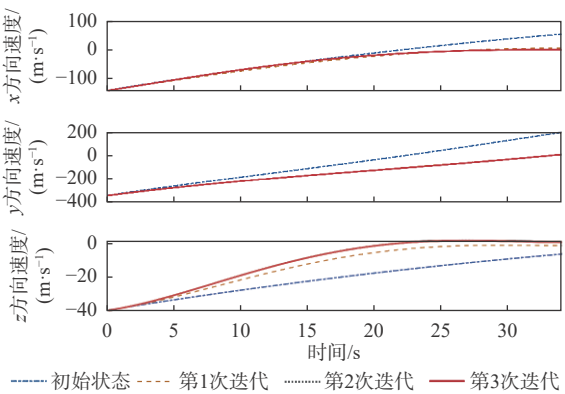


图6 算例1基于UMPSP制导方法的火箭着陆段速度-时间曲线

Fig. 6 Velocity-time curves of rocket landing phase based on UMPSP guidance method in example 1

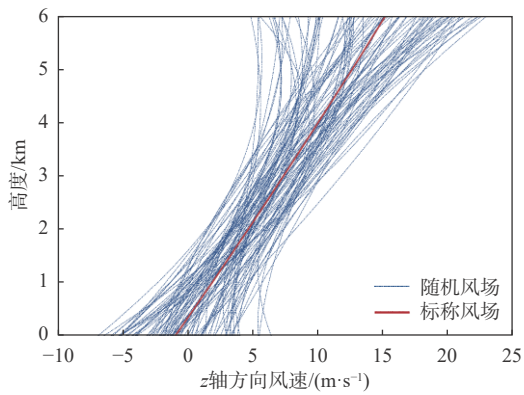


图7 z方向标称风场与100组随机风场

Fig. 7 Nominal wind field and 100 sets of random wind fields in the z direction

0.777 6 m/s。可以看出，基于UMPSP的制导方法相比于MPSP制导方法，显著减小了火箭终端状态偏差，且表现出更小的误差分布，从而提高了着陆精

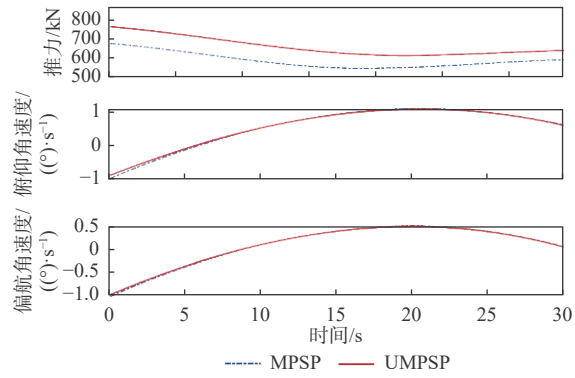


图8 UMPSP制导方法与MPSP制导方法的控制-时间对比曲线

Fig. 8 Control-time comparison curves between UMPSP guidance method and MPSP guidance method

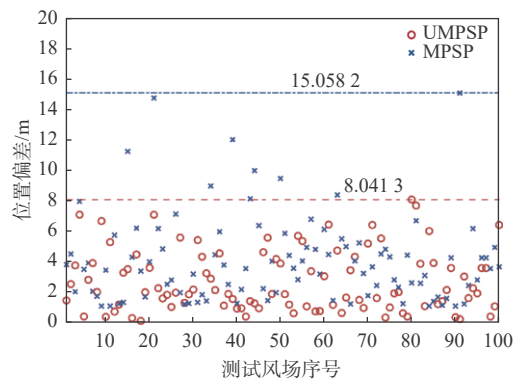


图9 随机风场下终端位置偏差对比

Fig. 9 Comparison of terminal position deviations under random wind fields

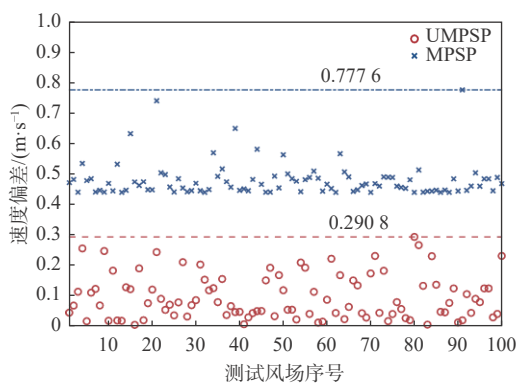


图10 随机风场下终端速度偏差对比

Fig. 10 Comparison of terminal velocity deviations under random wind fields

表2 随机风场下终端偏差均值对比

Table 2 Comparison of mean terminal deviation under random wind fields

制导方法	终端位置偏差均值/m	终端速度偏差均值/(m·s⁻¹)
UMPSP	2.665 2	0.092 0
MPSP	4.007 4	0.478 2

表 3　随机风场下终端偏差标准差对比

Table 3　Comparison of standard terminal deviation under random wind fields

制导方法	终端位置偏差标准差/m	终端速度偏差标准差/(m·s^{-1})
UMPSP制导方法	2.012 4	0.072 9
MPSP制导方法	2.820 4	0.056 7

度, 验证了基于 UMPSP 制导方法的有效性。

进一步验证基于 UMPSP 制导方法的鲁棒性, 考虑测量到的风场统计特性存在10%的偏差: 风场均值$\boldsymbol{\mu}_{\mathrm{w}}=[-0.080,4.906,5.753]^{\mathrm{T}}$, 风场方差$\boldsymbol{\sigma}_{\mathrm{w}}^{2}=[0.91,1.32,2.93]^{\mathrm{T}}$, 分别利用 UMPSP 和 MPSP 生成的控制解进行仿真, 仿真结果如图 11 和图 12 与表 4 和表 5 所示。

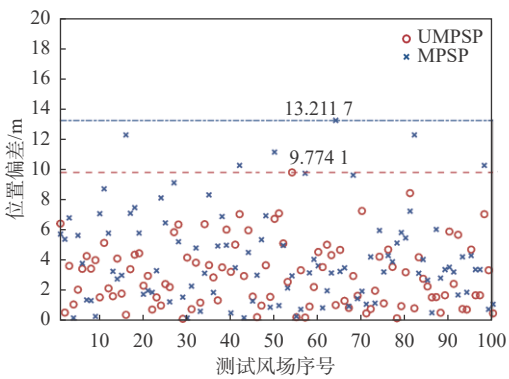


图 11　随机风场存在统计偏差下终端位置偏差对比

Fig. 11　Comparison of terminal position deviations under statistical bias in random wind fields

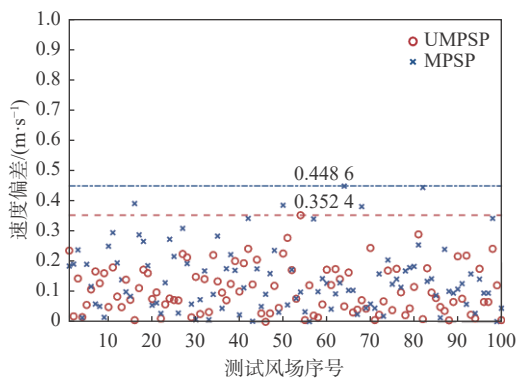


图 12　随机风场存在统计偏差下终端速度偏差对比

Fig. 12　Comparison of terminal velocity deviations under statistical bias in random wind fields

表 4　随机风场存在统计偏差下终端偏差均值对比

Table 4　Comparison of mean terminal deviation under statistical bias in random wind fields

制导方法	终端位置偏差均值/m	终端速度偏差均值/(m·s^{-1})
UMPSP	3.000 7	0.106 6
MPSP	4.802 2	0.492 2

表 5　随机风场存在统计偏差下终端偏差标准差对比

Table 5　Comparison of standard terminal deviation under statistical bias in random wind fields

制导方法	终端位置偏差标准差/m	终端速度偏差标准差/(m·s^{-1})
UMPSP	2.134 8	0.078 1
MPSP	3.242 3	0.062 1

图 11 和图 12 展示了 2 种方法下的终端状态偏差对比。表 4 和表 5 分别列出了 2 种方法在终端状态偏差的均值对比和标准差对比。其中, 图 11 和图 12 右侧标注的数值为风场统计特性存在 10% 偏差时 2 种制导方法的最大终端偏差。UMPSP 与 MPSP 制导方法的最大位置偏差分别为 9.774 1 m 和 13.211 7 m, 最大速度偏差分别为 0.352 4 m/s 和 0.448 6 m/s。从上述仿真结果可以看出, 在不确定风场存在统计偏差下, 基于 UMPSP 的制导方法相比于 MPSP 制导方法, 终端位置和速度的最大偏差分别减少了 26.0% 和 21.4%, 平均偏差分别减少了 37.5% 和 78.3%, 证明了本文方法具有较强的鲁棒性及对不确定风场的统计特性偏差具有较强的适应性。

4.2　算例 2

为进一步验证基于 UMPSP 制导方法的计算效率, 以标称风场进行仿真条件设计, 采用与文献 [30] 一致的初始状态, 火箭的初始位置$\boldsymbol{r}_0=[2\,100,5\,582,450]^{\mathrm{T}}$ m, 火箭的初始速度$\boldsymbol{v}_0=[-190,-353,-40]^{\mathrm{T}}$ m/s, 其余条件与算例一保持一致, 得到仿真结果如图 13 和图 14 所示。

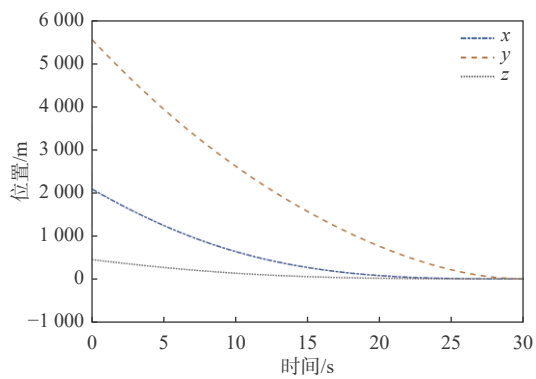


图 13　算例 2 基于 UMPSP 制导方法的火箭着陆段位置-时间曲线

Fig. 13　Position-time curves of rocket landing phase based on UMPSP guidance method in example 2

从仿真结果曲线可以看出, 火箭精准实现了定点软着陆, 终端位置与速度均满足终端约束要求。表 6 为基于 UMPSP 的制导方法与文献 [29] 中的凸优化制导方法对比。可以看出, 基于 UMPSP 的制导方法在计算效率方面领先于凸优化制导方法, 在

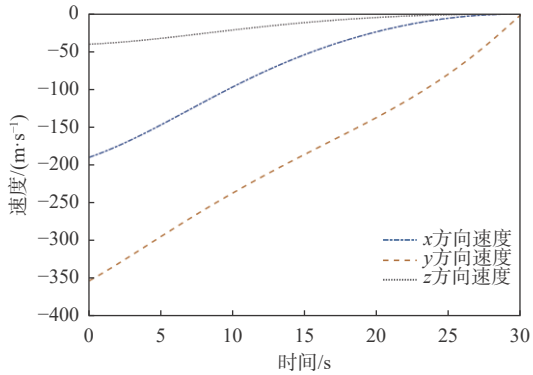


图 14 算例 2 基于 UMPSP 制导方法的火箭着陆段速度-时间曲线

Fig. 14 Velocity-time curves of rocket landing phase based on UMPSP guidance method in example 2

表 6 基于 UMPSP 的制导方法与凸优化制导方法对比

Table 6 Comparison between UMPSP guidance method and convex optimization guidance approach

制导方法	算法收敛时间/s	终端位置偏差/m	终端速度偏差/(m·s^{-1})
UMPSP	2.41	1.264	0.543
凸优化[29]	6.72	0.451	12.137

终端位置偏差相近的条件下速度偏差也大幅优于凸优化制导方法。

进一步地，为验证快速解析制导方法与基于 UMPSP 制导方法的鲁棒性，在算例二仿真条件的基础上，进行蒙特卡罗打靶仿真。假设火箭初始位置$\boldsymbol{r}_0$和$\boldsymbol{v}_0$的标准差分别为$[350,930,75]^{\mathrm{T}}$ m和$[15,30,3]^{\mathrm{T}}$ m/s，仿真次数为 50。打靶统计结果如表 7 和图 15 所示。

表 7 蒙特卡罗仿真统计结果

Table 7 Monte Carlo simulation statistical results

统计量	终端位置/m	终端速度/(m·s^{-1})	终端姿态/(°)	迭代次数
均值	[0.523,0.790,0.117]	[0.049,0.312,0.010]	[90.018,0.001]	3.185
标准差	[2.652,0.849,0.926]	[0.180,0.491,0.061]	[0.056,0.013]	0.622

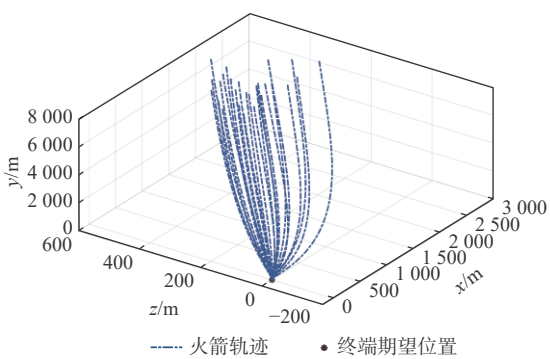


图 15 不同初始状态下火箭着陆段三维轨迹

Fig. 15 3D trajectory of rocket landing phase under different initial conditions

可以看出，在不同初始状态下，UMPSP 算法依然很好地满足了终端约束，大多数情况下 UMPSP 算法仅迭代 3～4 次便实现了收敛，验证了快速解析制导方法为 UMPSP 制导提供初始控制解的高效性与鲁棒性。

5 结 论

针对不确定风场中可回收火箭着陆段鲁棒制导问题，考虑火箭推力与姿态的耦合，提出基于 UMPSP 的可回收火箭着陆段鲁棒制导方法，利用快速解析制导方法提供初始控制解，结合 UMPSP 算法高效完成可回收火箭的定点垂直软着陆。主要结论如下：

1）建立火箭推力与姿态耦合的动力学方程，在考虑大气层内存在不确定风场的前提下，根据无迹最优控制与 MPSP 算法理论求解出一组对原系统不确定风场参数不敏感的控制解，减小了终端状态的误差分布。

2）针对实际场景中的不确定风场完成火箭着陆段 Sigma 点的构建，结合 UMPSP 算法特点，设计一种快速解析制导方法以生成初始控制指令，进一步提高了求解效率。

3）相比于 MPSP 制导方法和凸优化制导方法，本文基于 UMPSP 的可回收火箭鲁棒制导方法提高了火箭的着陆精度，对随机风场具有较强鲁棒性的同时，具有较高的计算效率。

参考文献（References）

[1] Blackmore L. Autonomous precision landing of space rockets [C]//Proceedings of the Frontiers of engineering: reports on leading-edge engineering from the 2016 symposium. Washington, D. C. : The National Academies Press, 2016: 57-64.

[2] 徐大富, 张哲, 吴克, 等. 垂直起降重复使用运载火箭发展趋势与关键技术研究进展[J]. 科学通报, 2016, 61(32): 3453-3463.
Xu D F, Zhang Z, Wu K, et al. Recent progress on development trend and key technologies of vertical take-off vertical landing re-usable launch vehicle[J]. Chinese Science Bulletin, 2016, 61(32): 3453-3463(in Chinese).

[3] Klumpp A R. Apollo lunar descent guidance[J]. Automatica, 1974, 10(2): 133-146.

[4] 张洪华, 关轶峰, 黄翔宇, 等. 嫦娥三号着陆器动力下降的制导导航与控制[J]. 中国科学 (技术科学), 2014, 44(4): 377-384.
Zhang H H, Guan Y F, Huang X Y, et al. Guidance navigation and control for Chang'E-3 powered descent[J]. Scientia Sinica (Technologica), 2014, 44(4): 377-384(in Chinese).

[5] Mcinnes C R. Direct adaptive control for gravity-turn descent[J]. Journal of Guidance, Control, and Dynamics, 1999, 22(2): 373-375.

[6] Zhou L Y, Xia Y Q. Improved ZEM/ZEV feedback guidance for Mars powered descent phase[J]. Advances in Space Research, 2014, 54(11): 2446-2455.

[7] Acikmese B, Ploen S R. Convex programming approach to powered descent guidance for Mars landing[J]. Journal of Guidance, Control, and Dynamics, 2007, 30(5): 1353-1366.

[8] Açıkmeşe B, Blackmore L. Lossless convexification of a class of optimal control problems with non-convex control constraints[J]. Automatica, 2011, 47(2): 341-347.

[9] Szmuk M, Acikmese B, Berning A W. Successive convexification for fuel-optimal powered landing with aerodynamic drag and non-convex constraints[C]//Proceedings of the AIAA Guidance, Navigation, and Control Conference. Reston: AIAA, 2016: 0378.

[10] 王劲博, 崔乃刚, 郭继峰, 等. 火箭返回着陆问题高精度快速轨迹优化算法[J]. 控制理论与应用, 2018, 35(3): 389-398.
Wang J B, Cui N G, Guo J F, et al. High precision rapid trajectory optimization algorithm for launch vehicle landing[J]. Control Theory & Applications, 2018, 35(3): 389-398(in Chinese).

[11] Szmuk M, Reynolds T P, Açıkmeşe B. Successive convexification for real-time six-degree-of-freedom powered descent guidance with state-triggered constraints[J]. Journal of Guidance, Control, and Dynamics, 2020, 43(8): 1399-1413.

[12] Reynolds T P, Szmuk M, Malyuta D, et al. Dual quaternion-based powered descent guidance with state-triggered constraints[J]. Journal of Guidance, Control, and Dynamics, 2020, 43(9): 1584-1599.

[13] 安泽, 熊芬芬, 梁卓楠. 基于偏置比例导引与凸优化的火箭垂直着陆制导[J]. 航空学报, 2020, 41(5): 242-255.
An Z, Xiong F F, Liang Z N. Landing-phase guidance of rocket using bias proportional guidance and convex optimization[J]. Acta Aeronautica et Astronautica Sinica, 2020, 41(5): 242-255(in Chinese).

[14] Padhi R, Kothari M. Model predictive static programming: a computationally efficient technique for suboptimal control design[J]. International Journal of Innovative Computing, Information and Control, 2009, 5(2): 399-411.

[15] Maity A, Padhi R, Mallaram S, et al. A robust and high precision optimal explicit guidance scheme for solid motor propelled launch vehicles with thrust and drag uncertainty[J]. International Journal of Systems Science, 2016, 47(13): 3078-3097.

[16] Sachan K, Padhi R. Waypoint constrained multi-phase optimal guidance of spacecraft for soft lunar landing[J]. Unmanned Systems, 2019, 7(2): 83-104.

[17] Banerjee A, Padhi R, Vatsal V. Optimal guidance for accurate lunar soft landing with minimum fuel consumption using model predictive static programming[C]//Proceedings of the 2015 American Control Conference. Piscataway: IEEE Press, 2015: 1861-1866.

[18] Wang Y, Topputo F. Robust Bang-off-Bang low-thrust guidance using model predictive static programming[J]. Acta Astronautica, 2020, 176: 357-370.

[19] Maity A, Oza H B, Padhi R. Generalized model predictive static programming and angle-constrained guidance of air-to-ground missiles[J]. Journal of Guidance, Control, and Dynamics, 2014, 37(6): 1897-1913.

[20] Mondal S, Padhi R. Constrained quasi-spectral MPSP with application to high-precision missile guidance with path constraints[J]. Journal of Dynamic Systems, Measurement, and Control, 2021, 143(3): 031001.

[21] Wang X, Dai P, Cheng X M, et al. An online generation method of ascent trajectory based on feedforward neural networks[J]. Aerospace Science and Technology, 2022, 128: 107739.

[22] Mathavaraj S, Padhi R. Unscented MPSP for optimal control of a class of uncertain nonlinear dynamic systems[J]. Journal of Dynamic Systems, Measurement, and Control, 2019, 141(6): 065001.

[23] Mathavaraj S, Padhi R. Quasi-spectral unscented MPSP guidance for robust soft-landing on asteroid[J]. Journal of Optimization Theory and Applications, 2021, 191(2): 823-845.

[24] Padhi R, Banerjee A, Mathavaraj S, et al. Computational guidance using model predictive static programming for challenging space missions: an introductory tutorial with example scenarios[J]. IEEE Control Systems Magazine, 2024, 44(2): 55-80.

[25] Lu P, Callan R. Propellant-optimal powered descent guidance revisited[J]. Journal of Guidance, Control, and Dynamics, 2023, 46(2): 215-230.

[26] 冯子鑫, 薛文超, 张冉, 等. 可回收火箭大气层内动力下降的多阶段鲁棒优化制导方法[J]. 自动化学报, 2024, 50(3): 505-517.
Feng Z X, Xue W C, Zhang R, et al. A multi-stage robust optimization guidance method for endoatmospheric powered descent of reusable rockets[J]. Acta Automatica Sinica, 2024, 50(3): 505-517(in Chinese).

[27] Halbe O, Raja R G, Padhi R. Robust reentry guidance of a reusable launch vehicle using model predictive static programming[J]. Journal of Guidance, Control, and Dynamics, 2014, 37(1): 134-148.

[28] Simplício P, Marcos A, Bennani S. Guidance of reusable launchers: improving descent and landing performance[J]. Journal of Guidance, Control, and Dynamics, 2019, 42(10): 2206-2219.

[29] 张志国, 马英, 耿光有, 等. 火箭垂直回收着陆段在线制导凸优化方法[J]. 弹道学报, 2017, 29(1): 9-16.
Zhang Z G, Ma Y, Geng G Y, et al. Convex optimization method used in the landing-phase on-line guidance of rocket vertical recovery[J]. Journal of Ballistics, 2017, 29(1): 9-16(in Chinese).

[30] 陈星伦, 张冉, 张晓燕. 大气层内动力下降段的组合干扰补偿制导[J]. 航空学报, 2023, 44(23): 156-171.
Chen X L, Zhang R, Zhang X Y. Combined disturbance compensation guidance for powered descent in atmosphere[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(23): 156-171(in Chinese).

A robust guidance method for reusable rocket landing phase based on UMPSP

ZHANG Yonghua[1, 2, 3], WANG Zheng[1, 2, 3, 4, 5, *], WANG Shiyu[6], BAI Yunfei[6], QIU Likuan[7]

(1. Unmanned System Research Institute, Northwestern Polytechnical University, Xi'an 710072, China;
2. National Key Laboratory of Unmanned Aerial Vehicle Technology, Xi'an 710072, China;
3. Integrated Research and Development Platform of Unmanned Aerial Vehicle Technology, Xi'an 710072, China;
4. National Key Laboratory of Aerospace Flight Dynamics, Northwestern Polytechnical University, Xi'an 710072, China;
5. Northwest Institute of Mechanical and Electrical Engineering, Xianyang 712099, China;
6. China Academy of Launch Vehicle Technology, Beijing 100076, China;
7. Shanghai Electro-Mechanical Engineering Institute, Shanghai 201109, China)

Abstract: This paper presents a robust guidance approach for the landing phase, based on unscented model predictive static programming (UMPSP). It seeks to solve the problem of reusable rockets making accurate vertical soft landings in the face of unpredictable atmospheric wind fields. Firstly, the dynamic equation of rocket thrust and attitude coupling is established. Under the consideration of an unknown uncertain wind field, a set of control strategies insensitive to the uncertain wind field parameters of the original system is derived using unscented optimal control and model predictive static programming (MPSP) theories. This aims to minimize the terminal state error dispersion and enhance landing precision. Secondly, capitalizing on the features of the UMPSP algorithm, a rapid analytical guidance methodology is proposed to initialize the control strategy, thereby further boosting solution efficiency. The results of the simulation show that the suggested UMPSP-based robust guidance approach for the landing phase exhibits excellent robustness and superior computing efficiency against a variety of uncertain wind field conditions, while guaranteeing high-precision landing of reusable rockets.

Keywords: model predictive static programming; reusable rocket; uncertain wind field; guidance and control; robust guidance

Received: 2024-06-28; **Accepted**: 2024-08-16; **Published Online**: 2024-09-14 17:07

URL: link.cnki.net/urlid/11.2625.V.20240914.1142.001

Foundation items: National Natural Science Foundation of China (62303378); Foundation of China National Key Laboratory of Science and Technology on Test Physics & Numerical Mathematics (JP2022-800006000107-237,08-YY-2023-R11); Foundation of Shanghai Astronautics Science and Technology Innovation (SAST2022-114)

* **Corresponding author**. E-mail: wz_nwpu@126.com

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0662

不确定环境下基于POMDP和参数化MPC的无人机在线路径规划

院金彪[1]，刘海艳[2]，马博迪[3]，赵玏洋[4]，高红岗[1]，刘贞报[1,*]

(1. 西北工业大学 民航学院，西安 710072；2. 上海民用航空控制与导航系统有限公司，上海 200241；3. 长安大学 信息学院，西安 710016；4. 深圳大学 建筑与城市规划学院，深圳 518060)

摘 要：无人机在未知环境中自主飞行时，定位与感知层面存在着难以消除的不确定性因素，开展航路规划方法以在不确定性干扰下增强航路有效性并提升无人机（UAVs）目标跟踪能力具有重要意义。当前，名义信念状态优化（NBO）为目标跟踪的不确定性提供了理论依据，基于管道的模型预测控制（Tube-based-MPC）则为规划与控制的分离架构提供了支持，从而使模型预测控制（MPC）能够应用于实时航路规划系统。基于此，提出一种在线航路规划方法以解决未知环境下的目标跟踪、避障问题。将航路规划问题抽象成一个部分可观测马尔可夫决策过程（POMDP）模型，并运用卡尔曼滤波对置信状态进行估计，将目标定位的不确定性度量融入到框架中；基于简化的三维运动模型构造了Tube-based-MPC优化框架对POMDP进行求解，通过构建包含置信状态和未知障碍物的非线性优化问题，实现未来一定连续时间跨度的航路规划。在优化问题中充分考虑无人机和障碍物形状，并引入全维度避障距离度量，显著拓展优化问题的可行域。引入Q-Learning强化学习框架，以MPC作为策略函数逼近器，提升目标跟踪的闭环性能。仿真实验和硬件在环实验验证了所提方法的有效性。

关 键 词：部分可观测马尔可夫决策过程；基于管道的模型预测控制；航路规划；强化学习；目标跟踪

中图分类号：V249

文献标志码：A **文章编号**：1001-5965(2026)11-3941-17

在当今快速发展的科技领域，无人机(unmanned aerial vehicles, UAVs)技术正迅速成为解决多领域挑战的前沿工具之一。随着无人机的广泛应用，如救援任务[1-2]、智能油气管道巡检[3]、探索勘测和灾害响应[4-5]等，对其智能化和自主性的需求日益迫切。面对不断增长的需求和挑战，研究者们致力于提升无人机的感知、规划和控制能力，以确保其在未知环境中能够高效、安全地执行任务。

航路规划作为无人机自主飞行的关键技术，通过综合考虑环境中的障碍物、地形等因素，能够为无人机生成安全可行的飞行路径，避免与障碍物发生碰撞，最大程度降低事故风险，也可以根据具体环境特征调整飞行路径，使无人机能够适应不同的工作场景，提高其应用的多样性。尤其在进行远距离，大范围作业时，飞手对于飞行环境中的阵风、团雾、移动威胁等信息的掌握是不准确的(环境状态

收稿日期：2024-09-06；**录用日期**：2024-11-15；**网络出版时间**：2024-11-22 17:09

网络出版地址：link.cnki.net/urlid/11.2625.V.20241122.1600.001

基金项目：国家自然科学基金 (52072309,12102345)；陕西省重点研发计划 (2019ZDLGY14-02-01,2022FP-40)；深圳市基础研究资助项目 (JCYJ20190806152203506)；航空科学基金 (ASFC-2018ZC53026)；苏州市科学技术局资助项目 (ZXL2023177)；太仓市基础研究计划资助项目 (TC2023JC13)

* **通信作者**. E-mail：liuzhenbao@nwpu.edu.cn

引用格式：院金彪，刘海艳，马博迪，等. 不确定环境下基于POMDP和参数化MPC的无人机在线路径规划[J]. 北京航空航天大学学报，2026，52（11）：3941-3957. Yuan J B，Liu H Y，Ma B D，et al. UAV online path planning based on POMDP and parameterized MPC in uncertain environments[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：3941-3957（in Chinese）.

的不确定性),再加上机载传感器、执行器动作和飞行动力学方面的不确定性,当面临这些突发风险时,需要无人机进行在线航路规划以完成自主避障。

部分可观测马尔可夫决策过程(partially observable Markov decision process, POMDP)为不确定性下的规划提供了一种数学上的严格方法[6]。POMDP为基于智能体对状态空间的不完全观测而进行的一系列马尔可夫决策过程,其通过置信度描述各个可能状态的概率值,从而获得某一规划时刻的置信状态,进而反复和环境交互推理得到动作序列,其在无人机领域也有一定的应用。Trotti等[7]提出一种轨迹规划方法,使无人机能够到达目标的同时避开禁飞区域,优化燃料消耗、飞行时间等,并对飞行角度进行约束,研究中考虑了固定翼飞机的动力学,并添加了不确定性模型误差以考虑近似情况。该研究基于蒙特卡罗树搜索(Monte Carlo tree search, MCTS)进行在线求解,减轻了POMDP模型求解的复杂性。Morere等[8]提出一种基于POMDP框架并采用贝叶斯优化(Bayesian optimization, BO)的轨迹规划(简称BO-POMDP)算法,所得BO-POMDP算法通过使用MCTS进行求解,并设计了平衡探索和利用奖励函数,无人机空对地监控实验验证表明,BO-POMDP算法具有较好的性能。Deng等[9]针对无人机辅助的车辆通信问题进行了研究,采用联合优化无人机轨迹设计和车辆分配的方案,将车辆轨迹预测和联合优化问题建模为POMDP。为解决POMDP的非马尔可夫性,设计基于深度Q网络(deep Q-network, DQN)算法和长短时记忆(long short-term memory, LSTM)网络层,构建了一个新的深度循环Q网络(deep recurrent Q-network, DRQN)框架,仿真结果表明,该基于DRQN框架的方案收敛速度快,且在总频谱效率方面优于基准方案。Aniceto dos Santos等[10]针对无人机在未知环境中收集信息即信息路径规划(informative path planning, IPP)和自主探索(autonomous exploration, AE)问题,提出一种使用具有POMDP的顺序BO进行森林监测的探索和IPP的建模策略,基于BO-POMDP在不确定性环境下进行研究,开发了一个顺序决策模型。

以上研究中针对POMDP的求解主要体现为2类,即基于MCTS[7-8,10]的算法和基于强化学习[9]的算法。尽管对POMDP在无人机领域的应用进行了研究和探索,取得了一定的效果,但针对MCTS类算法,其性能直接受动作的离散程度影响,权衡决策树的复杂度和算法搜索时间仍是一个难点。针对强化学习类算法,由于对环境的依赖性较高,不同场景间的通用性差,不利于无人机在大范围3D空间高效的航路规划需求。

此外,针对POMDP的计算复杂度问题(随着求解深度增加,规划范围呈指数级增长,计算效率低),很多学者对求解效率进行了改进。目前常见的求解方式有部分可观察蒙特卡罗规划(partially observable Monte Carlo planning, POMCP)算法[11]、确定稀疏部分可观测树(determinized sparse partially observable tree, DESPOT)算法[12-13]、自适应策略树(adaptive behavior tree, ABT)算法[14]、DESPOT-α算法[15]、实时调整POMDP解决方案(简称TAPIR)算法[16]、多极决策(multi-policy decision making, MPDM)算法[17]、领域特定的闭环策略树(domain-specific closed-loop policy tree, DCPTree)算法[18]、强化学习算法[19-20]、名义信念状态优化(nominal belief state optimization, NBO)算法[21]等。其中,文献[11-16]算法都适用于离散状态和离散动作空间的规划,通常会构造一棵策略树,在此基础上按照一定的准则搜索策略,并在理论上提供精确解,文献[17-18]算法是预先给出未来一定规划周期内可能的若干方案,从而构造离散的状态-动作或离散的状态-动作-观察树,大大减少了无效策略,在结构化环境中具有较好的应用。文献[19-20]算法基于强化学习框架通过与环境不断交互学习不同置信状态下可能的动作方案,其优势为可以学习到较优的离散或连续动作方案,但对环境依赖性强。此外,针对无人机在开放空间中的航路规划应用,离散化的动作空间会大大缩小无人机的求解可行域,且离散粒度太大会增加POMDP模型的复杂程度,造成维度灾难,增大求解难度。NBO算法作为POMDP的近似求解方案,具有很好的处理连续动作的能力,对于无人机在不确定性环境中的在线决策有很好的辅助作用,且相比其他近似算法计算效率高。文献[22-24]在NBO算法基础上进一步拓展,将动力学模型及各种感兴趣的特征纳入框架,展示了算法的强大和灵活性,并对多种跟踪控制和规避威胁场景进行了研究,证明了其实用性。

模型预测控制(model predictive control, MPC)作为一种流行的控制算法框架,能够轻松构建涵盖多种约束的复杂优化问题,并实现对未来一定时间跨度的在线轨迹生成,以应对未知的环境变化,在航路规划领域应用广泛。本文通过MPC框架对NBO算法进行优化问题的构建。然而,在该优化问题中,由于目标函数、约束条件及状态转移方程中的系数通常保持不变,导致其本身存在的误差难以得到改善,进而影响目标跟踪的闭环性能。近年

来, 基于 MPC 的强化学习[25-29]为进一步提升求解质量带来了可能。其核心在于将 MPC 作为策略输出逼近器, 在强化学习框架下, 利用经验池样本逐步调整 MPC 中的参数, 以实现优化的目的。与传统将深度神经网络(deep neural network, DNN)作为策略逼近器的强化学习框架相比, 基于 MPC 的强化学习具有更少的参数, 适应性更强。

本文着眼于未知环境中目标和模型的不确定性, 同时结合无人机作业时可能遭遇的未知静态或动态威胁场景, 提出一种在线航路规划方法。该方法充分考虑了目标状态的不确定性、动力学模型的不确定性, 以及以未知多面体形式呈现的静态障碍物和动态障碍物。本文方法基于 NBO 的理念完成了优化问题建模, 借助 MPC 框架融入了基于全维度距离度量[30]的避障约束条件, 并引入基于 Q-Learning 的强化学习框架来优化模型参数, 旨在提升目标跟踪的闭环性能; 利用 Casadi 求解该优化问题, 获取了不同置信状态下的连续动作输出, 达成了在连续动作空间中进行一定时间跨度的在线轨迹优化。为便于表述, 将本文提出的基于 Q-Learning 的 NBO 算法命名为 QL-NBO。本文的主要创新点包括:

1) 构建了基于 MPC 的 NBO 优化求解框架, 充分发挥 NBO 在处理目标状态不确定性方面的优势, 达成了未知环境中的在线轨迹规划。在这一框架内, 针对避障问题采用了考虑障碍物形状的全维度距离度量[30]方法, 相较于将障碍物等效为球形或椭球形等标准几何体的方式, 该方法扩大了问题求解的可行域, 且相比基于对偶变换的避障[31-32]轨迹规划, 具备更快的求解速度。

2) 引入了基于 MPC 的强化学习算法, 对优化模型进行参数化处理, 将 MPC 用作策略函数逼近器, 于 Q-Learning 框架中实时调整模型的权重系数, 有效改善了障碍物增多时避障航路有效性(到障碍物距离大于 0)降低的状况, 提高了 MPC 优化模型的求解质量及目标跟踪的闭环性能。

1　无人机系统

1.1　问题描述

本文选择电动垂直起降飞行器(electric vertical take-off and landing, eVTOL)作为研究平台, 重点考虑其在固定翼模式下的运动特性。设定的场景为复杂的三维环境, 包含静态和动态障碍物, 这些障碍物在规划初期是未知的。因此, 需要通过在线决策实时生成路径, 引导无人机在避障的同时尽可能完成设定任务。此外, 为确保路径的可行性, 还需考虑无人机的运动学约束。因此, 在线航路规划问题成为一个需要同时满足多种约束条件的优化问题。

1.2　三维运动学模型

针对航路规划本文只考虑运动学模型, 该模型主要用来约束航点以满足无人机运动学特点, 从而引导无人机以较小代价完成自主导航。通常三维空间下的运动学模型为[33]

$$\begin{cases} \dot{x} = v\cos\phi\cos\varphi \\ \dot{y} = v\cos\phi\sin\varphi \\ \dot{z} = v\sin\phi \\ \dot{v} = u \\ \dot{\varphi} = \omega_\varphi \\ \dot{\phi} = \omega_\phi \end{cases} \tag{1}$$

式中: (x,y,z)为无人机的实时位置; v为无人机的巡航速度; ϕ为无人机的航迹倾角; φ为无人机的航迹偏角; ω_ϕ和ω_φ分别为航迹倾角速度和航迹偏角速度; u为加速度, 即无人机的合加速度。

为确保生成路径能够方便无人机以较小的代价跟踪, 该运动学模型需要遵守如下可行性约束:

$$\begin{cases} \omega_{\phi\min} < \omega_\phi < \omega_{\phi\max} \\ \omega_{\varphi\min} < \omega_\varphi < \omega_{\varphi\max} \\ \phi_{\min} < \phi < \phi_{\max} \\ u_{\min} \leqslant u \leqslant u_{\max} \\ v_{\min} \leqslant v \leqslant v_{\max} \end{cases} \tag{2}$$

2　POMDP 模型设计

POMDP 模型的作用是在环境状态不确定、动作不确定的情况下能够找到一组动作序列, 使该智能体在这组序列下的价值回报最大[6], 典型的 POMDP 模型由一个 7 元组 $<S,A,Z,T,O,R,\gamma>$组成。其中, S为状态空间, A为动作空间, Z为观察空间, T为状态转移条件概率 $T(S,A,S')=P(S'|S,A)$, S'为转移后的状态空间, O为观察条件转移概率 $O(S',A,Z)=P(\boldsymbol{z}|\boldsymbol{s}',\boldsymbol{a})$, $\boldsymbol{a}$为动作, $\boldsymbol{s}'$为转移后的状态, $\boldsymbol{z}$为观察, 每当执行一个动作后, 环境会给智能体返回一个奖励R, 从当前时刻开始, 向前执行多步动作后, 每一步的奖励会以折扣γ^H递减, 其中, H为规划时段跨度, 且$0\leqslant\gamma<1$。

2.1　置信状态

考虑实际环境状态的不完全观测, POMDP 模型引入了置信状态的概念, 置信状态可以描述为不同时刻下所有状态的概率分布。令时刻t时$\boldsymbol{s}$的置信状态为$\boldsymbol{b}_t(\boldsymbol{s})$, 当执行动作$\boldsymbol{a}_t$后得到观察为$\boldsymbol{z}_t$, 则$t+1$时刻的置信状态为

$$\boldsymbol{b}_{t+1}(\boldsymbol{s}') = \eta O(\boldsymbol{s}',\boldsymbol{a}_{t+1},\boldsymbol{z}_{t+1})\sum_{\boldsymbol{s}\in S} T(\boldsymbol{s},\boldsymbol{a}_{t+1},\boldsymbol{s}')\boldsymbol{b}_t(\boldsymbol{s}) \tag{3}$$

式中: $\eta\in(0,1)$; 转移概率T遵循贝叶斯[34]规则。

设置信状态更新函数为 τ，则有 $\boldsymbol{b}_{t+1}=\tau(\boldsymbol{b}_t,\boldsymbol{a}_{t+1},\boldsymbol{z}_{t+1})=\cdots=\tau(\cdots\tau(\tau(\boldsymbol{b}_0,\boldsymbol{a}_1,\boldsymbol{b}_1),\boldsymbol{a}_2,\boldsymbol{b}_2),\cdots,\boldsymbol{a}_t,\boldsymbol{z}_t)$，从中可以看出每个置信状态都包含了从最初时刻到当前时刻所有历史动作和观察信息 $(\boldsymbol{a}_1,\boldsymbol{z}_1,\boldsymbol{a}_2,\boldsymbol{z}_2,\cdots,\boldsymbol{a}_{t+1},\boldsymbol{z}_{t+1})$，反映出置信状态在转移过程中是根据历史观测和动作来推断当前状态的概率分布。

当智能体在执行策略 π 时，H 个规划时间段跨度下，智能体获得的期望总折扣奖励为

$$V_\pi(\boldsymbol{b})=E\left(\sum_{t=0}^{H}\gamma^t R(\boldsymbol{s}_t,\pi(\boldsymbol{b}_t))|\boldsymbol{b}_0=\boldsymbol{b}\right) \tag{4}$$

式中：E 为期望。

某一置信状态下的最优动作可以通过评价价值最大时所执行的动作来确定：

$$V^*(\boldsymbol{b})=\max_{\boldsymbol{a}\in A}\left\{\sum_{s\in S}\boldsymbol{b}(\boldsymbol{s})R(\boldsymbol{s},\boldsymbol{a})+\gamma\sum_{z\in Z}P(z|\boldsymbol{b},\boldsymbol{a})V^*(\tau(\boldsymbol{b},\boldsymbol{a},z))\right\} \tag{5}$$

2.2 组成成分对应

本文的任务是在未知场景下能够使无人机考虑环境状态的不确定性避开一切静态和动态障碍。将该问题映射到 POMDP 模型中需要在如下几方面进行处理。

1）状态 S。状态是智能体在环境中所处的当前情况或配置，规划时间跨度 k 的状态可表示为 $\boldsymbol{s}_k=(\boldsymbol{X}_k,\boldsymbol{G}_k,\boldsymbol{\xi}_k,\boldsymbol{P}_k,\boldsymbol{O}_{\mathrm{bs}k})$，其中，$\boldsymbol{X}_k$ 为无人机运动学模型状态 $(\boldsymbol{x}_k,\boldsymbol{y}_k,\boldsymbol{z}_k,\boldsymbol{v}_k,\phi_k,\varphi_k)$，$\boldsymbol{G}_k$ 为期望的无人机目标状态 $(\boldsymbol{x}_G,\boldsymbol{y}_G,\boldsymbol{z}_G,\boldsymbol{v}_G,\phi_G,\varphi_G)$，$\boldsymbol{\xi}_k$ 和 $\boldsymbol{P}_k$ 分别为跟踪状态下后验均值向量和协方差矩阵，其计算可参考卡尔曼滤波算法[35-36]，$\boldsymbol{O}_{\mathrm{bs}k}$ 为时间跨度 k 下的观察空间。

2）动作 A。这里的动作为运动学模型的输入，因此，第 k 个规划时间跨度的动作定义为 $\boldsymbol{a}_k=(\omega_{\phi_k},\omega_{\varphi_k},\boldsymbol{u}_k)$。

3）观察空间 Z 和条件概率 O。考虑测量的不确定性，第 k 个规划时间跨度的观测 $\boldsymbol{z}_k$ 可通过式(6)计算：

$$\begin{cases}\boldsymbol{z}_k^{\boldsymbol{X}}=\boldsymbol{X}_k\\ \boldsymbol{z}_k^{\boldsymbol{G}}=\boldsymbol{G}_k+\boldsymbol{e}_k\\ \boldsymbol{z}_k^{\boldsymbol{\xi}}=\boldsymbol{\xi}_k\\ \boldsymbol{z}_k^{\boldsymbol{P}}=\boldsymbol{P}_k\end{cases} \tag{6}$$

式中：$\boldsymbol{z}_k^{\boldsymbol{X}}$ 为系统状态观测值；当目标可视时，$\boldsymbol{z}_k^{\boldsymbol{G}}$ 为目标状态观测值，否则，$\boldsymbol{z}_k^{\boldsymbol{G}}$ 不可测量；$\boldsymbol{e}_k$ 为测量噪声；$\boldsymbol{z}_k^{\boldsymbol{\xi}}$ 和 $\boldsymbol{z}_k^{\boldsymbol{P}}$ 为跟踪状态观测值。

可以看出观察空间 $\boldsymbol{z}_k^{\boldsymbol{X}}$、$\boldsymbol{z}_k^{\boldsymbol{\xi}}$ 和 $\boldsymbol{z}_k^{\boldsymbol{P}}$ 与状态空间是相等的，假定了实际当中无人机的状态和跟踪状态是完全可观察的，而目标状态是不完全观察的，这也是不确定性来源。

4）状态转移规则。当无人机从某一状态 $\boldsymbol{X}_k$ 执行动作 $\boldsymbol{a}_{k+1}$ 后环境会返回新的状态 $\boldsymbol{X}_{k+1}$，其中，系统状态转移通过运动学模型来确定。目标状态转移 $\boldsymbol{G}_{k+1}=\boldsymbol{F}\boldsymbol{G}_k+\boldsymbol{v}_k$，其中，矩阵 $\boldsymbol{F}$ 为跟踪目标的状态转移矩阵，$\boldsymbol{v}_k$ 表示测量中的随机噪声。跟踪状态转移则通过标准卡尔曼滤波算法确定。

5）奖励函数。无人机在总时间跨度为 H 的规划周期内，执行每个动作都会产生一个奖励，这些奖励的总和就是总时间跨度内的奖励，本文以无人机当前位置到目标位置的距离作为代价，当时间跨度为 k 时的奖励值计算如下：

$$C(\boldsymbol{s}_k,\boldsymbol{a}_k)=E_{e,v}\left(\|\boldsymbol{G}_{k+1}-\boldsymbol{\xi}_{k+1}\|_2^2\,|\,\boldsymbol{s}_k,\boldsymbol{a}_k\right) \tag{7}$$

式中：$C(\boldsymbol{s}_k,\boldsymbol{a}_k)$ 为跟踪状态和目标状态之间的均方差的期望。

6）折扣回报 γ。折扣回报可自行设定，其范围为[0,1)之间。

当确定了 POMDP 模型的各个组成成分后就可以进行置信状态的计算，第 k 个时间跨度的置信状态为

$$\boldsymbol{b}_k=\left(\boldsymbol{b}_k^{\boldsymbol{X}},\boldsymbol{b}_k^{\boldsymbol{G}},\boldsymbol{b}_k^{\boldsymbol{\xi}},\boldsymbol{b}_k^{\boldsymbol{P}}\right) \tag{8}$$

式中：$\boldsymbol{b}_k^{\boldsymbol{X}}(\boldsymbol{s})=\delta(\boldsymbol{X}-\boldsymbol{X}_k)$，$\delta(\cdot)$ 为概率密度函数；$\boldsymbol{b}_k^{\boldsymbol{\xi}}(\boldsymbol{s})=\delta(\boldsymbol{\xi}-\boldsymbol{\xi}_k)$；$\boldsymbol{b}_k^{\boldsymbol{P}}(\boldsymbol{s})=\delta(\boldsymbol{P}-\boldsymbol{P}_k)$；而 $\boldsymbol{b}_k^{\boldsymbol{G}}(\boldsymbol{s})$ 可以通过贝叶斯公式计算，也可以通过对目标点或障碍物的轨迹预测进行计算。

3 NBO 近似解和 MPC 优化

关于 POMDP 的求解，其核心目标在于探寻一组动作序列，以较小代价或奖励较大的决策方式完成任务。以无人机的应用场景来说，鉴于环境变化迅速且对实时性有着较高要求，无需开展过长时间跨度的预测。故而，能够将目标函数设定为规划时间跨度总长为 H 的累积期望：

$$J_H=E\left(\sum_{k=0}^{H-1}C(\boldsymbol{s}_k,\boldsymbol{a}_k)\right) \tag{9}$$

在每个时间跨度 k 下，动作的选择都需要依赖之前所有历史状态和动作。假设问题(9)基于状态 $\boldsymbol{s}_k(k=0,1,\cdots,H-1)$ 存在最优动作序列，则相对于置信状态 $\boldsymbol{b}_k(k=0,1,\cdots,H-1)$ 来说，该最优动作序列也一样存在，因此，可以将式(9)用置信状态和动作对表示为

$$J_H=E\left(\sum_{k=0}^{H-1}c(\boldsymbol{b}_k,\boldsymbol{a}_k)|\boldsymbol{b}_0\right) \tag{10}$$

式中：$c(\boldsymbol{b}_k,\boldsymbol{a}_k)=\int C(\boldsymbol{s}_k,\boldsymbol{a}_k)\boldsymbol{b}(\boldsymbol{s})\mathrm{d}\boldsymbol{s}$，即置信状态中每一状态执行动作 $\boldsymbol{a}_k$ 后的期望，这里用积分表示是因为置信状态本身的连续性。设最优策略为 π_k^*，则有动

作$\boldsymbol{a}_k^*=\pi_k^*(\boldsymbol{b}_k)$。进一步, 式(10)根据贝尔曼方程可写成如下形式:

$$J_H^*(\boldsymbol{b}_k)=c(\boldsymbol{b}_k,\boldsymbol{a})+E\left(J_{H-1}^*(\boldsymbol{b}_{k+1})|\boldsymbol{b}_k,\boldsymbol{a}\right) \tag{11}$$

将式(10)等号右边部分表示为动作价值, 则有

$$Q_H(\boldsymbol{b}_k,\boldsymbol{a})=c(\boldsymbol{b}_k,\boldsymbol{a})+E\left(J_{H-1}^*(\boldsymbol{b}_{k+1})|\boldsymbol{b}_k,\boldsymbol{a}\right) \tag{12}$$

因此, 时间跨度为k时, 最优策略为

$$\pi_k^*(\boldsymbol{b}_k)=\underset{\boldsymbol{a}}{\operatorname{argmin}}Q_H(\boldsymbol{b}_k,\boldsymbol{a}) \tag{13}$$

所有时间跨度对应的最优动作$\boldsymbol{a}$组成的序列则为整个规划周期的最优策略。

3.1 NBO 近似

由于置信状态本身及无人机运动学模型中动作空间的连续性, 造成 POMDP 问题的维度灾难, 增加了求解难度。正如引言中分析的, POMDP 的求解采用当前一些较新的求解器时, 由于都对动作状态进行了离散化处理, 但在大范围空间中进行航路规划时, 随着环境中的障碍物数量的增加, 问题的维度呈指数上升, 导致求解慢, 不适合无人机在空中高速运动的场景。因此, 本文采用 NBO 算法, 实现了对连续动作的优化。该算法对目标函数做了如下近似:

$$J_H(\boldsymbol{b}_0)\approx\sum_{k=0}^{H-1}c\left(\hat{\boldsymbol{b}}_k,\boldsymbol{u}_k\right) \tag{14}$$

式中: $\hat{\boldsymbol{b}}_k$为名义信念状态, 通过卡尔曼滤波算法中的$\left(\hat{\boldsymbol{\xi}}_k,\hat{\boldsymbol{P}}_k\right)$进行更新:

$$\hat{\boldsymbol{b}}_k^G(\boldsymbol{G})=\mathcal{N}\left(\boldsymbol{G}-\hat{\boldsymbol{\xi}}_k,\hat{\boldsymbol{P}}_k\right) \tag{15}$$

式中: $\hat{\boldsymbol{\xi}}_k$和$\hat{\boldsymbol{P}}_k$的更新如下:

$$\begin{cases}\hat{\boldsymbol{\xi}}_{k+1}=\boldsymbol{F}_k\hat{\boldsymbol{\xi}}_k\\ \hat{\boldsymbol{P}}_{k+1}=\begin{cases}\left[\left(\boldsymbol{F}_k\hat{\boldsymbol{P}}_k\boldsymbol{F}_k^{\mathrm{T}}+\boldsymbol{Q}_k\right)^{-1}+\boldsymbol{S}_{k+1}\right]^{-1}\\ \left(\boldsymbol{F}_k\hat{\boldsymbol{P}}_k\boldsymbol{F}_k^{\mathrm{T}}+\boldsymbol{Q}_k\right)^{-1}\end{cases}\end{cases} \tag{16}$$

式中: $\hat{\boldsymbol{P}}_{k+1}$等式右侧上方表示目标可视, 下方为其他情况; $\boldsymbol{F}_k$为目标的状态转移矩阵; $\boldsymbol{Q}_k$为噪声矩阵; $\boldsymbol{S}_{k+1}=\boldsymbol{H}_{k+1}^{\mathrm{T}}\left[\boldsymbol{R}_{k+1}\left(\hat{\boldsymbol{\xi}}_k,\boldsymbol{X}_k\right)\right]^{-1}\boldsymbol{H}_{k+1}$, $\boldsymbol{H}_k$为观测矩阵, $\boldsymbol{R}_k$的计算式为

$$\boldsymbol{R}_k=\boldsymbol{M}_k\begin{bmatrix}\sigma_{\text{range}}^2(k)&0&0\\0&\sigma_{\text{angle_}\phi}^2(k)&0\\0&0&\sigma_{\text{angle_}\varphi}^2(k)\end{bmatrix}\boldsymbol{M}_k^{\mathrm{T}} \tag{17}$$

式中: $\sigma_{\text{range}}(k)=(p/100)r_{\text{eff}}(k)$; $\sigma_{\text{angle_}\phi}(k)=qr_{\text{eff}}(k)$; $\sigma_{\text{angle_}\varphi}(k)=\mu r_{\text{eff}}(k)$; p、q和μ分别为无人机当前位置、目标位置的距离和纵向方位角与横向方位角的不确定性度量, $r_{\text{eff}}(k)=\sqrt{r_k^2+\tilde{b}^2}$, r_k为当前位置到目标点的距离, $\tilde{b}$为非 0 常数, 表示距离测量误差; $\boldsymbol{M}_k$的计算式为

$$\boldsymbol{M}_k=\begin{bmatrix}\cos\phi_k&0&\sin\phi_k\\0&1&0\\-\sin\phi_k&0&\cos\phi_k\end{bmatrix}\begin{bmatrix}\cos\varphi_k&-\sin\varphi_k&0\\\sin\varphi_k&\cos\varphi_k&0\\0&0&1\end{bmatrix} \tag{18}$$

由式(16)可以看出名义误差协方差矩阵$\hat{\boldsymbol{P}}_{k+1}$取决于未来时刻对目标观测有效性, 即目标是否在感知范围内。当目标不在感知范围内时, 能通过假设目标在第 k+1 时间跨度的位置为$\hat{\boldsymbol{\xi}}_{k+1}$, 确保无人机跟踪状态和目标状态在该时间跨度下的均方误差最小, 因此, 有

$$c\left(\hat{\boldsymbol{b}}_k,\boldsymbol{u}_k\right)=\mathrm{Tr}\hat{\boldsymbol{P}}_{k+1} \tag{19}$$

式中: $\mathrm{Tr}\hat{\boldsymbol{P}}_{k+1}$为无人机对目标跟踪的不确定性度量, $\mathrm{Tr}\hat{\boldsymbol{P}}_{k+1}$中的不确定性最小同时也反应了跟踪状态和目标状态的均方误差最小。

此外, $\boldsymbol{X}_k$和$\boldsymbol{G}_k$的计算如下:

$$\begin{cases}\boldsymbol{X}_{k+1}=f(\boldsymbol{X}_k,\boldsymbol{a}_k)+\boldsymbol{n}_k & \boldsymbol{n}_k\sim\mathcal{N}(\boldsymbol{0},\boldsymbol{N}_k)\\ \boldsymbol{G}_{k+1}=\boldsymbol{F}_k\hat{\boldsymbol{\xi}}_k+\boldsymbol{m}_k & \boldsymbol{m}_k\sim\mathcal{N}(\boldsymbol{0},\boldsymbol{M}_k)\end{cases} \tag{20}$$

式中: $f(\boldsymbol{x}_k,\boldsymbol{a}_k)$为无人机系统的运动学模型; $\boldsymbol{N}_k$为系统误差矩阵。

3.2 Tube-based-MPC

文献 [21-23] 均运用 MATLAB 的 fmin 函数进行仿真求解。为将该求解方式进一步拓展至更通用的平台, 本文采用当前流行的 MPC[37-41] 框架来构造并求解优化问题。规划所生成的轨迹作为控制系统外环的参考输入, 以引导无人机飞行。

针对 MPC 优化问题的求解, 存在众多方便使用的库。本文选用了 C++版本的 Casadi(https://gitee.com/lanqx/casadi.git), 该库具备强大的功能集及简洁的语言设计, 易于学习和使用。本文构造的 MPC 为一个收紧约束的优化问题, 亦称基于管道的 MPC(Tube-based-MPC) [42], 通过减小可行域, 提高了规划结果的安全性, 使其更易跟踪。本文构造的 MPC 优化问题如下:

$$\begin{cases}\min\limits_{\boldsymbol{a}_k}\sum\limits_k c\left(\hat{\boldsymbol{b}}_k,\boldsymbol{a}_k\right)+d_k\\ \text{s.t.}\begin{cases}\boldsymbol{x}_0=\boldsymbol{x}_{\text{S}},\boldsymbol{x}_{H+1}=\boldsymbol{x}_{\text{F}}\\ \hat{\boldsymbol{P}}_{k+1}=\begin{cases}\left[\left(\boldsymbol{F}_k\hat{\boldsymbol{P}}_k\boldsymbol{F}_k^{\mathrm{T}}+\boldsymbol{Q}_k\right)^{-1}+\boldsymbol{S}_{k+1}\right]^{-1}\\ \left(\boldsymbol{F}_k\hat{\boldsymbol{P}}_k\boldsymbol{F}_k^{\mathrm{T}}+\boldsymbol{Q}_k\right)^{-1}\end{cases}\\ h(\boldsymbol{x}_k,\boldsymbol{a}_k)\leqslant 0\qquad k=0,1,\cdots,H\end{cases}\end{cases} \tag{21}$$

式中: $\boldsymbol{x}_0$为无人机的初始状态; $\boldsymbol{x}_{\text{S}}$为对应的初始状态取值; $\boldsymbol{x}_{H+1}$为终点状态; $\boldsymbol{x}_{\text{F}}$为终点状态取值; $h(\boldsymbol{x}_k,\boldsymbol{a}_k)$为运动学模型的状态和输入约束; d_k为关于避障距离的度量, 其计算式为

$$d_k=\{|\boldsymbol{X}_k-\boldsymbol{m}_k||m\in O_{\text{bs}k}^M\} \tag{22}$$

式中: $O_{\text{bs}k}^M$表示时间跨度为k时无人机感知范围内的M个障碍物; d_k为第k个时间跨度下无人机与 M 个障碍

物的距离集合，其计算方式采用全维度距离进行表示。

3.3 全维度距离表示

通常在式(21)中有关避障约束，大多会将障碍物等效为规则的几何图形，并通过解析式来实现避障约束。然而，在实际情况中，大多数障碍物都是不规则的多边形或多面体。若将这些不规则形状等效成规则的球形、圆柱、椭圆等形状，将会缩小可行域，致使求解失败或求解效果不理想。尽管文献[31-32]采用对偶变换的方式很好地从理论上解决了避障约束，但由于引入了新的变量和约束条件，导致在障碍物增多时求解时间迅速增加，无法在障碍物密集的环境中进行在线规划。而文献[30]通过将避障约束放到目标函数中，显著提升了求解性能。因此，本文在文献[30]二维平面的避障距离度量方法基础上进行了拓展，以满足三维空间中无人机航路规划的需求。首先，避障约束表示为

$$\begin{cases} s_{\mathrm{d}}(D,B):\ =d_{\mathrm{ist}}(D,B)-p_{\mathrm{en}}(D,B) \\ d_{\mathrm{ist}}(D,B)=\min_T\{\|T\|_2:(D+T)\cap O\neq\varnothing\} \\ p_{\mathrm{en}}(D,B)=\min_T\{\|T\|_2:(D+T)\cap O=\varnothing\} \end{cases} \tag{23}$$

式中：D为无人机当前的位置和姿态；B为凸多边形障碍物的位置和姿态；$d_{\mathrm{ist}}(D,B)$为当无人机和障碍物未重叠时，两者之间的最短距离；$p_{\mathrm{en}}(D,B)$为当无人机和障碍物重叠时，两者分开的最短距离。

这些距离的度量均由无人机和障碍物的顶点与顶点及顶点和面之间的距离所组成集合中的最小值构成，因此，导数不连续，无法充当约束条件或目标函数通过MPC框架进行优化。虽然整数规划能够解决此类问题，但其无法提供平滑解以供无人机跟踪。文献[30]针对式(23)所描述的避障问题从理论层面进行了推导，并提供了相应的解决方案。设有2个集合$X_{\mathrm{u}},Y_{\mathrm{u}}\in\mathbf{R}$，其闵可夫斯基差为

$$X_{\mathrm{u}}-Y_{\mathrm{u}}=\{(x-y)\in\mathbf{R}:x\in X_{\mathrm{u}},y\in Y_{\mathrm{u}}\} \tag{24}$$

式中：集合$X_{\mathrm{u}}-Y_{\mathrm{u}}$为一个以0点为原点的多边形或多面体，集合到0点的距离包含A到B的最短距离，因此，无人机到障碍物的距离可以表示为

$$s_{\mathrm{d}}(D,B)=s_{\mathrm{d}}(0,B-D) \tag{25}$$

考虑方向性，则有

$$\begin{aligned} &\max_{\mathcal{P}_{f_{\mathrm{e}}},\mathcal{P}_{f_{\mathrm{o}}}}\left\{s_{\mathrm{d}}\left(0,B-\mathcal{P}_{f_{\mathrm{e}}}\right),s_{\mathrm{d}}\left(0,\mathcal{P}_{f_{\mathrm{o}}}-D\right)\right\}\leqslant s_{\mathrm{d}}(D,B) \\ &\quad\forall f_{\mathrm{e}}=\{1,2,\cdots,K_{\mathrm{e}}\},\forall f_{\mathrm{o}}=\{1,2,\cdots,K_{\mathrm{o}}\} \end{aligned} \tag{26}$$

式中：$\mathcal{P}_{f_{\mathrm{e}}}$和$\mathcal{P}_{f_{\mathrm{o}}}$分别为无人机的$f_{\mathrm{e}}$面和$f_{\mathrm{o}}$面；$K_{\mathrm{e}}$为无人机的面的个数；$K_{\mathrm{o}}$为障碍物的面数。且$s_{\mathrm{d}}\left(0,B-\mathcal{P}_{f_{\mathrm{e}}}\right)$和$s_{\mathrm{d}}\left(0,\mathcal{P}_{f_{\mathrm{o}}}-D\right)$的计算式分别为

$$\begin{cases} s_{\mathrm{d}}\left(0,B-\mathcal{P}_{f_{\mathrm{e}}}\right)=\dfrac{1}{\|\boldsymbol{H}^{f_{\mathrm{e}}}\|_2}\left(-\boldsymbol{h}^{f_{\mathrm{e}}}+\min_{\boldsymbol{u}_{\mathrm{T}}}\left(\boldsymbol{H}^{f_{\mathrm{e}}}\right)^{\mathrm{T}}\boldsymbol{u}_{\mathrm{T}}\right) \\ s_{\mathrm{d}}\left(0,\mathcal{P}_{f_{\mathrm{o}}}-D\right)=\dfrac{1}{\|\boldsymbol{G}^{f_{\mathrm{o}}}\|_2}\left(-\boldsymbol{g}^{f_{\mathrm{o}}}+\min_{\boldsymbol{y}_{\mathrm{r}}}\left(\boldsymbol{G}^{f_{\mathrm{o}}}\right)^{\mathrm{T}}\boldsymbol{y}_{\mathrm{r}}\right) \end{cases} \tag{27}$$

式中：$\boldsymbol{h}^{f_{\mathrm{e}}}$和$\boldsymbol{g}^{f_{\mathrm{o}}}$分别为无人机和障碍物各个面的法向量；$\boldsymbol{H}^{f_{\mathrm{e}}}$和$\boldsymbol{G}^{f_{\mathrm{o}}}$分别为无人机和障碍物的面$f_{\mathrm{e}}$和面$f_{\mathrm{o}}$的法向量且方向向外；$\boldsymbol{u}_{\mathrm{T}}$和$\boldsymbol{y}_{\mathrm{r}}$分别为无人机和障碍物的各个顶点。式(27)的物理意义是无人机和障碍物各自顶点到对方面f_{e}或面f_{o}的最短距离。

3.4 最短距离约束

避障要求在每个时间跨度k的无人机和周围一定范围内的U个障碍物之间的最短距离均大于d_{m}，则有

$$s_{\mathrm{d}}(D(k),B_u(k))\geqslant d_{\mathrm{m}}\qquad u=1,2,\cdots,U \tag{28}$$

式中：$D(k)$为第k个时间跨度对应的无人机的位置，$B_u(k)$为第k时间跨度时，无人机附近U个障碍物中的第u个障碍物。联立式(25)和式(27)，则有

$$\begin{cases} s_{\mathrm{d}}(D(k),B_u(k))\geqslant \\ \quad\max\left\{\max_{f_{\mathrm{e}}}\min_{v_{\mathrm{ero}}}\boldsymbol{H}\left(\boldsymbol{R},\mathcal{P}_{f_{\mathrm{e}}}\right)^{\mathrm{T}}\left(v^u_{v_{\mathrm{ero}}}(k)-v_{f_{\mathrm{e}}}(k)\right)\right. \\ \left.\max_{f_{\mathrm{o}}}\min_{v_{\mathrm{ere}}}\boldsymbol{H}\left(\boldsymbol{R}_n(k),\mathcal{P}^u_{f_o}\right)^{\mathrm{T}}\left(v_{v_{\mathrm{ere}}}(k)-v^u_{f_{\mathrm{o}}}(k)\right)\right\}\geqslant d_{\mathrm{m}} \\ v_{\mathrm{ere}}\in\{1,2,\cdots,N_{\mathrm{e}}\},v_{\mathrm{ero}}\in\left\{1,2,\cdots,N^u_{\mathrm{o}}\right\} \\ f_{\mathrm{e}}\in\{1,2,\cdots,K_{\mathrm{e}}\},f_{\mathrm{o}}\in\left\{1,2,\cdots,K^u_{\mathrm{o}}\right\} \end{cases} \tag{29}$$

式中：$\boldsymbol{H}(\boldsymbol{R},\mathcal{P})$为无人机或障碍物面$\mathcal{P}$上由内指向外的单位法向量；$\boldsymbol{R}$为无人机或障碍物的旋转矩阵；$v_{f_{\mathrm{e}}}(k)$为无人机面$f_{\mathrm{e}}$上的任意一点；$v_{v_{\mathrm{ere}}}(k)$为无人机的一个顶点；$v^u_{f_{\mathrm{o}}}(k)$为第$u$个障碍物的面$f_{\mathrm{o}}$上的任意一点；$v^u_{v_{\mathrm{ero}}}(k)$为第$u$个障碍物的一个顶点。

以$s_{\mathrm{d}}\left(0,B-\mathcal{P}_{f_{\mathrm{e}}}\right)$为例，其计算示意图如图1所示。图1中，以障碍物顶点到f_{e2}面的距离为例，可以计算UAV的其他面到障碍物各个顶点的距离。反之$s_{\mathrm{d}}\left(0,\mathcal{P}_{f_{\mathrm{o}}}-D\right)$可以通过计算UAV各个顶点到障碍物各个面的距离，采用式(29)进行计算。与文献[30]一样，对式(29)采用对数求和指数(log_sum_exp, LSE)进行平滑处理，LSE能够增加数值稳定性，防止数值溢出，并增加计算效率。以$\max\{\gamma\}$为例，LSE处理后的取值会限定在如下范围中：

$$\max\{\gamma\}+\frac{\ln\Omega}{\alpha'}\geqslant L_{\mathrm{SE}(\alpha'>0)}(\gamma)\geqslant\max\{\gamma\} \tag{30}$$

式中：$\dfrac{\ln\Omega}{\alpha'}$为一个很小的项，$\alpha'>0$表示对max进行平滑，$\alpha'<0$表示对min进行平滑。

LSE处理后的形式为

$$\begin{cases} U(D(k),B_u(k))=L_{\mathrm{SE}(\alpha'>0)}(\boldsymbol{d})-\dfrac{\ln\left(K_{\mathrm{e}}+K^u_{\mathrm{o}}\right)}{\alpha'} \\ \boldsymbol{d}=\left[\boldsymbol{d}_U^{\mathrm{T}},\boldsymbol{d}_E^{\mathrm{T}}\right]^{\mathrm{T}}\in\mathbf{R}^{K_{\mathrm{e}}+K^u_{\mathrm{o}}} \\ \boldsymbol{d}_U=\left[d_U^1,\ldots,d_U^{f_{\mathrm{e}}},\ldots d_U^{K_{\mathrm{e}}}\right]^{\mathrm{T}}\in\mathbf{R}^{K_{\mathrm{e}}} \\ \boldsymbol{d}_E=\left[d_E^1,\ldots,d_E^{f_{\mathrm{o}}},\ldots d_E^{K^u_{\mathrm{o}}}\right]^{\mathrm{T}}\in\mathbf{R}^{K^u_{\mathrm{o}}} \end{cases} \tag{31}$$

式中：$d_U^{f_{\mathrm{e}}}=s_{\mathrm{d}}\left(0,B_u(k)-\mathcal{P}_{f_{\mathrm{e}}}(k)\right)$；$d_E^{f_{\mathrm{o}}}=s_{\mathrm{d}}\left(0,\mathcal{P}^u_{f_{\mathrm{o}}}(k)-D(k)\right)$，同样对$d_U^{f_{\mathrm{e}}}$和$d_E^{f_{\mathrm{o}}}$通过LSE平滑结果为

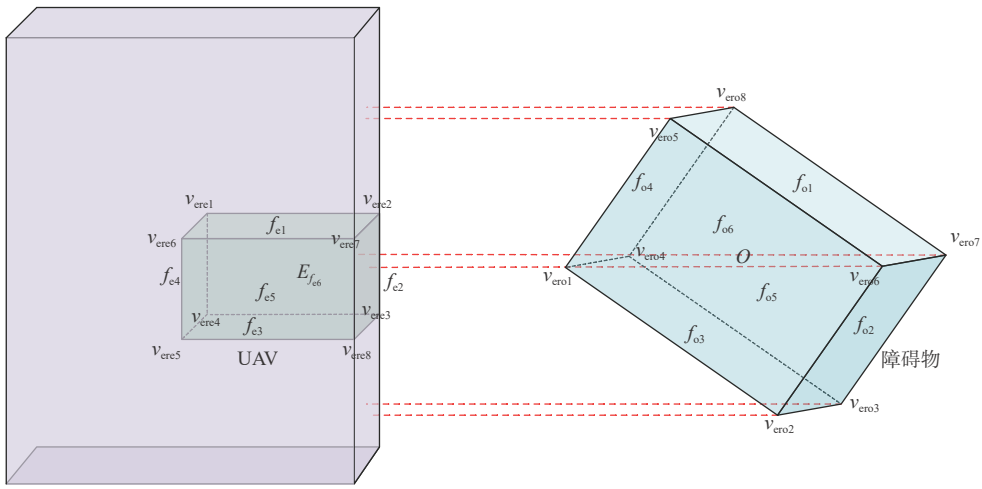


图 1　$s_{\mathrm{d}}\left(0, B-\mathcal{P}_{f_{\mathrm{e}}}\right)$ 计算示意图

Fig. 1　Schematic diagram of calculation of $s_{\mathrm{d}}\left(0, B-\mathcal{P}_{f_{\mathrm{e}}}\right)$

$$\begin{cases} d_U^{f_{\mathrm{e}}} = L_{\mathrm{SE}(\alpha'<0)}\left(\left[d_{U_1}^{f_{\mathrm{e}}}, \cdots, d_{U_{\mathrm{vero}}}^{f_{\mathrm{e}}}, \cdots, d_{U_{N_{\mathrm{o}}^u}}^{f_{\mathrm{e}}}\right]^{\mathrm{T}}\right) + \tilde{d}_U^{f_{\mathrm{e}}} \\ d_E^{f_{\mathrm{o}}} = L_{\mathrm{SE}(\alpha'<0)}\left(\left[d_{E_1}^{f_{\mathrm{o}}}, \cdots, d_{E_{\mathrm{vere}}}^{f_{\mathrm{o}}}, \cdots, d_{E_{N_{\mathrm{e}}}}^{f_{\mathrm{o}}}\right]^{\mathrm{T}}\right) + \tilde{d}_E^{f_{\mathrm{o}}} \end{cases} \tag{32}$$

式中: $d_{U_{\mathrm{vero}}}^{f_{\mathrm{e}}} = \boldsymbol{H}\left(\boldsymbol{R}(k), \mathcal{P}_{f_{\mathrm{e}}}\right)^{\mathrm{T}} \boldsymbol{R}_u(k) \boldsymbol{l}_{v_{\mathrm{vero}}}^u$, 其物理含义为无人机 f_{e} 面的单位法向量上障碍物顶点 $\boldsymbol{R}_u(k)\boldsymbol{l}_{v_{\mathrm{vero}}}^u$ 的投影; $\tilde{d}_U^{f_{\mathrm{e}}} = \left|\boldsymbol{H}\left(\boldsymbol{R}, \mathcal{P}_{f_{\mathrm{e}}}\right)^{\mathrm{T}}\right| \left(B_{\mathrm{o}}^u(k) - v_{f_{\mathrm{e}}}(k)\right)$, 其物理含义为障碍物中心点 $B_{\mathrm{o}}^u(k)$ 到无人机 $\boldsymbol{H}\left(\boldsymbol{R}, \mathcal{P}_{f_{\mathrm{e}}}\right)^{\mathrm{T}}$ 所在面上的任意一点 $v_{f_{\mathrm{e}}}(k)$ 的距离在该方向量上的投影; 同理, $d_{E_{\mathrm{vere}}}^{f_{\mathrm{o}}} = \left|\boldsymbol{H}\left(\boldsymbol{R}_u(K), \mathcal{P}_{f_{\mathrm{o}}}^u\right)^{\mathrm{T}}\right| \boldsymbol{R}\boldsymbol{l}_{v_{\mathrm{vere}}}$, $\tilde{d}_E^{f_{\mathrm{o}}} = \left|\boldsymbol{H}\left(\boldsymbol{R}_u(K), \mathcal{P}_{f_{\mathrm{o}}}^u\right)^{\mathrm{T}}\right| \cdot \left(D_{\mathrm{e}}(k) - v_{f_{\mathrm{o}}}^u(k)\right)$。

设 $d_k = d_{\mathrm{m}} - U\left(D(k), B_u(k)\right)$, 本文设计了一个平滑函数代替无人机和障碍物间距离的惩罚, 具体为

$$c_k = \begin{cases} 0.5x^2 & x < d_k, x > 0 \\ x + 0.5d_k^2 - d_k & x \geqslant d_k \\ 0 & x \leqslant 0 \end{cases} \tag{33}$$

将式(33)代入式(22), 最终目标函数为

$$\begin{cases} \min\limits_{\boldsymbol{a}_k} \sum\limits_k c\left(\hat{\boldsymbol{b}}_k, \boldsymbol{a}_k\right) + w_1 c_k + w_2 \sum\limits_i \tilde{s}_i \\ \text{s.t.} \begin{cases} \boldsymbol{x}_0 = \boldsymbol{x}_{\mathrm{S}}, \boldsymbol{x}_H = \boldsymbol{x}_{\mathrm{F}} \\ \hat{\boldsymbol{P}}_{k+1} = \begin{cases} \left[\left(\boldsymbol{F}_k \hat{\boldsymbol{P}}_k \boldsymbol{F}_k^{\mathrm{T}} + \boldsymbol{Q}_k\right)^{-1} + \boldsymbol{S}_{k+1}\right]^{-1} \\ \left(\boldsymbol{F}_k \hat{\boldsymbol{P}}_k \boldsymbol{F}_k^{\mathrm{T}} + \boldsymbol{Q}_k\right)^{-1} \end{cases} \\ h_i\left(\boldsymbol{x}_k, \boldsymbol{a}_k\right) \leqslant s_i \qquad k = 0, 1, \cdots, H, i = 0, 1, \cdots, H \end{cases} \end{cases} \tag{34}$$

式中: w_1 和 w_2 分别为避障条件 c_k 和松弛变量 $\tilde{s}_i$ 的系数。

将未知环境中无人机与所感知的静态和动态障碍物间的距离均以符号距离的方式进行表示, 此时满足了任意一个时间跨度下的优化需要, 对于动态障碍物还需考虑其时间跨度总数为 H 的可能的运动位置和姿态。如图 2 所示。

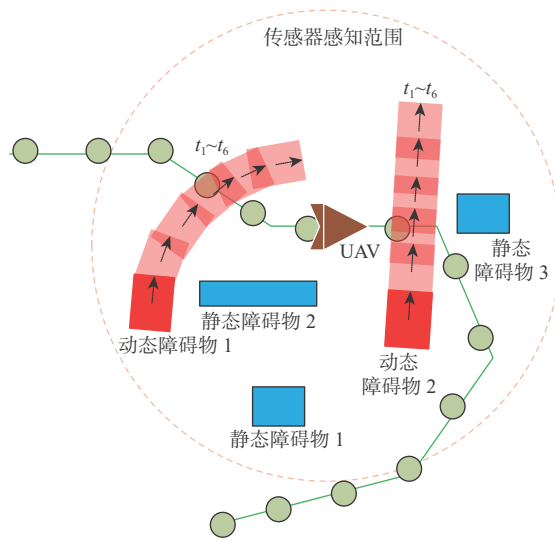


图 2　未知场景避障示意图

Fig. 2　Schematic diagram of obstacle avoidance in unknown scenarios

图 2 中无人机通过机载传感器感知到周围一定范围内有 2 个动态障碍物和 3 个静态障碍物, 其中, 动态障碍物考虑了 t_1～t_6 时间跨度的位置和姿态。绿色的折线为任务指定航线, 圆点为航点, 目的是尽量靠近任务航线朝着航点序列飞行。在 MPC 优化过程中, 针对不同的时间跨度 k 考虑的动态障碍物的位置和姿态是不同的。本文旨在对航路规划框架进行验证, 并未对障碍物的感知和识别及动态障碍物轨迹预测进行研究, 该内容属于其他领域。本文在处理动态障碍物时提前设定了轨迹, 模拟轨迹预测过程, 从轨迹队列中, 按照时间跨度获取其位置和姿态。针对障碍物的形状则都设定为高低不等的长方体(非凸多面体也需分割成多个凸多面进行计算)。

4 基于MPC的强化学习

MPC控制器的闭环性能取决于其组成部分，尤其是预测模型[29]。动力学中的不匹配会削弱MPC可靠预测系统行为的能力，从而影响控制器的性能及其避免违反约束的能力。本文采用的三维空间运动模型突显了该问题。本节将展示如何通过利用在线闭环数据，通过强化学习自动学习MPC中的参数来解决这些缺点。

4.1 MPC参数化

MPC作为策略输出逼近器，为融合到强化学习框架中，需要对其进行参数化处理，基于式(34)，参数化后的优化问题为

$$\begin{cases}\min\limits_{\boldsymbol{a}_k}\left(\theta_{\mathrm{p}}^2\sum\limits_k c\left(\hat{\boldsymbol{b}}_k,\boldsymbol{a}_k\right)+\theta_{\mathrm{u}}^2\|\boldsymbol{u}_{k+1}-\boldsymbol{u}_k\|_2+\theta_{\mathrm{o}}^2 w_1 c_k\right)\gamma^k+\\ \qquad w_2\sum\limits_i s_i\\ \text{s.t.}\begin{cases}\boldsymbol{x}_0=\boldsymbol{x}_{\mathrm{S}},\boldsymbol{x}_H=\boldsymbol{x}_{\mathrm{F}}\\ \hat{\boldsymbol{P}}_{k+1}=\begin{cases}\left[\left(\boldsymbol{F}_k\hat{\boldsymbol{P}}_k\boldsymbol{F}_k^{\mathrm{T}}+\boldsymbol{Q}_k\right)^{-1}+\boldsymbol{S}_{k+1}\right]^{-1}\\ \left(\boldsymbol{F}_k\hat{\boldsymbol{P}}_k\boldsymbol{F}_k^{\mathrm{T}}+\boldsymbol{Q}_k\right)^{-1}\end{cases}\\ h_i(\boldsymbol{x}_k,\boldsymbol{a}_k)\leqslant s_i\qquad k=0,1,\cdots,H,i=0,1,\cdots,H\end{cases}\end{cases}\tag{35}$$

式中：$c\left(\hat{\boldsymbol{b}}_k,\boldsymbol{a}_k\right)$包含了时间跨度$k$时的无人机位置和目标点位置，其计算可参考式(19)；θ_{p}为与目标相关的参数；θ_{u}为与输入变化相关的参数；θ_{o}为与避障相关的参数；w_1和w_2均为固定常数，用来稳定优化问题求解过程。使用松弛变量一方面表示这个约束的小违反(尽管是不希望的)是可以容忍的；另一方面确保在学习过程中既能放松约束，又能对违反进行惩罚，以便使智能体学会区分安全和不安全的策略[29]。此外，在优化问题中，有时存在一些硬约束条件(必须严格满足的条件)，但由于各种实际原因，完全满足这些条件可能会很困难或导致问题无解。通过引入松弛变量，可以将硬约束转化为等式约束加上松弛变量的非负约束，从而提升优化问题的求解成功率。

MPC每求解一次，无人机向前前进一步并记录一次阶段成本，然后将该成本值连同状态和动作及下一个状态存储到经验池中，以便强化学习框架通过构造时序差分(temporal difference, TD)误差损失函数进行参数调整。本文的阶段成本代价s_{gc}考虑了状态越界代价s_{c}，输入成本变换率最小代价a_{rc}及距离障碍物的距离d_{oc}三部分。具体如下：

$$s_{\mathrm{gc}}(k)=w_{\mathrm{s1}}s_{\mathrm{c}}+w_{\mathrm{s2}}a_{\mathrm{rc}}+w_{\mathrm{s2}}d_{\mathrm{oc}}\tag{36}$$

$$s_{\mathrm{c}}=\max(0,x_k(n)-x_{\mathrm{ub}},x_{\mathrm{lb}}-x_k(n))\tag{37}$$

$$a_{\mathrm{rc}}=a_k-a_{\mathrm{last}}\tag{38}$$

$$d_{\mathrm{oc}}=d(x_k(k),O)\tag{39}$$

总体而言，可调参数矢量$\boldsymbol{\theta}$为

$$\boldsymbol{\theta}=(\theta_{\mathrm{p}},\theta_{\mathrm{u}},\theta_{\mathrm{o}})\tag{40}$$

$\boldsymbol{\theta}$在强化学习过程中根据阶段成本会逐步调整优化问题权重，提升求解质量。当参数足够多的情况下，参数化的MPC框架有能力获得最优策略[26]。

4.2 基于二阶最小二乘时序差的Q学习

基于LSTD-Q的强化学习方法能高效利用数据，且往往比更基础的时序差分学习方法收敛得更快[29]。针对$\boldsymbol{\theta}$构建贝尔曼剩余误差的最小二乘如下：

$$\min_{\boldsymbol{\theta}}E\left(\|Q_*(\boldsymbol{s},\boldsymbol{a})-Q_{\boldsymbol{\theta}}(\boldsymbol{s},\boldsymbol{a})\|_2^2\right)\tag{41}$$

式中：$Q_*(\boldsymbol{s},\boldsymbol{a})\approx L(\boldsymbol{s},\boldsymbol{a})+\gamma Q_{\boldsymbol{\theta}}(\boldsymbol{s}_+,\pi(\boldsymbol{s}_+))$，为当前状态$\boldsymbol{s}$时，执行动作$\boldsymbol{a}$后的动作价值，$\boldsymbol{s}_+$为转移后的新状态，$L(\boldsymbol{s},\boldsymbol{a})$为执行动作$\boldsymbol{a}$后的立即回报；$Q_{\boldsymbol{\theta}}(\boldsymbol{s},\boldsymbol{a})$为执行动作$\boldsymbol{a}$前，现有策略模型对动作价值的评估。

二阶最小二乘时序差的Q学习则是通过对式(41)进行偏导数计算，关于$\boldsymbol{\theta}$的更新如下：

$$\begin{cases}\boldsymbol{\theta}\leftarrow\boldsymbol{\theta}-\alpha_{\mathrm{L}}\boldsymbol{A}^{-1}\boldsymbol{b}\\ \boldsymbol{A}=E\left(\delta(\nabla\boldsymbol{\theta})^2Q_{\boldsymbol{\theta}}+\nabla\boldsymbol{\theta}Q_{\boldsymbol{\theta}}\nabla\boldsymbol{\theta}^{\mathrm{T}}\delta\right)\\ \boldsymbol{b}=E\left(\delta\dfrac{\partial Q_{\boldsymbol{\theta}}}{\partial\boldsymbol{\theta}}\right)\end{cases}\tag{42}$$

式中：$\delta=L(s_i,\boldsymbol{a}_i)+\gamma V_{\boldsymbol{\theta}}(s_{i+1})-Q_{\boldsymbol{\theta}}(s_i,\boldsymbol{a}_i)$为TD误差；$V_{\boldsymbol{\theta}}(s_{i+1})$为状态价值；$\alpha_{\mathrm{L}}$为学习率。

在式(42)中关于$Q_{\boldsymbol{\theta}}$的导数和海森矩阵的计算需要通过优化问题最优值的灵敏度来获得。可以构造如下函数：

$$\mathcal{L}_{\boldsymbol{\theta}}=\Phi_{\boldsymbol{\theta}}+\boldsymbol{\lambda}^{\mathrm{T}}G_{\boldsymbol{\theta}}+\boldsymbol{\mu}^{\mathrm{T}}H_{\boldsymbol{\theta}}\tag{43}$$

式中：$\Phi_{\boldsymbol{\theta}}$为优化问题的目标函数；$\boldsymbol{\lambda}$和$\boldsymbol{\mu}$分别为与等式约束$G_{\boldsymbol{\theta}}$和不等式约束$H_{\boldsymbol{\theta}}$相关的拉格朗日乘子。

设$z=\{p,\boldsymbol{\lambda},\boldsymbol{\mu}\}$，$p=\{X,\overline{U}\}$，其中$X$和$\overline{U}$分别为与优化问题中的状态和输入相关的变量，可得梯度$\nabla\boldsymbol{\theta}Q_{\boldsymbol{\theta}}$和海森矩阵$(\nabla\boldsymbol{\theta})^2Q_{\boldsymbol{\theta}}$为

$$\begin{cases}\nabla\boldsymbol{\theta}Q_{\boldsymbol{\theta}}=\dfrac{\partial Q_{\boldsymbol{\theta}}}{\partial\boldsymbol{\theta}}=\dfrac{\partial\mathcal{L}_{\boldsymbol{\theta}}(\boldsymbol{s},\boldsymbol{a},z^*)}{\partial\boldsymbol{\theta}}\\ \nabla\boldsymbol{\theta}^2Q_{\boldsymbol{\theta}}=\boldsymbol{H}_{\mathrm{h}}(Q_{\boldsymbol{\theta}})=\dfrac{D}{D\boldsymbol{\theta}}\left(\dfrac{\partial\mathcal{L}_{\boldsymbol{\theta}}(\boldsymbol{s},\boldsymbol{a},z^*)}{\partial\boldsymbol{\theta}}\right)\approx\dfrac{\partial^2\mathcal{L}_{\boldsymbol{\theta}}(\boldsymbol{s},\boldsymbol{a},z^*)}{\partial\boldsymbol{\theta}^2}\end{cases}\tag{44}$$

计算得到的海森矩阵$\boldsymbol{H}_{\mathrm{h}}$总是通过加上一个单位矩阵的倍数来被修改为正定的[29]，因此，对参数需要施加上下限，原始的更新规则被表述为以下优化问题：

$$\begin{cases}\Delta\boldsymbol{\theta}^{*}=\arg\min\limits_{\Delta\boldsymbol{\theta}}\dfrac{1}{2}\Delta\boldsymbol{\theta}^{\mathrm{T}}\boldsymbol{H}_{\mathrm{h}}\Delta\boldsymbol{\theta}+\alpha\boldsymbol{F}^{\mathrm{T}}\Delta\boldsymbol{\theta}\\ \text{s.t.}\begin{cases}\boldsymbol{\theta}_{\mathrm{lb}}\leqslant\boldsymbol{\theta}+\Delta\boldsymbol{\theta}\leqslant\boldsymbol{\theta}_{\mathrm{ub}}\\ \Delta\boldsymbol{\theta}_{\mathrm{lb}}\leqslant\Delta\boldsymbol{\theta}\leqslant\Delta\boldsymbol{\theta}_{\mathrm{ub}}\end{cases}\end{cases}\tag{45}$$

式中: $\boldsymbol{F}=\nabla\boldsymbol{\theta}Q_{\boldsymbol{\theta}}$; $\boldsymbol{H}_{\mathrm{h}}=\nabla\boldsymbol{\theta}^{2}Q_{\boldsymbol{\theta}}$; 梯度的更新量为 $\Delta\boldsymbol{\theta}^{*}$, 因此, 式(42)中关于参数 $\boldsymbol{\theta}$ 的更新如下:

$$\boldsymbol{\theta}\leftarrow\boldsymbol{\theta}+\Delta\boldsymbol{\theta}^{*}\tag{46}$$

综合以上, 本文 QL-NBO 算法流程如图 3 所示。该算法核心在于避障优化模型的构建及基于最小二阶时序差的 Q-Learning 进行实时的参数调整。其中, 针对前者主要包含 3 部分, 分别为 POMDP 框架下基于 NBO 的目标函数近似、多面体避障距离度量和基于最小二乘平滑 LSE 的避障距离可微性处理及运动学模型状态和输入约束。针对后者主要实现对优化模型中需要学习的参数进行动态调整。详细流程如图 3 所示。可以看出, 首先, 构造避障优化问题模型; 其次, 对模型进行参数化处理, 并对相关参数进行初始化; 然后, 采用 Casadi 求解库计算模型输出策略(平滑的参考轨迹); 接着, 无人机按照该策略引导向前飞行, 此时判断无人机是否到达目标位置, 如到达则结束飞行, 如未到达则记录当前时间跨度前后的环境状态及奖励等信息($<\boldsymbol{s},\boldsymbol{a},\boldsymbol{s}',\boldsymbol{r},\mathrm{done}>$, 其中, done 为结束标志, $\boldsymbol{s}$ 和 $\boldsymbol{s}'$ 为相邻的 2 个环境状态, $\boldsymbol{a}$ 为动作策略, $\boldsymbol{r}$ 为奖励值)并存入经验池中; 最后, 基于 Q-Learning 强化学习框架进行相关参数调整。

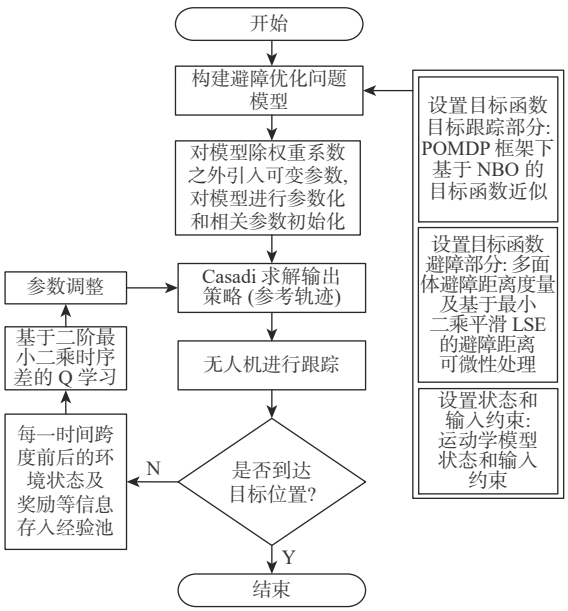


图 3　本文 QL-NBO 算法流程

Fig. 3　Flowchart of the QL-NBO algorithm

5　规划框架

本节设计了一个规划框架对本文算法进行验证, 如图 4 所示。框架支持软件在环和硬件在环仿真, 基于文献 [43] 和文献 [44] 搭建, 整个框架分为 L1、L2 和 L3 这 3 层。L1 包含地图模块、任务模块、规划模块和感知模块, 内部通过 MAVROS 进行通信。地图模块负责在场景中生成静态和动态障碍物, 以及订阅飞控中的任务, 并通过 RVIZ 进行可视化处理; 任务模块负责手动切换 OffBoard 和发布位置三元组(针对执行固定航路的任务场景, 可用来判断当前位置和航线任务间关系), 以便进行航路切换(参考了 px4 源代码 git clone https://github.com/PX4/

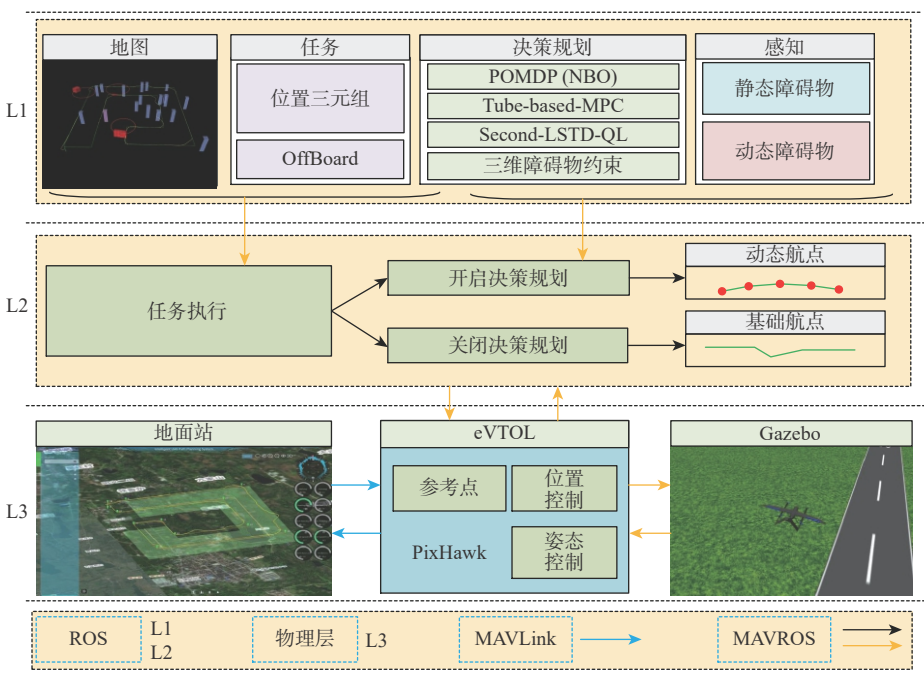


图 4　航路规划框架

Fig. 4　Path planning framework

PX4-Autopilot.git)到飞控端;规划模块采用NBO对POMDP近似处理,采用Tube-based-MPC(收紧约束的优化问题)框架进行优化问题构造,基于Q-Learning强化学习框架通过构造二次最小二乘问题实现对参数化MPC的更新,同时针对障碍物约束,在三维空间中采用考虑多面体形状的全维度避障度量,并进行LSE平滑处理,对未来5个时间跨度的轨迹点进行预测,每个时间跨度为2.5 s;感知模块负责将检测到的静态和动态障碍物及未来5个时间跨度的轨迹通过MAVROS发送给规划模块。L2负责整个规划框架主体数据装配和整个软件的任务执行,活跃在整个系统的生命周期内。无人机在飞行过程中会一直感知地图中的障碍物信息,该模块判断当前环境中不存在障碍物时按照任务航点执行,一旦发现有障碍物则会启动规划模块,通过任务模块借助三元组话题将避障轨迹发送给无人机跟踪。L3为物理层,包含地面站、无人机和Gazebo环境。地面站基于QGroundControl开发,增加了3D可视化模块及其他容易操作的功能;无人机模块负责接收任务执行模块发送的航点任务,通过位置和姿态控制完成轨迹跟踪;Gazebo负责飞行环境可视化,将实时的位置和速度等信息提供给飞控单元。

6 实验分析

6.1 仿真平台及参数设置

本文设计的规划框架运行在Ubuntu18.04操作系统上,飞控单元采用PixHawk平台,无人机是自定义的eVTOL模型,并将其加载到Gazebo环境中。计算单元采用i7处理器,硬盘为500 GB纯固态。在场景中,以长方体替代所有凸多面体作为障碍物,原因在于无论是凹多面体还是大型凸多面体,皆可分割为多个凸多面体。对于不规则形状障碍物的测试,文献[30]已完成。本文创建的场景中障碍物数量众多,为便于测试,统一设置为高度随机的长方体,主要聚焦于其有效性与避障性能分析。实验参数设置如表1所示。

表1 参数设置

Table 1 Parameter settings

参数	数值
$\boldsymbol{P}$	$\mathrm{diag}(1.0)_{6\times6}$
$\boldsymbol{Q}_k$	$\mathrm{diag}(10^{-4})_{6\times6}$
$\boldsymbol{H}_k$	$[1.0_{2\times2}\quad 0.0_{2\times4}]$
$\boldsymbol{R}$	$\mathrm{diag}(1.0)_{3\times3}$
$\boldsymbol{F}_k$	$\mathrm{diag}(1.0)_{6\times6}$
d_m/m	100.0
感知范围/m	200.0
d_t/s	1.0
时间跨度	5
v/(m·s^{-1})	17~25
θ_p	1.0
θ_u	1.0
θ_o	1.0
α	5×10^6
w_1	5×10^3
w_2	1×10^6
$w_{\mathrm{s}1}$	0.1
$w_{\mathrm{s}2}$	0.1
$w_{\mathrm{s}3}$	0.1
p	10
q	10
μ	10
$\widetilde{b}$	10

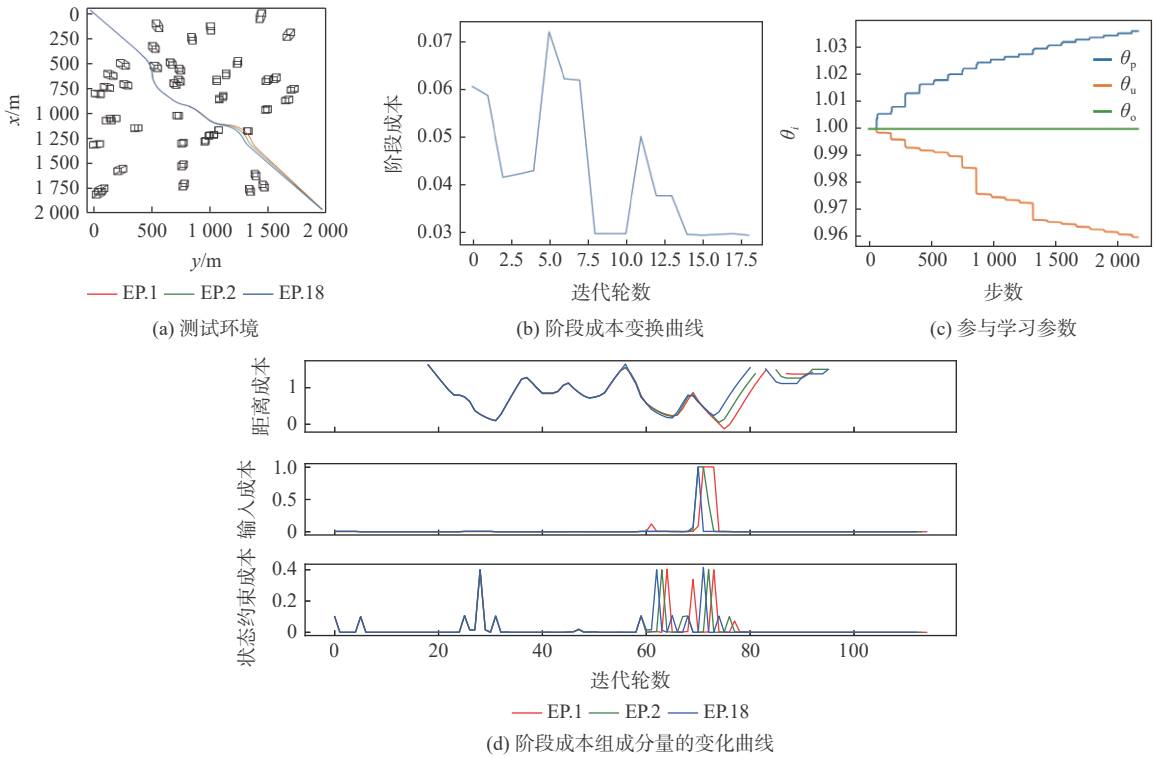
6.2 Q-Learning对NBO的有效性

为验证Q-Learning对NBO的有效性,本文设计了如图5(a)所示的场景,障碍物为随机生成的长方体,无人机飞行起点为(20, 20, 80)m,终点为(2 000, 2 000, 80)m,无人机实时感知周围200 m范围内的障碍物,构造当前位置到目标点NBO定点目标跟踪问题。每个迭代中,无人机都从相同的起点朝着目标点飞行,并实时对感知到的障碍物进行避障,以便直观地看出参数调整后的跟踪效果。整个过程逐步通过Q-Learning强化学习框架进行MPC策略模型优化,结果如图5(b)~图5(d)所示。

从图5(a)可以看出,初始迭代中无人机和障碍物发生了碰撞,在后续目标跟踪过程中,无人机逐渐远离了障碍物,3条路径(红、绿、蓝)分别对应图5(d)中的EP.1、EP.2、EP.18这3次迭代的结果,同时图5(d)中的距离成本、输入成本及状态约束成本分别为图5(b)阶段成本的3个组成分量。从图5(b)可以看出,随着迭代次数的增加,整个迭代的阶段成本总和呈下降趋势。取其中的第1、第2、第18次迭代进行对比,从图5(d)中的距离成本可看出无人机逐渐远离了障碍物,图5(d)中的输入成本可看出输入的变化率在逐渐变小,图5(d)中的状态约束成本可看出违反约束的情况在逐渐缩小。图5(c)为参数化MPC中3个动态调整参数θ_p、θ_u、θ_o的变化趋势,能够看出θ_p和θ_o均发生了调整,θ_u一直维持在初始值状态。综合以上可以看出Q-Learning强化学习框架对NBO问题的结果产生了正向影响。

6.3 不同障碍物数量影响下的鲁棒性分析

针对QL-NBO算法鲁棒性分析,本文设计了障



(a) 测试环境　(b) 阶段成本变换曲线　(c) 参与学习参数

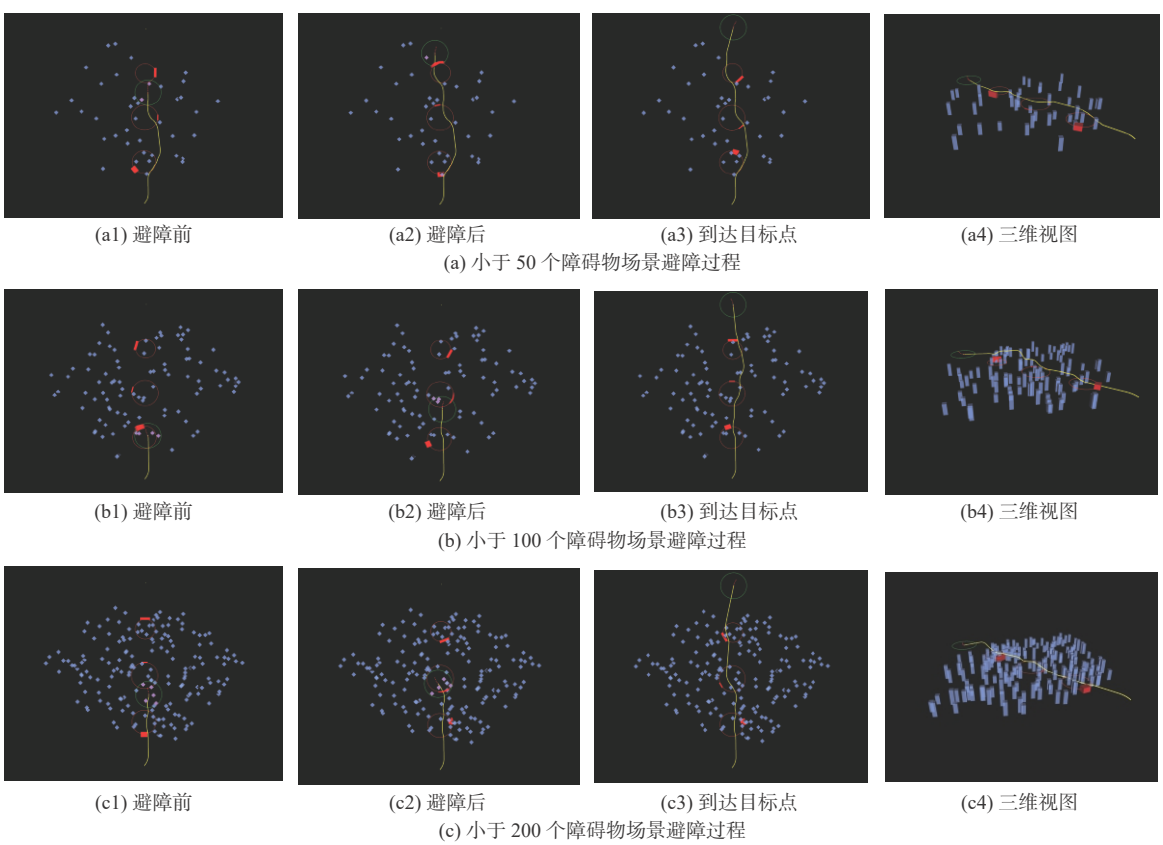
(d) 阶段成本组成分量的变化曲线

图 5　Q-Learning 对 NBO 的有效性仿真结果

Fig. 5　Simulation results of effectiveness of Q-Learning on NBO

碍物数量分别为 50、100、200 以内 3 种随机场景，并添加了 3 个以半径分别为 180、100、200 m 的圆形轨迹运动的动态障碍物。场景大小为 2 000 m×2 000 m×500 m, 规划模型和跟踪模型均为式 (1) 中的运动学模型。

实验结果如图 6 所示，其中，图 6(a)场景中包



(a1) 避障前　(a2) 避障后　(a3) 到达目标点　(a4) 三维视图

(a) 小于 50 个障碍物场景避障过程

(b1) 避障前　(b2) 避障后　(b3) 到达目标点　(b4) 三维视图

(b) 小于 100 个障碍物场景避障过程

(c1) 避障前　(c2) 避障后　(c3) 到达目标点　(c4) 三维视图

(c) 小于 200 个障碍物场景避障过程

图 6　3 种不同障碍物数量的仿真场景

Fig. 6　Presents three simulation scenarios with different numbers of obstacles

含障碍物数量在 50 以内，图 6(a1)和图 6(a2)表示仿真过程中避障前后状态，图 6(a3)和图 6(a4)分别为仿真完成后的顶视图和 3D 视图。图 6(b)和图 6(c)分别为障碍物数量为 100 和 200 以内的场景。每张图中的 3 个大小不同的红色方块是动态障碍物，红色圆圈是提前设定的动态障碍物轨迹，黄色的线是无人机在运动学模型作用下走过的航路，在无人机朝向目标点跟踪的过程中，会实时以半径 200 m 的圆(图中的绿色圆圈)向周围环境感知静态和动态障碍物，感知到的障碍物则显示为粉色实体矩形，未被感知到的障碍物则为半透明的蓝色矩形，场景中矩形障碍物的高度均在 100～120 m 范围内。此外，可在图 6(a2)、图 6(b1)、图 6 (b2) 和图 6 (c2) 看出，当无人机在靠近动态障碍物时，对障碍物未来若干个时间跨度进行了预测，本文设置的预测步长为 5。

图 7 展示了如图 6 所示 3 种障碍物场景下整个仿真期间无人机避障距离的变化过程。能够发现，在这 3 种场景的整个仿真进程中，无人机与障碍物的最小距离均大于 0，这表明本文 QL-NBO 算法具备良好的避障能力。图中当障碍物数量小于 50 和 100 时，出现了曲线断裂的现象，其原因在于此时无人机感知到 200 m 范围内的静态和动态障碍物数量均为 0，致使避障距离变为无穷大，这同时也体现出该场景中障碍物的分布相对较为稀疏。而当障碍物数量小于 200 时，曲线保持连续，这说明无人机在每一时间跨度下均能感知到静态或动态障碍物。结合图 6 和图 7 可以看出，3 种障碍物场景下本文 QL-NBO 算法均能完成避障，体现了其在 3 种场景下的求解成功率较高，具有较好的鲁棒性，较为稳定。

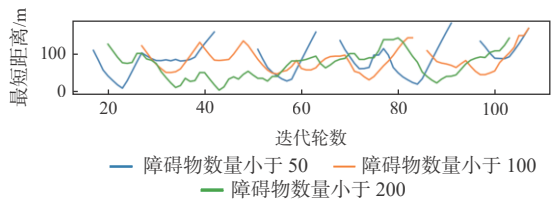


图 7 无人机与障碍物的最短距离

Fig. 7 Minimum distance between the UAV and obstacles

6.4 不同障碍物场景下求解时间对比

对算法求解时间的度量对于优化资源利用具有重要意义，尤其在资源有限的状况下，有助于使用者遴选出高效的算法。本文分别于障碍物数量小于 50、80、100、120、150、200 的障碍物场景下，针对 HybridA*算法[45]、NBO(Dual)算法[31-32]、NBO(LSE)算法[30]及本文 QL-NBO(LSE)算法，从起点至终点执行完一次定点目标跟踪任务，对其平均计算时间展开对比，结果如表 2 所示。

表 2 多种算法不同障碍物场景下的平均单次计算时间对比

Table 2 Comparison of average single calculation time of multiple algorithms in different obstacle scenarios

算法	时间/s					
	障碍物数量小于50	障碍物数量小于80	障碍物数量小于100	障碍物数量小于120	障碍物数量小于150	障碍物数量小于200
HybridA*(a_{cc} = 0.25; t = 5.0 s)	0.01	0.01	–	–	–	–
HybridA*(a_{cc} = 0.125; t = 5.0 s)	0.02	0.33	3.51	–	–	–
HybridA*(a_{cc} = 0.1; t = {1,2,3,4,5} s)	0.02	0.52	8.31	–	–	–
NBO(Dual)	0.22	0.21	0.24	0.83	0.84	0.83
NBO(LSE)	0.05	0.08	0.08	0.08	0.14	0.14
QL-NBO(LSE)	0.08	0.08	0.14	0.14	0.15	0.15

注：“–”表示搜索失败。

表 2 中的障碍物数量分别为各个场景中各自障碍物的总数，当障碍物越多时无人机所感知到的障碍物数量会越多，因此，每一时间跨度参与到优化中的障碍物数量会相应增加。此外，障碍物的数量都用小于进行表述是因为障碍物在生成时按照指定个数随机生成，当靠近起点或终点 500 m 范围内则不允许障碍物生成，因此，通常情况下生成的障碍物数量少于设定数量。

表 2 为 HybridA* 算法设定的 3 种离散加速度 a_{cc} 与时间步长的组合形式，当障碍物数量处于 80 以下时，所有算法均可实现规划任务。然而，当障碍物数量渐增至 100 时，HybridA*算法第 1 种参数无法在规定时间内完成计算；而当障碍物数量进一步增加至 120 时，HybridA*算法第 2 种和第 3 种参数组合也未能在规定时间内达成计算。通过对这 3 种参数的比较分析可知，Hybrid A* 算法受离散加速度的影响颇为显著。在障碍物相对稀少的场景中，仅需离散程度较低的加速度即可搜索出完整的从起点至终点的路径。但随着障碍物数量的增多，为搜索到路径，搜索维度需相应提升，所耗费的时间也随之增加。

反观 NBO(Dual)算法、NBO(LSE)算法及本文 QL-NBO(LSE)算法，其在所有障碍物环境中的表现均较为稳定。其中，与 NBO(Dual)算法相比，其余 2 种算法的计算耗时更少，展现出了较好的实时性。在应对小于 200 个障碍物时，每个迭代的平均

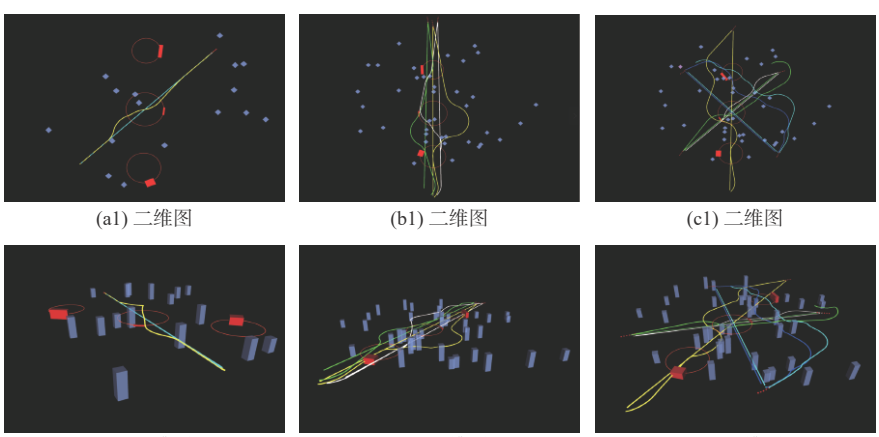
耗时大致维持在 0.1 s 左右, 具有较高的计算效率。此外, 由于本文 QL-NBO 算法 属于在线实时规划算法, 相较于 NBO(LSE) 算法, 该算法在计算时间方面的优势并不突出, 其优势主要体现在求解质量及整个跟踪过程的闭环性能上(6.2 节实验 已表明该点)。

进一步深入剖析 HybridA* 算法整体计算成功率较低的另一原因: eVTOL 在固定翼模式下存在非完整性约束, 由于失速速度的限制, 无人机无法将速度降至 0, 这在速度约束方面对算法的可行域造成了限制。当障碍物密集时, 尽管 HybridA*算法通过提高离散程度能够提升搜索成功率, 但其相应的耗时也会增加。对于在未知场景下以固定翼模式飞行的 eVTOL 而言, 该算法无法应用于其实时航路规划之中。需要指出的是, 这仅仅是针对静态障碍物环境而言, 若考虑动态障碍物, 将会面临更为严峻的挑战, 如何平衡其搜索维度和计算时间是一个难题。不过, 当障碍物较少时, 从表 2 可以看出, 其计算实时性较高。因此, 在障碍物较少的简单环境下, HybridA*算法具有显著的实时性优势, 且对于静态环境的离线规划, 或是具备完整性约束的系统, 例如, 能够进行微分平坦处理的四旋翼无人机系统, 由于速度可以为 0, 极大拓展了速度规划的范围, 此时应用 HybridA*算法也具有较好的优势, 关于本文涉及的 HybridA *算法, 详情可参考文献 [45]。

6.5　动态目标跟踪下单机和多机避障

实验 2、实验 3 和实验 4 均为静态目标下的测试, 为测试本文算法在动态目标下的跟踪避障能力及对于单机和多机规划的扩展能力, 本文设计了 1 架、3 架和 5 架无人机分别同时对动态目标跟踪的实验, 场景中放置了少于 50 个静态障碍物和 3 个动态障碍物, 仿真结果如图 8 所示, 避障距离变化如图 9 所示。其中, 针对 1 架无人机场景, 无人机 1 的起终点分别为(20,20,80)m 和(2 000,2 000,80)m, 跟踪目标起点和终点也为(20,20,80)m 和(2 000,2 000,80)m; 针对 3 架无人机场景, 无人机 1、无人机 2 和无人机 3 的起点分别为(20,20,80)m、(200,40,80)m 和(20, 200,80)m, 对应的终点分别为(2 000,2 000,80)m、(2 100,2 000,80)m 和(2 000,2 100,80)m, 相应每架无人机所跟踪的目标的起点分别为(20,20,80)m、(80, 20,80)m 和(20,80,80)m, 对应的终点分别为(2 000, 2 000,80)m、(2 000,2 020,80)m 和(2 020,2 000,80)m; 针对 5 架无人机场景, 无人机 1、无人机 2、无人机 3、无人机 4 和无人机 5 的起点分别为(20,20,80)m、(20,1 000,80)m、(2 000,1 020,80)m、(1 000, 20, 80)m 和(1 020,2 000,80)m, 对应的终点分别为(2 000,2 000, 80)m、(2 000,1 000,80)m、(20,1 020,80)m、(1 000, 2 000, 80)m 和(1 020,20,80)m, 相应每架无人机所跟踪的目标起点分别为(20,20,80)m、(20,1 000, 80)m, (2 000,1 200,80)m、(1 000, 20, 80)m 和(1 200, 2 000,80)m, 对应的终点分别为(2 000,2 000,80)m、(2000,1 000,80)m、(20,1 200,80)m、(1 000,2000,80)m 和(1 200,20,80)m。所有动态目标均以 20 m/s 的速度匀速直线朝对应的终点运动, 实验全程确保目标点是可知的, 但考虑了当前位置和目标位置通视和被障碍物阻挡的情况, 此时目标函数中对目标点的跟踪部分根据式(19)进行计算, 感知模块主要获取当前位置 200 m 范围内的障碍物参与规划。此外, 针对多目标跟踪, 需要将式(35)中目标函数增加关于无人机间距离的 LSE 平滑项, 且该距离的度量也采用本文提到的多面体间的全维度距离计算方式(见式(33))。

图 8 为 1 架、3 架和 5 架无人机在动态目标跟



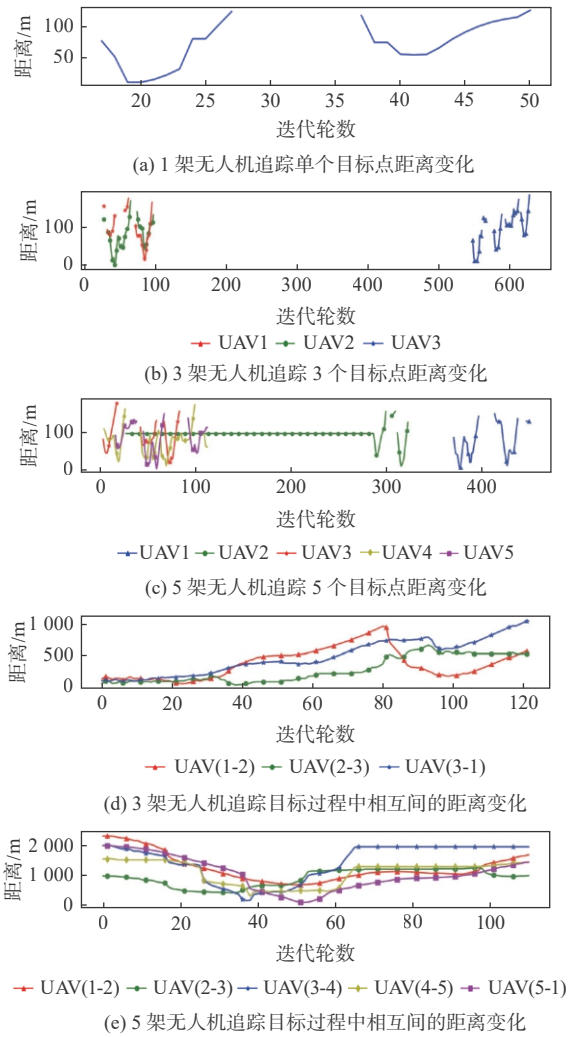
(a1) 二维图　(b1) 二维图　(c1) 二维图

(a2) 三维图　(b2) 三维图　(c2) 三维图

(a) 单架无人机追踪单个目标点　(b) 3 架无人机追踪 3 个目标点　(c) 5 架无人机追踪 5 个目标点

图 8　1 架、3 架、5 架无人机动态目标跟踪效果

Fig. 8　Dynamic target tracking effect of 1, 3, and 5 UAVs



(a) 1 架无人机追踪单个目标点距离变化

(b) 3 架无人机追踪 3 个目标点距离变化

(c) 5 架无人机追踪 5 个目标点距离变化

(d) 3 架无人机追踪目标过程中相互间的距离变化

(e) 5 架无人机追踪目标过程中相互间的距离变化

图 9 不同数量无人机跟踪时的距离变化

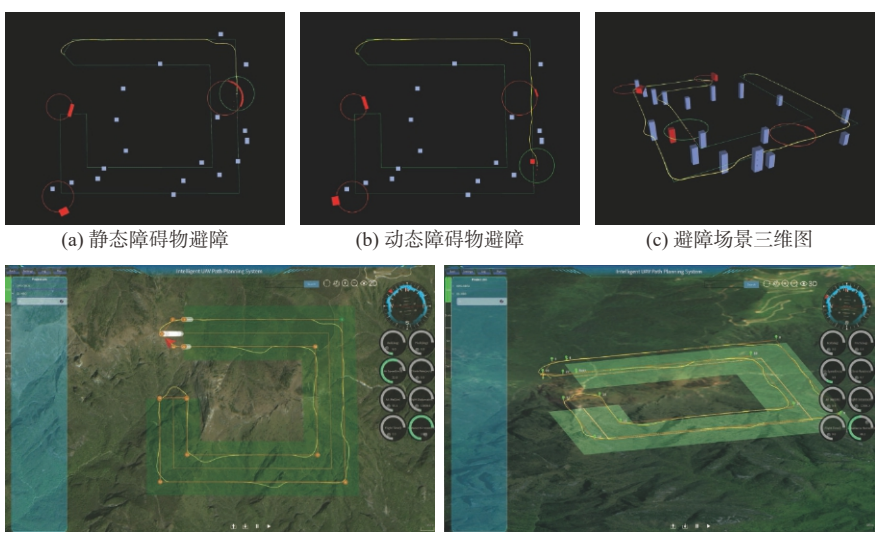
Fig. 9 Distance variations during tracking with different numbers of UAVs

踪场景下的仿真截图，每张图中直线为无人机所跟踪的目标，其中，图 8(b1)、图 8(b2)、图 8(c1)和图 8(c2)中的目标路径颜色和对应无人机路径颜色相同，方便区分。从图 8 可以直观地看出，单架和多架无人机场景下均能对动态目标完成跟踪并避障。图 9 为图 8 中对应的跟踪过程中无人机距离所感知范围内障碍物的最小距离的变化曲线，直观地从图中就能看出所有的避障距离均大于 0，表明无人机既完成了动态目标跟踪，又能躲避障碍物，也考虑了无人机间的距离，展示了本文 QL-NBO(LSE)算法对于单机和多机之间扩展的灵活性。

6.6 航路任务下的硬件在环测试

航线跟踪任务的规划模型使用了式(1)中的运动学模型，跟踪模型为 px4，并采用硬件在环仿真进行验证，控制系统采用 px4 原有的位置控制外环和姿态控制内环[46]，系统采用规划和控制分离的架构，在规划层采用收紧的 MPC，采用 Tube-based-MPC 进行优化问题求解，控制层则采用 eVTOL 本身的动力学模型进行跟踪，该方法的优势在于简化的模型能够加快 MPC 的求解，以提供满足实时性要求的预测参考轨迹引导无人机飞行。硬件在环仿真环节，首先，执行 px4 程序，再启动航路规划系统，然后，在地面站规划任务航线，并上传到飞控，规划系统订阅无人机的航路任务和实时位置，在地面站解锁并使无人机起飞则开始执行任务。该环节可以验证规划框架的稳定性和算法的实用性。无人机开始以旋翼模式飞到 80 m 高度，转换到固定翼模式，此时通过手动控制将无人机切换为 OffBoard 模式。

在整个任务执行过程中，无人机将航路规划系统的位置三元组作为参考，沿着任务航线飞行，当感知到周围存在障碍物时，系统开始实时在航线上生成要跟踪的目标航点 (图 10 中的紫色航点) 以引导无人机飞行，规划模块根据每个时间跨度是否感



(a) 静态障碍物避障 (b) 动态障碍物避障 (c) 避障场景三维图

(d) 地面站端顶视图 (e) 地面站端三维图

图 10 航线任务避障决策过程

Fig. 10 Obstacle avoidance path planning process of the flight mission

知到障碍物而选择开启或停用, 整个任务场景中, 静态和动态障碍物的设置和定点跟踪任务是相同的, 不同之处在于本文将第 3 个时间跨度的航点实时发送给飞控端跟踪, 主要是因为在硬件在环仿真中, 每次无人机前进的位置和所期望的位置会有偏差, 如果将第 2 个航点发送给无人机, 由于受初始航向的影响, 使跟踪效果变差, 避障过程如图 10 所示。

从图 10 可以看出, 无人机在感知到障碍物时会开启规划模块, 且能够生成未来 5 个时间跨度的航点 (可以在图 10(a)中看到有 6 个红色的离散航点), 在生成的航点前方的紫色航点为动态生成的目标点。图 10(a)为无人机正在对动态障碍物进行避障, 可以看到, 红色障碍物向前生成了 5 个时间跨度的半透明红色障碍物, 用来模拟对动态障碍物的轨迹预测, 结合图 10(b)看出, 此时无人机的轨迹变化不大, 表明考虑了动态障碍物的轨迹信息; 图 10(b)为无人机正在对静态障碍物进行避障, 感知到 200 m 范围的障碍物为其右侧高亮长方体, 结合图 10(c)可以看出完成了对静态障碍物的避障; 图 10(c)为任务场景的三维图, 图中无人机虽然感知到了一个静态障碍物(绿色圆圈所包含的红色长方体), 但由于距离障碍物较远, 因此, 对执行轨迹影响不大。图 10(d)和图 10(e)分别为本次任务执行中无人机走过的航路在地面站端的二维和三维可视化。可以看出, 本文规划框架能够综合任务需要和避障需要进行决策规划并完成任务。

7　结　论

1) 本文对未知环境下无人机目标跟踪航路规划问题展开深入研究, 设计并开发了能够随机生成障碍物的仿真环境, 用以对本文 QL-NBO 算法和规划框架进行验证。

2) 本文方法深入探究了 POMDP 模型, 借助 MPC 实现了 NBO 算法。针对避障需求, 引入全维度避障距离度量, 在满足避障基本要求的前提下, 当障碍物数量相同时, 相比基于对偶变换原理的避障优化问题提高了求解效率。

3) 针对 MPC 本身难以消除误差的问题, 提出 QL-NBO 算法, 该算法基于 Q-Learning 强化学习框架达成了 MPC 框架中相关参数的动态调整, 有效提升了目标跟踪的闭环性能, 同时通过实验验证了其从单机到多机的协同避障方面具有良好扩展性。

4) 在系统应用方面, 本文提供了一个实时航路规划系统, 并基于 px4、ROS、RVIZ、Gazebo 开展了软件仿真和硬件在环仿真, 通过实验验证了本文规划框架的可行性、鲁棒性和有效性。

未来, 可基于该框架和算法进一步扩展其在多机任务中的应用, 如集群打击, 协同作业等。可在感知和传感器误差的灵敏性问题、多无人机间的通信覆盖和优化及协同作业中的执行效率等方面进行深入研究。此外, 在硬件在环仿真时, 无人机的跟踪效果受到初始航迹偏角的影响, 导致与软件仿真的结果存在偏差。后续可基于该框架, 进一步从速度优化和控制器设计的角度进行研究以改善其跟踪效果。

参考文献（References）

[1] Dong J, Ota K, Dong M X. UAV-based real-time survivor detection system in post-disaster search and rescue operations[J]. IEEE Journal on Miniaturization for Air and Space Systems, 2021, 2(4): 209-219.

[2] Liu X L, Ansari N. Resource allocation in UAV-assisted M2M communications for disaster rescue[J]. IEEE Wireless Communications Letters, 2019, 8(2): 580-583.

[3] Alharam A, Almansoori E, Elmadeny W, et al. Real time AI-based pipeline inspection using drone for oil and gas industries in Bahrain[C]//Proceedings of the International Conference on Innovation and Intelligence for Informatics, Computing and Technologies. Piscataway: IEEE Press, 2020: 1-5.

[4] Shamsoshoara A, Afghah F, Blasch E, et al. UAV-assisted communication in remote disaster areas using imitation learning[J]. IEEE Open Journal of the Communications Society, 2021, 2: 738-753.

[5] Guo Q, Peng J, Xu W Z, et al. Minimizing the longest tour time among a fleet of UAVs for disaster area surveillance[J]. IEEE Transactions on Mobile Computing, 2022, 21(7): 2451-2465.

[6] Dong W J, Qi X Z, Chen Z X, et al. An indoor path planning and motion planning method based on POMDP[C]//Proceedings of the IEEE International Conference on Robotics and Biomimetics. Piscataway: IEEE Press, 2017: 1564-1570.

[7] Trotti F, Farinelli A, Muradore R. An online path planner based on POMDP for UAVs[C]//Proceedings of the European Control Conference. Piscataway: IEEE Press, 2023: 1-6.

[8] Morere P, Marchant R, Ramos F. Sequential Bayesian optimization as a POMDP for environment monitoring with UAVs[C]//Proceedings of the IEEE International Conference on Robotics and Automation. Piscataway: IEEE Press, 2017: 6381-6388.

[9] Deng D H, Wang C W, Wang W D. Joint air-to-ground scheduling in UAV-aided vehicular communication: a DRL approach with partial observations[J]. IEEE Communications Letters, 2022, 26(7): 1628-1632.

[10] Aniceto Dos Santos M A, Vivaldini K C T. A modeling strategy using Bayesian optimization with POMDP for exploration and informative path planning of UAVs in monitoring of forest[C]//Proceedings of the International Conference on Computational Science and Computational Intelligence. Piscataway: IEEE Press, 2022: 451-456.

[11] Silver D, Veness J. Monte-Carlo planning in large POMDPs [C]//Proceedings of the 24th International Conference on Neural Information Processing Systems - Volume 2. New York: ACM, 2010: 2164-2172.

[12] Ye N, Somani A, Hsu D, et al. DESPOT: online POMDP planning with regularization[J]. Journal of Artificial Intelligence Research, 2017, 58(1): 231-266.

[13] Bai H Y, Cai S J, Ye N, et al. Intention-aware online POMDP planning for autonomous driving in a crowd[C]//Proceedings of the IEEE International Conference on Robotics and Automation. Piscataway: IEEE Press, 2015: 454-460.

[14] Kurniawati H, Yadav V. An online POMDP solver for uncertainty planning in dynamic environment[M]//Robotics Research: The 16th International Symposium ISRR. Berlin: Springer, 2016: 611-629.

[15] Priyadarshini G N, Hsu D, Sun L W. DESPOT-alpha: online POMDP planning with large state and observation spaces[C]//Proceedings of the Robotics: Science and Systems XV. Robotics: Science and Systems Foundation, 2019.

[16] Klimenko D, Song J, Kurniawati H. TAPIR: a software toolkit for approximating and adapting POMDP solutions online[C]//Proceedings of the Australasian Conference on Robotics and Automation. Sydney: Australian Robotics and Automation Association, 2014: 28.

[17] Cunningham A G, Galceran E, Eustice R M, et al. MPDM: multipolicy decision-making in dynamic, uncertain environments for autonomous driving[C]//Proceedings of the IEEE International Conference on Robotics and Automation. Piscataway: IEEE Press, 2015: 1670-1677.

[18] Ding W C, Zhang L, Chen J, et al. EPSILON: an efficient planning system for automated vehicles in highly interactive environments[J]. IEEE Transactions on Robotics, 2022, 38(2): 1118-1138.

[19] Adiprawita W, Ahmad A S, Sembiring J, et al. Reinforcement learning with heuristic to solve POMDP problem in mobile robot path planning[C]//Proceedings of the International Conference on Electrical Engineering and Informatics. Piscataway: IEEE Press, 2011: 1-5.

[20] Lee Y, Cai P P, Hsu D. MAGIC: learning macro-actions for online POMDP planning[C]//Proceedings of the Robotics: Science and Systems XVII. Robotics: Science and Systems Foundation, 2021.

[21] Miller S A, Harris Z A, Chong E K P. A POMDP framework for coordinated guidance of autonomous UAVs for multitarget tracking[J]. EURASIP Journal on Advances in Signal Processing, 2009, 2009(1): 724597.

[22] Ragi S, Chong E K P. UAV path planning in a dynamic environment via partially observable Markov decision process[J]. IEEE Transactions on Aerospace and Electronic Systems, 2013, 49(4): 2397-2412.

[23] Yang Q M, Zhang J D, Shi G Q. Modeling of UAV path planning based on IMM under POMDP framework[J]. Journal of Systems Engineering and Electronics, 2019, 30(3): 545-554.

[24] Eaton C M, Chong E K P, Maciejewski A A. Robust UAV path planning using POMDP with limited FOV sensor[C]//Proceedings of the IEEE Conference on Control Technology and Applications. Piscataway: IEEE Press, 2017: 1530-1535.

[25] Cai W Q, Kordabad A B, Esfahani H N, et al. MPC-based reinforcement learning for a simplified freight mission of autonomous surface vehicles[C]//Proceedings of the 60th IEEE Conference on Decision and Control. New York: ACM, 2021: 2990-2995.

[26] Gros S, Zanon M. Data-driven economic NMPC using reinforcement learning[J]. IEEE Transactions on Automatic Control, 2020, 65(2): 636-648.

[27] Esfahani H N, Kordabad A B, Gros S. Approximate robust NMPC using reinforcement learning[C]//Proceedings of the European Control Conference. Piscataway: IEEE Press, 2021: 132-137.

[28] Lagoudakis M G, Parr R. Least-squares policy iteration[J]. Journal of Machine Learning Research, 2003, 4: 1107-1149.

[29] Airaldi F, De Schutter B, Dabiri A. Reinforcement learning with model predictive control for highway ramp metering[EB/OL]. (2025-02-03)[2026-09-11]. https://doi.org/10.48550/arXiv.2311.08820.

[30] Han Z C, Wu Y W, Li T, et al. An efficient spatial-temporal trajectory planner for autonomous vehicles in unstructured environments[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(2): 1797-1814.

[31] Zhang X J, Liniger A, Borrelli F. Optimization-based collision avoidance[J]. IEEE Transactions on Control Systems Technology, 2021, 29(3): 972-983.

[32] He R X, Zhou J Y, Jiang S, et al. TDR-OBCA: a reliable planner for autonomous driving in free-space environment[C]//Proceedings of the American Control Conference. Piscataway: IEEE Press, 2021: 2927-2934.

[33] Wang Y X, Wang H L, Lun Y B. Shortest path planning of UAV for target tracking and obstacle avoidance in 3D environment[C]//Proceedings of the 39th Chinese Control Conference. Piscataway: IEEE Press, 2020: 3385-3390.

[34] Das M, Ghosh S K. Reducing parameter value uncertainty in discrete Bayesian network learning: a semantic fuzzy Bayesian approach[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2021, 5(3): 361-372.

[35] Youn W, Ko N Y, Gadsden S A, et al. A novel multiple-model adaptive Kalman filter for an unknown measurement loss probability[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 8500511.

[36] Partovibakhsh M, Liu G J. An adaptive unscented Kalman filtering approach for online estimation of model parameters and state-of-charge of lithium-ion batteries for autonomous mobile robots[J]. IEEE Transactions on Control Systems Technology, 2015, 23(1): 357-363.

[37] Dong F, Li X C, You K Y, et al. Standoff tracking using DNN-based MPC with implementation on FPGA[J]. IEEE Transactions on Control Systems Technology, 2023, 31(5): 1998-2010.

[38] Bauersfeld L, Spannagl L, Ducard G J J, et al. MPC flight control for a tilt-rotor VTOL aircraft[J]. IEEE Transactions on Aerospace and Electronic Systems, 2021, 57(4): 2395-2409.

[39] Feng Z W, Cao G Y, Grigoriadis K M, et al. Secure MPC-based path following for UAS in adverse network environment[J]. IEEE Transactions on Industrial Informatics, 2023, 19(11): 11091-11101.

[40] Jacquet M, Kivits M, Das H, et al. Motor-level N-MPC for cooperative active perception with multiple heterogeneous UAVs[J]. IEEE Robotics and Automation Letters, 2022, 7(2): 2063-2070.

[41] Liu Y Y, Van Schijndel J, Longo S, et al. UAV energy extraction with incomplete atmospheric data using MPC[J]. IEEE Transactions on Aerospace and Electronic Systems, 2015, 51(2): 1203-1215.

[42] Falugi P, Mayne D Q. Getting robustness against unstructured un-

certainty: a tube-based MPC approach[J]. IEEE Transactions on Automatic Control, 2014, 59(5): 1290-1295.

[43] Xiao K, Tan S C, Wang G H, et al. XTDrone: a customizable multi-rotor UAVs simulation platform[C]//Proceedings of the 4th International Conference on Robotics and Automation Sciences. Piscataway: IEEE Press, 2020: 55-61.

[44] Xiao K, Ma L, Tan S C, et al. Implementation of UAV coordination based on a hierarchical multi-UAV simulation platform[C]// Proceedings of the Advances in Guidance, Navigation and Control. Singapore: Springer Singapore, 2022: 5131-5143.

[45] Zhou B Y, Gao F, Wang L Q, et al. Robust and efficient quadrotor trajectory generation for fast autonomous flight[J]. IEEE Robotics and Automation Letters, 2019, 4(4): 3529-3536.

[46] Yang J, Liu C J, Coombes M, et al. Optimal path following for small fixed-wing UAVs under wind disturbances[J]. IEEE Transactions on Control Systems Technology, 2021, 29(3): 996-1008.

UAV online path planning based on POMDP and parameterized MPC in uncertain environments

YUAN Jinbiao[1]，LIU Haiyan[2]，MA Bodi[3]，ZHAO Leyang[4]，GAO Honggang[1]，LIU Zhenbao[1,*]

(1. School of Civil Aviation，Northwestern Polytechnical University，Xi'an 710072，China；
2. Shanghai Civil Aviation Control and Navigation System Co.，Ltd，Shanghai 200241，China；
3. School of Information Engineering，Chang'an University，Xi'an 710016，China；
4. School of Architecture & Urban Planning，Shenzhen University，Shenzhen 518060，China)

Abstract: It is challenging to eliminate positioning and perception ambiguities when unmanned aerial vehicles (UAVs) operate autonomously in unfamiliar areas. In view of this, it is necessary to conduct research on path planning to enhance the effectiveness of the path under the interference of uncertain factors and thereby improve the target tracking ability of UAVs. The goal of applying model predictive control（MPC）to the real-time path planning system is currently accomplished by Tube-based-MPC, which supports the separation architecture of planning and control, and nominal belief state optimization (NBO), which offers a theoretical foundation for the uncertainty of target tracking. On this premise, this paper proposes an online path planning framework to solve the problems of target tracking and obstacle avoidance in unknown environments. First, the path planning problem is abstracted into a partially observable Markov decision process (POMDP) model, and the Kalman filter is used to estimate the belief state, integrating the uncertainty measure of target positioning into the framework. Secondly, based on the simplified 3-dimensional motion model, a tightened constraint Tube-based-MPC optimization framework is constructed to solve the POMDP. The path planning for a specific continuous time span in the future is achieved by building a nonlinear optimization problem that includes the belief state and unknown barriers. Then, the shapes of UAVs and obstacles are fully considered in the optimization problem, and a full-dimensional obstacle avoidance distance metric is introduced to significantly expand the feasible region of the optimization problem. Finally, the Q-learning reinforcement learning framework is introduced, and MPC is used as the policy function approximator to improve the closed-loop performance of target tracking. Simulation experiments and hardware-in-the-loop experiments verified the effectiveness of the proposed method.

Keywords: partially observable Markov decision process; Tube-based-MPC; path planning; reinforcement learning; target tracking

Received：2024-09-06；**Accepted**：2024-11-15；**Published Online**：2024-11-22 17：09

URL：link.cnki.net/urlid/11.2625.V.20241122.1600.001

Foundation items：National Natural Science Foundation of China (52072309,12102345); Key Research and Development Program of Shaanxi Province (2019ZDLGY14-02-01,2022FP-40); Shenzhen Fundamental Research Program (JCYJ20190806152203506); Aeronautical Science Foundation (ASFC-2018ZC53026); Suzhou Municipal Science and Technology Bureau under Grant (ZXL2023177); Taicang Basic Research Program under Grant (TC2023JC13)

* **Corresponding author**. E-mail：liuzhenbao@nwpu.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0843

基于风险约束的城市空域无人机安全路径规划

朱元军[1,2]，李妍[1,2]，张学军[1,2,*]，张维东[2,3]

(1. 北京航空航天大学 电子信息工程学院，北京 100191；2. 北京航空航天大学 空地一体新航行系统技术全国重点实验室，北京 100191；3. 北京航空航天大学 网络空间安全学院，北京 100191)

摘 要：面向未来低空经济的发展需要，针对城市空域无人机（UAVs）的安全路径规划问题，使用栅格法建模来表征离散三维空间，综合考虑无人机性能、无人机运行安全风险约束、城市空域结构等因素的影响，构建以最小化路径综合代价为目标函数的无人机三维安全路径规划模型。提出改进的风险约束A*（RC-A*）算法搜索无人机最优安全路径：采用考虑无人机物理参数、性能参数、地面人员密度和风险缓解措施的运行风险评估模型；设计综合距离代价和风险代价的实际代价函数与启发式函数；引入转向角度限制条件，提高算法的搜索效率。设计基于真实场景的仿真实验，结果表明：所提算法具备在城市三维空间中规划无人机安全路径的能力，与标准的A*算法相比，2组实验中路径总风险分别减少了67.34%和57.98%。

关 键 词：城市交通；无人机；路径规划；风险评估；风险约束
中图分类号：V279
文献标志码：A **文章编号**：1001-5965(2026)11-3958-11

“低空经济”作为新质生产力和战略性新兴产业典型代表，正被积极打造成为新的增长引擎。作为低空经济的主要载体，无人机(unmanned aerial vehicles, UAVs)近年来持续处于蓬勃发展时期，广泛应用在军事和民用的各应用领域[1-2]。随着无人机等航空器加入低空尤其是城市低空空域运行，城市空中交通(urban air mobility, UAM)[3]系统概念被提出，并引发广泛关注。可以说，UAM系统已经成为未来智能运输系统发展的必然趋势。目前，国内外业界和学术界已对其涉及的关键理论与核心技术展开了初步探索与研究[4-5]。其中，基于可接受风险的无人机运行规划技术研究是保障城市低空飞行安全的关键，其核心思路就是通过考虑城市运行安全风险约束、无人机的飞行性能等因素，为无人机系统规划出一条运行风险尽量最小化的有效飞行路径。

对于传统的无人机路径规划问题，国内外学者已经开展了广泛的研究，形成了较为成熟的体系，主要可以分为：以混合整数线性规划(mixed-integer linear programming, MILP)算法等为代表的线性规划算法[6]，以Dijkstra算法、A*算法、快速扩展随机树(rapidly-exploring random tree, RRT)算法等为代表的图搜索算法[7-8]，以遗传算法(genetic algorithm, GA)、蚁群优化(ant colony optimization, ACO)算法和粒子群优化(particle swarm optimization, PSO)算法为代表的智能优化算法[9-10]，和以深度强化学习算法为代表的人工智能类算法[11]等。但上述算法各有优缺点，对于在城市空域的无人机路径规划问题，众多学者做出了一系列针对性改进优化。胡莘婷等[12]提出了一种改进聚类蚁群算法来实现离散型城市环境下的安全路径规划。Primatesta等[13]提出了一种基于风险感知的城市环境无人机路径规划策略，使用风险地图将空间的离散位置与适当的风险代价相结合，进而实现路径的静态和动态规

收稿日期：2024-11-27；录用日期：2025-02-14；网络出版时间：2025-03-27 15:57
网络出版地址：link.cnki.net/urlid/11.2625.V.20250327.1510.001
基金项目：安徽省科技创新攻坚计划项目 (202423h08050007)
*通信作者. E-mail：zhxj@buaa.edu.cn

引用格式：朱元军，李妍，张学军，等. 基于风险约束的城市空域无人机安全路径规划 [J]. 北京航空航天大学学报，2026，52（11）：3958-3968. Zhu Y J，Li Y，Zhang X J，et al. Risk-constrained safe path planning for unmanned aerial vehicles in urban airspace [J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：3958-3968（in Chinese）.

划。张洪海等[14]结合城市低空物流配送要求, 提出一种综合考虑运行风险、噪声水平和运输成本的无人机路径规划方法, 能够实现多目标优化。王飞等[15]构建一种考虑物流配送顺序和路径协同规划的双层模型, 提出了一种改进的 PSO 算法求解无人机有效飞行路径。Pang 等建立了考虑地面风险、财产损失、噪声影响等综合成本的评估模型, 提出一种基于分布估计算法和 CostA*的混合估计算法[16], 实现城市空域无人机路径规划, 并进一步在文献 [17] 中针对飞行冲突问题, 提出了一种考虑风险约束的自适应冲突解脱决策方法来对预先规划的无人机路径进行优化。

纵观上述成果, 现有研究已在城市空域无人机安全路径规划领域做出了积极探索, 但仍有不足之处。部分研究仅考虑碰撞风险, 没有从路径规划的角度减少故障发生后造成的地面人员伤亡损失; 部分研究虽能规划得到综合考虑风险的有效路径, 但很难同时兼顾安全性和效率; 也有部分研究仅在仿真场景中对无人机路径规划方法进行验证对比, 无法保证城市实际复杂飞行环境的适用性。

针对上述问题, 本文综合考虑了无人机的飞行高度、转向角度、运行风险、路径长度和可用空域等约束条件, 建立评价无人机路径效率和安全性的路径综合代价模型; 引入动态评价路径目标区域风险分布情况的启发式函数, 可以根据算法的搜索状态提供更加精确的启发式信息; 以最小化无人机路径综合代价为优化目标, 提出了基于风险约束 A*(risk-constrained A*, RC-A*)算法的无人机城市空域安全路径规划方法, 可以有效搜索到城市三维空间中无人机的最优安全路径。

1　无人机安全路径规划问题建模

1.1　城市空域环境模型

城市空域是无人机运行的基础, 为表征空域运行环境, 利用栅格将城市三维空域进行离散化处理, 将范围$n\times m\times l$的栅格交叉点作为节点, 并进行编号。将三维空间离散化表示成一个分布均匀的三维点云, 用矩阵$\boldsymbol{P}_{n,m,l}$来描述, 其中, $P(i,j,h)(i=1,2,\cdots,n;j=1,2,\cdots,m;h=1,2,\cdots,l)$表示空间中的坐标为$(i,j,h)$的一个点, 则三维矩阵在高度$h$上的平面矩阵可以表示为

$$\boldsymbol{P}_{n,m,l}=\begin{bmatrix}P(1,1,h) & P(1,2,h) & \cdots & P(1,m,h)\\ P(2,1,h) & P(2,2,h) & \cdots & P(2,m,h)\\ \vdots & \vdots & & \vdots\\ P(n,1,h) & P(n,2,h) & \cdots & P(n,m,h)\end{bmatrix} \tag{1}$$

将城市低空环境中的建筑物视为无人机运行的静态障碍, 在三维空间矩阵中, 用 1 表示城市建筑物所占用的空间点, 用 0 表示城市建筑物未占用的空间点, 可以得到矩阵$\boldsymbol{B}_{n,m,l}$用来表示城市建筑物占用的节点, 表达式为

$$B(i,j,h)=\begin{cases}1\\0\end{cases} \tag{2}$$

式中: $B(i,j,h)$表示建筑物点云$\boldsymbol{B}_{n,m,l}$中的坐标为(i,j,h)的点。

对矩阵$\boldsymbol{B}_{n,m,l}$取反, 则得到对于无人机飞行可以使用的空间, 表示为矩阵$\boldsymbol{U}_{n,m,l}$, 其中所有的节点就是无人机可能使用的潜在飞行航路节点。如图 1 所示, 用一系列的航路节点R_r^{P}来表示无人机的飞行路径, 记为路径R_{Path}, 具体如下:

$$R_{\mathrm{Path}}=\{R_0^{\mathrm{P}},R_1^{\mathrm{P}},\cdots,R_k^{\mathrm{P}}\} \tag{3}$$

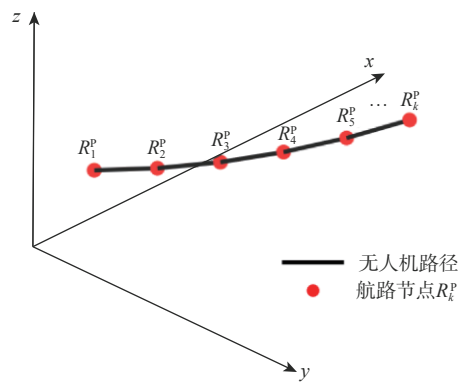


图 1　飞行路径在离散三维空间中的表示形式

Fig. 1　Depiction of flight path in discrete 3D airspace

1.2　无人机运行风险矩阵模型

无人机的运行风险表示无人机系统在空中失效并坠毁在城市地面造成的人员伤亡期望, 是无人机在城市空域中飞行给公共安全带来的最重要影响。在城市空域$\boldsymbol{P}_{n,m,l}$中, 可以构建大小相匹配的三维运行风险矩阵$\boldsymbol{R}_{n,m,l}$, 则在高度h上的平面矩阵为

$$\boldsymbol{R}_{n,m,l}=\begin{bmatrix}R(1,1,h) & R(1,2,h) & \cdots & R(1,m,h)\\ R(2,1,h) & R(2,2,h) & \cdots & R(2,m,h)\\ \vdots & \vdots & & \vdots\\ R(n,1,h) & R(n,2,h) & \cdots & R(n,m,h)\end{bmatrix} \tag{4}$$

式中: $R(i,j,h)$为无人机在坐标为(i,j,h)位置飞行时的运行风险, 其含义是无人机在该坐标位置坠毁时造成的伤亡期望, 其数值受到无人机空中失效概率和最终地面风险大小的共同影响, 单位为伤亡人数/飞行小时, 计算式为

$$R(i,j,h)=P(L)R_{\mathrm{f}}(i,j,h) \tag{5}$$

式中: $P(L)$为无人机在空中飞行时失效并坠毁的概率; $R_{\mathrm{f}}(i,j,h)$为无人机坠毁在地面上位置为(i,j,h)网

格内的最终地面风险值，可以用最终地面风险矩阵$\boldsymbol{R}_{\mathrm{f}}$来表示。

无人机的最终地面风险表示当无人机已经失效后坠毁在地面时给地面人员造成的风险影响，其值等于无人机初始地面风险矩阵$\boldsymbol{R}_i$和无人机风险缓解措施效果矩阵$\boldsymbol{M}$的哈达玛积，表达式为

$$\boldsymbol{R}_{\mathrm{f}}=\boldsymbol{R}_i\odot\boldsymbol{M} \tag{6}$$

无人机的初始地面风险$\boldsymbol{R}_i$为无人机运行的固有属性，仅与无人机的特征参数（最大特征尺寸、最大起飞质量、巡航速度）和坠落区域的地面人群密度有关[18]，$\boldsymbol{R}_i$元素表达式为

$$R_i(i,j,h)=D_{\mathrm{peo}}A_{\mathrm{cas}} \tag{7}$$

式中：D_{peo}为无人机坠毁区域的地面人员密度；A_{cas}为无人机坠毁造成的伤亡区域面积。

无人机风险缓解措施效果矩阵$\boldsymbol{M}$则表示无人机坠毁采用缓解措施时的作用效果[19]，分为M1和M2这2种类型，计算式为

$$\boldsymbol{M}=\boldsymbol{M}_1\odot\boldsymbol{M}_2 \tag{8}$$

式中：矩阵$\boldsymbol{M}_1$和$\boldsymbol{M}_2$分别表示M1类型和M2类型2种措施的缓解效果。

M1类型是减少直接暴露在风险区域中的人群数量，可以通过量化地面建筑物等要素对人员受到无人机撞击的保护效果来表示。无人机撞击造成的致死率P_{f}为

$$P_{\mathrm{f}}=(1-k)\Bigg/\left[1-2k+\sqrt{\frac{\alpha}{\beta}}\left(\frac{\beta}{E_{\mathrm{crash}}}\right)^{\frac{3}{P_{\mathrm{s}}}}\right] \tag{9}$$

式中：P_{s}为地面遮蔽系数；参数α为当$P_{\mathrm{s}}=6$时致死率$P_{\mathrm{f}}=50\%$所需的撞击能量值；参数β为无人机撞击人类致死所需的能量阈值；E_{crash}为无人机撞击时的动能；k为校正因子，适用于当无人机撞击瞬时动能较低时的情况，可由式(10)计算：

$$k=\min\left[1,\left(\frac{\beta}{E_{\mathrm{crash}}}\right)^{\frac{3}{P_{\mathrm{s}}}}\right] \tag{10}$$

M2类型是减少无人机撞击地面造成的影响，目前广泛受到关注的方法是给无人机安装降落伞。通过分析降落伞系统在无人机空中失效后的运动学过程，来表征M2措施的缓解效果。以本文研究的DJI M350多旋翼无人机为例，图2分析了装配降落伞的多旋翼无人机失效后的坠落过程，在理想状态下，受到重力和空气阻力F_{airdrag}的影响，速度方向与空气阻力方向相反。下降过程可以分为2个阶段，第1阶段无人机失去动力，从匀速水平飞行的状态转为弹道下降状态，此时降落伞系统没有工作；第2阶段降落伞系统打开，无人机进入降落伞下降状态。图2中，F_{power}为无人机动力。

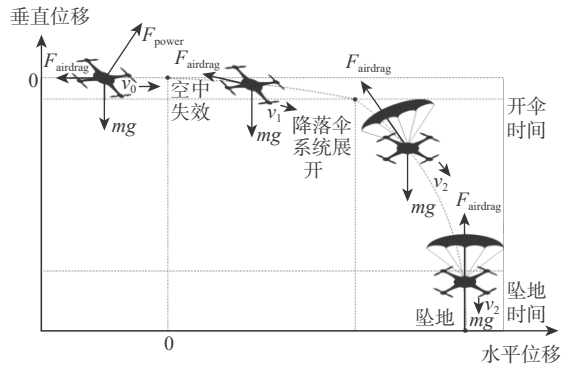


图2 多旋翼无人机失效后坠落过程分析

Fig. 2 Analysis of falling process of a multirotor UAV

具体关于无人机地面风险计算方式的推导，可以参考文献[20]，本文不多做赘述。

1.3 无人机路径规划优化模型

基于风险约束的无人机安全路径规划问题，本质上是要在含有风险因素的可用三维空间中，找到一条从起点到目标点综合代价最小的最优路径。目标是优化无人机的路径综合代价，可表示为式(11)，约束无人机飞行路径综合代价的因素有飞行高度、转向角度、运行风险、路径长度和可用空域等。

$$\min C_{\mathrm{Path}}=\sum_{r=1}^{K}C_r \tag{11}$$

式中：C_{Path}为无人机执行飞行任务的路径综合代价；$C_r(r=1,2,\cdots,K)$为无人机在$R_{r-1}^{\mathrm{P}}R_r^{\mathrm{P}}$这一路径段上的综合代价。

无人机在三维风险空间中寻找最优路径的约束条件如下。

1）飞行高度约束。在本文中，设置城市空域可以使用的飞行高度区间为$[h_{\mathrm{low}},h_{\mathrm{high}}]$，无人机在运行过程的阶段（不包括起飞和降落）应在该高度范围内飞行，同时需要绕过或飞跃不同高度的建筑物。

2）转向角度约束。本文以受到较多关注的多旋翼无人机作为研究对象，考虑到无人机的性能限制，约束路径规划算法的搜索角度范围，即无人机在三维空间中的飞行方向变化角度$\theta_{\mathrm{UAV}}\in[0,\pi/3]$。

3）运行风险约束。基于运行风险矩阵，无人机在单位路径段上飞行所带来的风险代价（即造成的伤亡期望）可以由式(12)和式(13)计算：

$$C_{\mathrm{risk}}^{r}=t_rR(i,j,h) \tag{12}$$

$$t_r=\left\|\overrightarrow{R_{r-1}^{\mathrm{P}}R_r^{\mathrm{P}}}\right\|_2\Big/v_{\mathrm{UAV}} \tag{13}$$

式中: C_{risk}^{r}为单位路径的风险代价; t_r为无人机从航路节点R_{r-1}^{P}飞行到R_r^{P}所用的时间; $\left\|\overrightarrow{R_{r-1}^{\text{P}}R_r^{\text{P}}}\right\|_2$为无人机从航路节点$R_{i-1}^{\text{P}}$飞行到$R_i^{\text{P}}$所移动的距离; v_{UAV}为无人机的巡航速度。

4) 路径长度约束。在离散的三维空间中, 无人机的飞行路径R_{Path}可以连接所有相邻航路节点来表示, 计算每组相邻航路节点的欧几里得距离并求和, 则可以得到总飞行路径长度。对于任意一段单位路径$R_{r-1}^{\text{P}}R_r^{\text{P}}$, 其路径长度可以表示为

$$C_{\text{dist}}^{r}=\left\|\overrightarrow{R_{r-1}^{\text{P}}R_r^{\text{P}}}\right\|_2 \tag{14}$$

式中: C_{dist}^{r}为单位路径的路径长度。

5) 可用空域约束。飞行路径规划算法的搜索空间应在无人机可飞行的空间节点矩阵$\boldsymbol{U}_{n,m,l}$内, 为使路径规划算法搜索过程中避开地形建筑物, 则需要约束。

将城市空域中无人机飞行路径的综合代价作为目标函数, 无人机的飞行高度、转向角度、运行风险、路径长度和可用空域作为约束条件, 可以得到三维空间中无人机的路径规划问题模型为

$$\begin{cases}\min \quad C_{\text{Path}}=\sum\limits_{r=1}^{K}C_r=\sum\limits_{r=1}^{K}(\alpha_1 C_{\text{dist}}^{r}+\alpha_2 C_{\text{risk}}^{r})\\ \text{s.t.}\quad \begin{cases}h_{\text{low}}\leqslant h_{\text{UAV}}\leqslant h_{\text{high}}\\ \theta_{\text{UAV}}\leqslant\dfrac{\pi}{3}\\ C_{\text{dist}}^{r}=\left\|\overrightarrow{R_{r-1}^{\text{P}}R_r^{\text{P}}}\right\|_2\\ C_{\text{risk}}^{r}=R(i,j,h)\dfrac{\left\|\overrightarrow{R_{r-1}^{\text{P}}R_r^{\text{P}}}\right\|_2}{v_{\text{UAV}}}\end{cases}\end{cases} \tag{15}$$

式中: α_1和α_2分别为路径长度代价和风险代价的权重系数, 且满足$\alpha_1+\alpha_2=1$。

2　三维安全路径规划算法设计

A*算法是一种经典的启发式搜索算法, 广泛应用于二维平面内的最短路径规划问题。标准 A*算法从开放列表中搜索具有最小总代价函数$f(r)$的节点r进行处理:

$$f(r)=g(r)+h(r) \tag{16}$$

式中: $g(r)$为从起始点到节点r的实际代价; $h(r)$为从节点r到目标点的估计代价的启发式函数。

在三维空间无人机路径规划问题中引入 A*算法时, 需要对 A*算法的实际代价函数和启发式函数进行改进, 以便同时考虑飞行距离和风险因素。

2.1　实际代价函数设计

在考虑静态运行风险约束的三维空间中, 仅使用欧氏距离作为距离代价的实际代价函数并不能评价路径的安全性, 需要将风险信息纳入计算。因此, 本文在设计复合实际代价函数时, 综合考虑了路径的距离代价和风险代价, 如下:

$$G(r)=G(r-1)+\alpha_1 C_{\text{dist}}^{r}+\alpha_2 C_{\text{risk}}^{r} \tag{17}$$

式中: $G(r-1)$为从起始点到父节点R_{r-1}^{P}的实际累积代价; C_{dist}^{r}为节点R_{r-1}^{P}到节点R_r^{P}的距离代价; $C_{\text{risk}}^{\text{r}}$为节点$R_{r-1}^{\text{P}}$到节点$R_r^{\text{P}}$的风险代价, 且满足$\alpha_1+\alpha_2=1$。

在计算风险代价时, 因为实际数值与单位的影响, 导致风险代价数值与距离代价数值会相差很大数量级, 相加容易造成风险代价被忽略。距离代价数值是基于所建立模型的单位标准值计算, 即每个网格单位长度为 1 m, 因此, 需要对风险代价进行归一化处理, 如式(18)所示, 使归一化后的风险代价和距离代价能够在同一数量级进行比较。

$$C_{\text{norm,risk}}^{r}=\frac{R(i,j,h)}{R_{\text{norm}}}\cdot\frac{\left\|\overrightarrow{R_{r-1}^{\text{P}}R_r^{\text{P}}}\right\|_2}{v_{\text{UAV}}} \tag{18}$$

式中: $C_{\text{norm,risk}}^{r}$为归一化后的风险代价; R_{norm}为该区域路径的归一化风险水平, 取风险矩阵元素的平均值和中位数中的较小值来代表该区域的风险水平的集中分布趋势, 作为归一化风险水平, 其表达式为

$$R_{\text{norm}}=\min\left(\frac{\sum\limits_{\boldsymbol{R}_{n,m,l}}R(i,j,h)}{n\times m\times l},M(R(i,j,h))\right) \tag{19}$$

式中: $M(R(i,j,h))$为风险矩阵元素中所有风险值的中位数。

2.2　启发式函数设计

启发式函数的作用是估算从当前节点R_r^{P}到目标节点的预期代价。传统的欧几里得距离启发式函数只能反映距离代价, 因此, 需要改进启发式函数的计算方法, 使其在预期代价估计中纳入目标路径上的风险预估。

将从当前节点到目标节点路径的预期代价分为两部分: 距离代价和风险代价。构建预期距离代价函数$H_{\text{dist}}(r)$, 使用欧几里得距离计算当前节点R_r^{P}到目标节点的直线距离, 则有:

$$H_{\text{dist}}(r)=\left|\left|\boldsymbol{p}_{R_r^{\text{P}}}-\boldsymbol{p}_{\text{GOAL}}\right|\right|_2 \tag{20}$$

式中: $\boldsymbol{p}_{R_r^{\text{P}}}$和$\boldsymbol{p}_{\text{GOAL}}$分别为当前节点$R_r^{\text{P}}$和目标节点的三维位置向量。

为估计目标路径上的风险代价, 构建当前节点R_r^{P}到目标节点的归一化预期风险代价函数$H_{\text{norm,risk}}(r)$, 用归一化预期风险估值和预计飞行时间相乘得到:

$$H_{\text{norm,risk}}(r)=\frac{R_{\text{pred}}(r)}{R_{\text{norm}}}t_{\text{pred}} \tag{21}$$

$$t_{\text{pred}}=\frac{\left|\left|\boldsymbol{p}_{R_r^{\text{P}}}-\boldsymbol{p}_{\text{GOAL}}\right|\right|_2}{v_{\text{UAV}}} \tag{22}$$

式中：$R_{\text{pred}}(r)$为从当前节点R_r^{P}到目标节点的预计风险估值；t_{pred}为预计飞行时间。

由于风险在不同空域单元中分布不均匀且难以预测，导致很难获取合适的启发式函数值。当启发式函数值过大，可能会导致风险代价下限提高，从而降低算法的性能；相反，如果启发式函数值过小，则在下限范围内搜索空间变大，算法的计算效率会明显降低。找到一个合适的启发式函数值可以使算法在路径质量和计算效率之间取得良好的平衡，因此，选择合适的方法计算预计风险估值是改进启发式函数的重要步骤。

选取以当前节点R_r^{P}到目标节点的线段为对角线的立方体范围，立方体的6个面平行或垂直于网格空间的坐标平面，如图3所示。用该立方体空间表示预期风险代价的搜索空间范围，记为集合$P(x,y,z)$，则有

$$\begin{cases}\min(i_r,i_{\text{g}})\leqslant x\leqslant\max(i_r,i_{\text{g}})\\ \min(j_r,j_{\text{g}})\leqslant y\leqslant\max(j_r,j_{\text{g}})\\ \min(h_r,h_{\text{g}})\leqslant z\leqslant\max(h_r,h_{\text{g}})\end{cases} \tag{23}$$

式中：(i_r,j_r,h_r)和$(i_{\text{g}},j_{\text{g}},h_{\text{g}})$分别表示节点$R_r^{\text{P}}$和目标节点的三维坐标；$x,y,z$均为正整数。

统计搜索空间范围$P(x,y,z)$内所有空间点的风险值分布情况，计算预期风险代价如下：

$$R_{\text{pred}}(r)=\min(R_{\text{avg}},R_{\text{med}}) \tag{24}$$

式中：R_{avg}为搜索空间范围内所有节点的平均风险值，由式(25)计算；R_{med}为该范围内所有节点风险值的中位数，由式(26)计算。

$$R_{\text{avg}}=\frac{1}{n_P}\sum_{P}R(x,y,z) \tag{25}$$

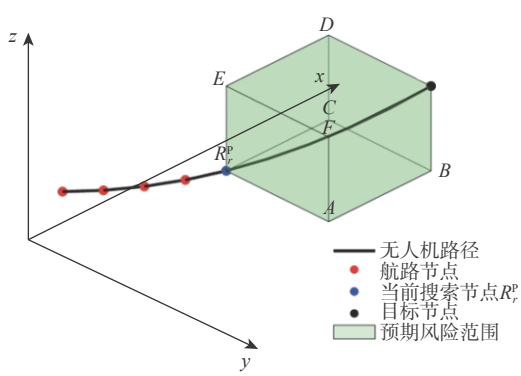


图3 改进启发式函数的预期风险代价统计范围

Fig. 3 Statistical range of predicted risk cost for improved heuristic function

$$R_{\text{med}}=M(R(x,y,z)) \tag{26}$$

式中：n_P为搜索空间范围内的所有节点个数。

在搜索空间范围内的风险数据集中，R_{avg}和R_{med}都可以表征风险数据的分布情况和集中趋势，取两者的较小值可以让路径的风险范围落在较小的区间内。这种方式可以使启发式函引导算法找到质量更好的路径。综合预期距离代价和预期风险代价，可以构建改进的启发式函数为

$$H(r)=\alpha_1H_{\text{dist}}(r)+\alpha_2H_{\text{norm,risk}}(r) \tag{27}$$

通过调节权重系数，可以平衡距离和风险在启发式函数中的权重。

2.3 快速搜索策略设计

在离散三维空间中，对于每一个航路点R_r^{P}，其周围有26个邻居节点可以作为可选择的下一个潜在航路节点。为提升算法性能，避免路径规划算法在某些特殊节点陷入局部最优，同时考虑到无人机的性能限制，约束路径规划算法的搜索角度范围，即无人机飞行方向变化角度$\theta_{\text{UAV}}\in[0,\pi/3]$。在本文使用的模型中，无人机飞行方向的变化角度计算式为

$$\theta_{\text{UAV}}=\arccos\left(\frac{\overrightarrow{R_{r-1}^{\text{P}}R_r^{\text{P}}}\cdot\overrightarrow{R_r^{\text{P}}R_{r+1}^{\text{P}}}}{\overrightarrow{R_{r-1}^{\text{P}}R_r^{\text{P}}}\times\overrightarrow{R_r^{\text{P}}R_{r+1}^{\text{P}}}}\right) \tag{28}$$

式中：$\overrightarrow{R_{r-1}^{\text{P}}R_r^{\text{P}}}$和$\overrightarrow{R_r^{\text{P}}R_{r+1}^{\text{P}}}$分别表示从航路点$R_{r-1}^{\text{P}}$到$R_r^{\text{P}}$和从航路点$R_r^{\text{P}}$到$R_{r+1}^{\text{P}}$的2个向量。

限制无人机只向当前航路节点前方角度范围$[0,\pi/3]$内搜索，可以使算法在选择下一扩展节点时，只向当前航路节点前方的若干个备选点搜索，提升搜索效率，如图4所示。

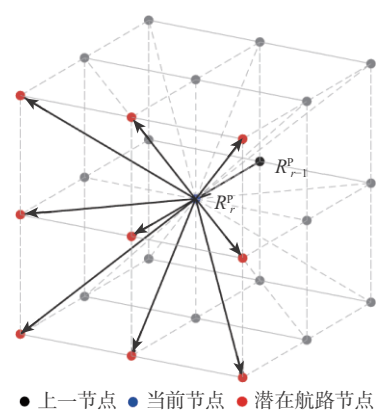


图4 离散三维空间中当前节点的潜在航路节点

Fig. 4 Current nodes and potential route nodes in discrete 3D space

2.4 改进的A*算法流程

综合实际代价函数和启发式函数，改进的A*算法总代价函数$F(r)$表达式为

$$F(r)=G(r)+H(r) \tag{29}$$

本文算法的实现流程如图 5 所示, 具体步骤如下。

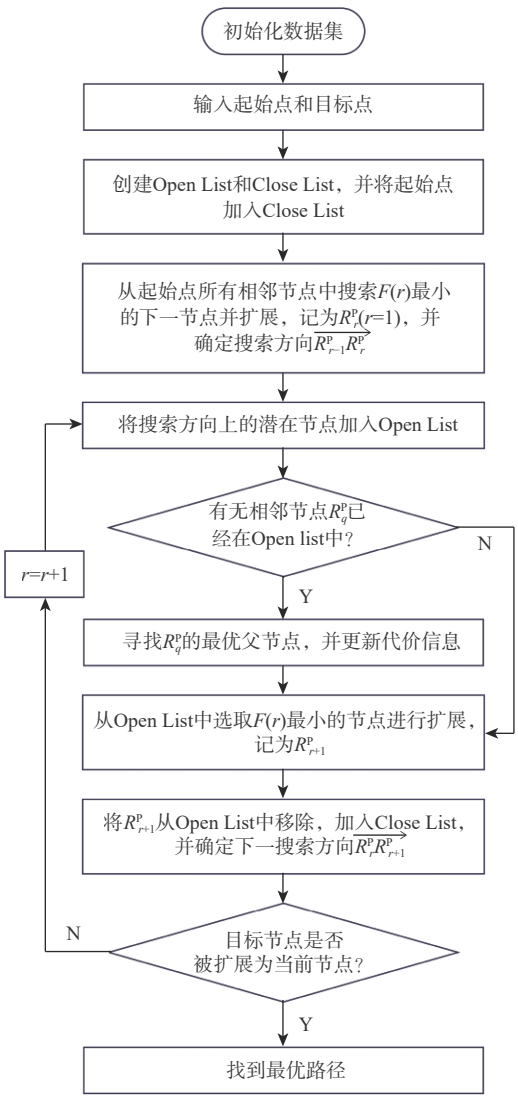


图 5　本文改进的 RC-A*算法流程

Fig. 5　Flow of the improved RC-A* algorithm

步骤 1　初始化无人机的性能参数、地形函数、静态运行风险函数、飞行路径约束条件、可用搜索空间等。

步骤 2　输入起始点和目标点的位置坐标。

步骤 3　创建开放列表 Open List, 用于储存待探索的节点, 并将起始点加入 Open List; 创建闭合列表 Close List, 用于储存已探索过的节点。

步骤 4　将起始点相邻的 26 个节点加入 Open List, 分别计算总代价函数值 $F(r)$, 选择 $F(r)$值最小的节点扩展, 记作 $R_r^p(r=1)$, 并将 R_r^p加入 Close List。

步骤 5　循环执行以下步骤。

1) 将当前节点 R_r^p在 $\overrightarrow{R_{r-1}^pR_r^p}$(当 r=1 时, R_{r-1}^p为起始点)方向上的 9 个潜在节点(非 Close List 中的节点)加入 Open List。

2) 若其中有节点 R_q^p已经在 Open List 中, 则表明节点 R_q^p此前已经被扩展, 需要确定节点 R_q^p的最优父节点。若当前节点 R_r^p到达节点 R_q^p的实际累计代价值 $G(r)$比原节点更低, 则更新其代价信息和父节点索引, 确保找到的路径总是最优。

3) 分别计算 Open List 中所有节点的总代价函数值 $F(r)$, 选择 $F(r)$值最小的节点扩展, 记作 R_{r+1}^p, 并将 R_{r+1}^p加入 Close List。

4) 更新节点序号 r=r+1。

步骤 6　当目标节点被选为当前节点时, 表示已经找到了最优路径, 终止循环步骤 5; 否则, 当 Open List 为空时, 表示不存在从起始点到目标点的可行路径, 终止循环步骤 5。

3　仿真实验与分析

3.1　仿真场景与参数设置

为验证本文算法的有效性, 使用 MATLAB 进行仿真实验。仿真场景数据选取深圳市南山区大小为 1.2 km×1.2 km 的真实场景, 深圳是中国发展低空经济的首批试点城市之一, 美团等公司已经在深圳实际开展了无人机配送的业务, 因此, 用深圳作为仿真场景更具实际意义, 同时, 该区域的风险分布疏密明显, 在仿真场景中对算法具备良好的测试能力。采用栅格法对仿真场景进行建模, 图 6 为该区域中的建筑物群在离散三维空间中的可视图, 其中, x 轴方向为由北到南, y 轴方向为由西到东。

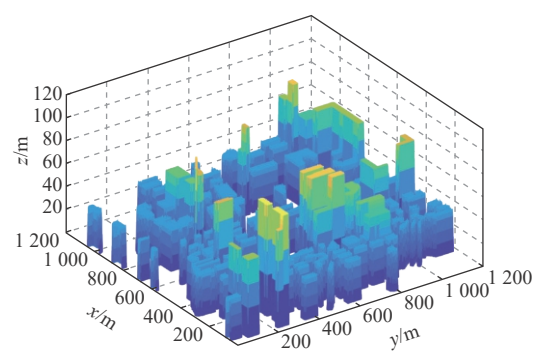


图 6　仿真场景设置

Fig. 6　Simulation scenario setting

使用谷歌地图和开放街道地图(open street map, OSM)地图的数据集, 统计和测算地表要素, 以计算地面遮蔽系统, 并基于 worldpop 全球人口分布数据集模拟人口密度数据。以 DJI M350 无人机为研究对象, 使用文献 [20] 的方法计算该无人机在城市空域飞行的三维运行风险矩阵。计算涉及到的关键参数如表 1 所示, 三维运行风险矩阵的可视化展示形式如图 7 所示。

表1 运行风险矩阵关键参数

Table 1 Key parameters of operations risk matrix

参数	数值
无人机系统失效概率$P(L)$	10^{-7}
重力加速度g/(m·s^{-2})	9.8
α/J	3.4×10^{4}
β/J	34
无人机起飞质量m/kg	9.2
无人机巡航速度v_{UAV}/(m·s^{-1})	20

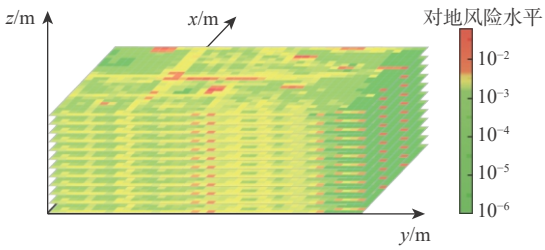


图7 三维运行风险矩阵表征

Fig. 7 Representation of 3D operations risk matrix

本文仿真了基于图结构搜索路径的RRT*算法、标准A*算法、文献[13]中提出的经典RiskA*算法和本文提出的改进RC-A*算法在同一场景中的安全路径规划能力，其中，RiskA*算法使用的启发式信息基于全局风险水平计算。仿真场景主要参数和路径规划算法参数设置如表2所示。

表2 仿真场景与路径规划算法参数

Table 2 Parameters of simulation scenario and path planning algorithm

参数	数值
仿真场景大小/m	1 200×1 200
栅格大小/m	1
最大飞行高度h_{high}/m	90
最小飞行高度h_{low}/m	30
最大转向角度θ_{UAV}/rad	$\pi/3$
起始点1坐标/m	(100,1 100,30)
起始点2坐标/m	(900,1 150,30)
目标点1坐标/m	(1 100,100,30)
目标点2坐标/m	(10,10,30)
距离代价权重α_1	0.4
风险代价权重α_2	0.6
算法搜索步长	10

3.2 仿真结果分析

仿真分别验证了4种算法从起始点(100,1 100,30) m到目标点(1 100,100,30) m，和起始点(900,1 150,30) m到目标点(10,10,30) m这2组路径的性能，实验数据如表3和表4所示，实验结果如图8～图11所示。其中，路径综合代价可以衡量算法生成路径的质量，路径总风险表示无人机按生成的路径执行单次飞行任务造成的伤亡人数期望，可以代表生成路径的安全水平。

表3 无人机路径规划算法性能比较（组1）

Table 3 Performance comparison of UAV path planning algorithms (group 1)

算法	路径点数量/个	路径总长度/m	路径总风险	路径综合代价
RRT*	178	1 758.94	1.32×10^{-7}	996.38
标准A*	101	1 439.64	5.48×10^{-8}	761.82
RiskA*[13]	163	1 965.05	1.83×10^{-8}	782.13
RC-A*	150	1 708.57	1.79×10^{-8}	717.20

表4 各算法相对于标准A*算法性能比较（组1）

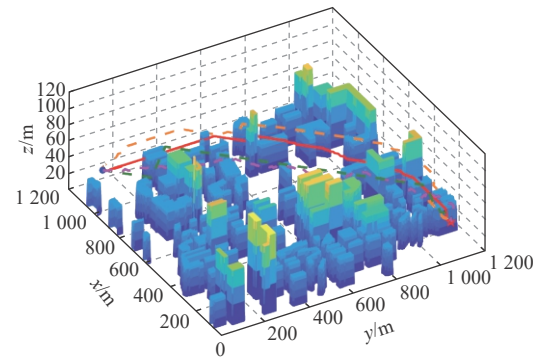
Table 4 Performance comparison relative to the standard A* algorithm (group 1)

算法	与标准A*算法对应指标的比值/%			
	路径点数量	路径总长度	路径总风险	路径综合代价
RRT*	176.24	122.18	240.88	130.79
RiskA*[13]	161.39	136.50	33.39	102.67
RC-A*	**148.51**	**118.68**	**32.66**	**94.14**

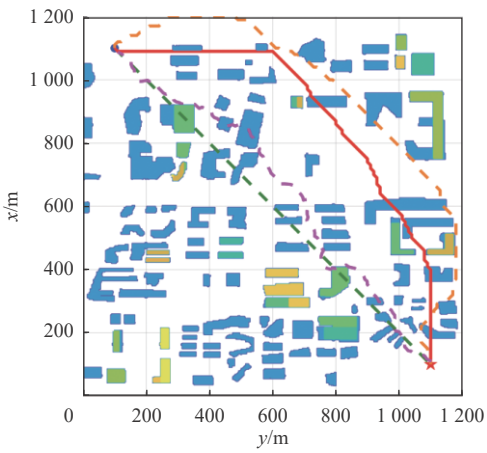
注：表中数据为各算法指标与标准A*算法对应指标的比值，标准A*算法对应值为100%。

表3是4种算法从起始点(100,1 100,30) m到目标点(1 100,100,30) m寻找到的无人机路径数据，表4中数据字体加粗代表最优，4种算法均能寻找到可用路径。本文RC-A*算法相比较于标准A*算法，路径总长度增加了18.68%，但路径总风险减少了67.34%，路径综合代价降低了5.86%，且在这3项数据上的表现均优于RRT*算法和RiskA*算法。

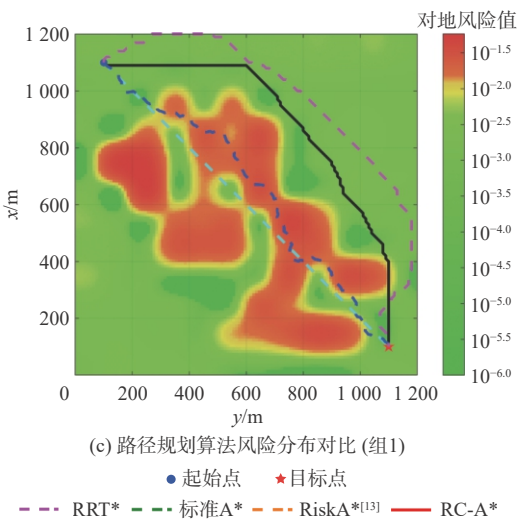
图8展示了4种算法路径规划结果，综合图8(a)和图8(b)可以看出，RRT*算法寻找到了一条较优的可行路径，标准A*算法寻找到了一条距离最短的路径。但在图8(c)所展示的二维风险热力图中，标准A*算法和RRT*算法均经过了高风险区域，因



(a) 路径规划算法三维结果对比 (组1)



(b) 路径规划算法二维结果对比 (组1)



(c) 路径规划算法风险分布对比 (组1)

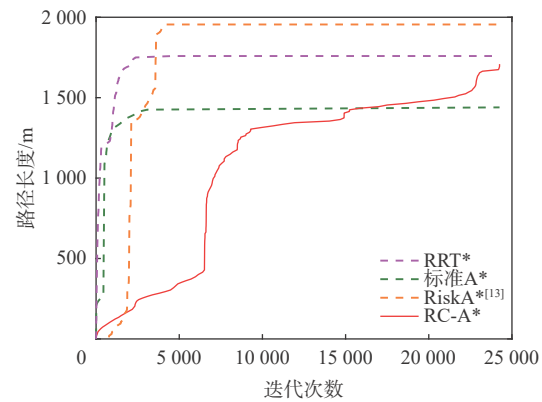
图 8　无人机路径规划结果对比(组 1)

Fig. 8　Comparison of the results for UAV path planning (group 1)

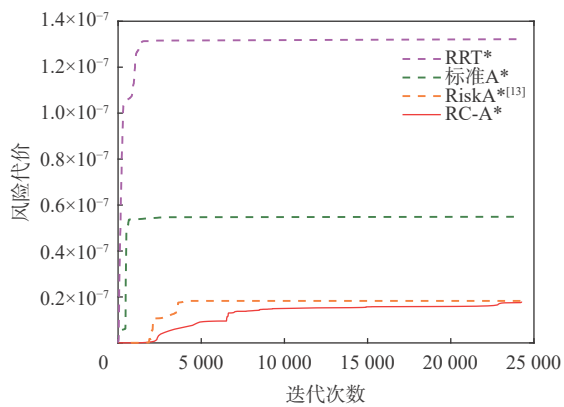
此, 路径的总风险代价较高, 而文献 [13] 提出的 RiskA*算法和本文提出的 RC-A*算法均有效规避了高风险区域, 相较于 RiskA*算法, 本文算法使用的动态启发式信息可以使算法在距离代价和风险代价的平衡性上表现更优, 从而使对应的路径综合代价更小。

因为 4 种算法都是基于图搜索的方式, 采用从起始点向目标点搜索的策略, 所以统计了 4 种算法寻找到的最终路径数据随着迭代次数的变化情况。图 9 展示了 4 种算法的路径数据收敛情况对比, RC-A*算法相比于 RiskA*算法收敛速度相对较慢, 但风险代价和路径综合代价在搜索过程中始终优于 RiskA*算法。RRT*算法和标准 A*算法虽然可以快速收敛, 但风险代价较高, 路径质量较差。

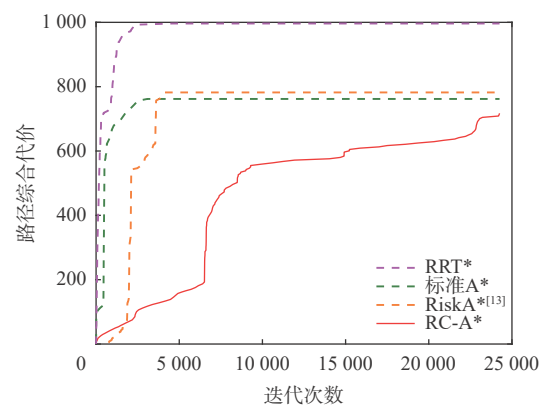
表 5 为 4 种算法在起始点 (900,1 150,30) m 到目标点 (10,10,30) m 生成的路径数据。表 6 中数据字体加粗代表最优, 本文 RC-A*算法相比较于标准 A*算法, 路径总长度增加了 6.57%, 但路径总风险减少了 57.98%, 路径综合代价减少了 5.13%; 相较于 RiskA*算法, 路径总风险增加了 51.76%, 但路径



(a) 路径长度收敛情况 (组1)



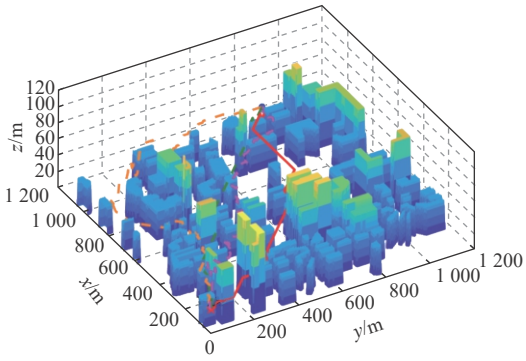
(b) 风险代价收敛情况 (组1)



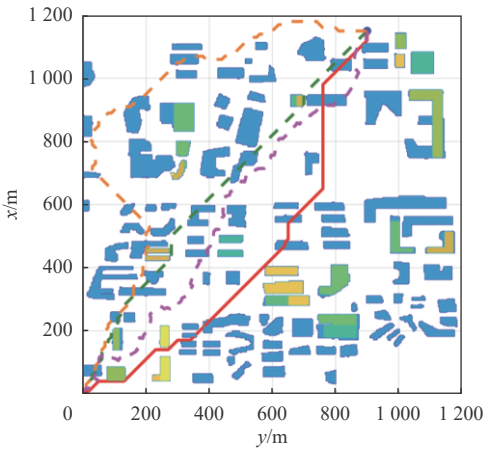
(c) 路径综合代价收敛情况 (组1)

图 9　4 种路径数据随迭代次数变化情况对比(组 1)

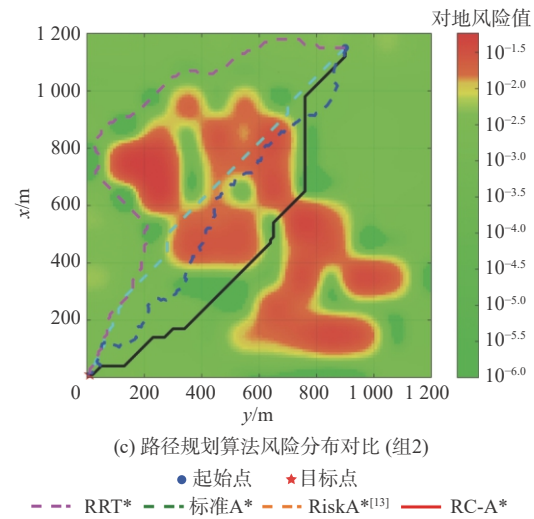
Fig. 9　Comparison of data changes in four paths with number of iterations (group 1)



(a) 路径规划算法三维结果对比 (组2)



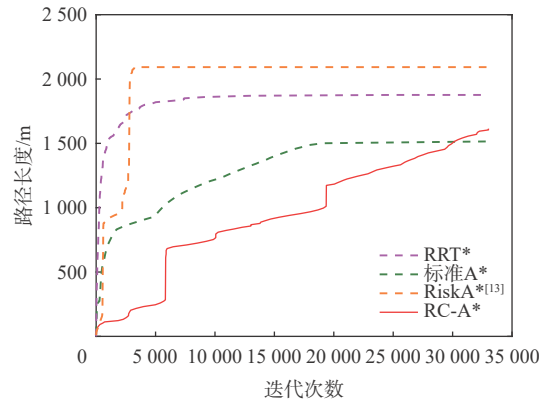
(b) 路径规划算法二维结果对比 (组2)



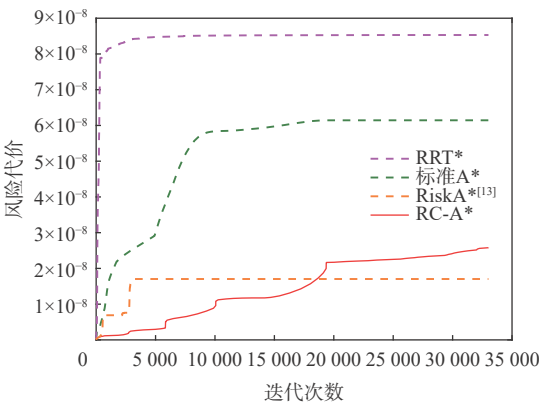
(c) 路径规划算法风险分布对比 (组2)

图 10 无人机路径规划结果对比(组 2)

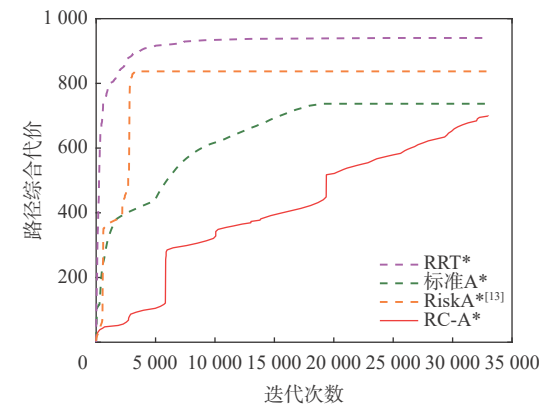
Fig. 10 Comparison of results for UAV path planning (group 2)



(a) 路径长度收敛情况 (组2)



(b) 风险代价收敛情况 (组2)



(c) 路径综合代价收敛情况 (组2)

图 11 4 种路径数据随迭代次数变化情况对比(组 2)

Fig. 11 Comparison of data changes in four paths with number of iterations (group 2)

总长度减少了 23.22%, 路径综合代价降低了 16.47%, 本文算法生成的路径质量更高。

图 10 展示了第 2 组仿真结果, 标准 A*算法和 RRT*算法寻找到的路径比较相似, 都穿过了高风险地区, RiskA*算法和 RC-A*算法的路径均避开了高风险区域, 算法具备对风险的规避能力。

图 11 展示了第 2 组仿真的路径数据收敛情况, 结合图 10(c) 和图 11(b) 可以看出, RiskA*算法在风险代价的表现上比较敏感, 原因是其使用了基于全局风险分布计算的启发式信息, 在局部的搜索调整能力上相比 RC-A*算法较弱, 因此, 在路径综合代

表 5 无人机路径规划算法性能比较(组 2)

Table 5 Performance comparison of UAV path planning algorithms (group 2)

算法	路径点数量/个	路径总长度/m	路径总风险	路径综合代价
RRT*	190	1 876.37	8.53×10^{-8}	940.28
标准A*	115	1 515.00	6.14×10^{-8}	737.01
RiskA*[13]	172	2 102.44	1.70×10^{-8}	837.08
RC-A*	132	1 614.59	2.58×10^{-8}	699.21

表 6　各算法相对于标准 A*算法性能比较（组 2）

Table 6　Performance comparison relative to standard A* algorithm (group 2)

算法	与标准A*算法对应指标的比值/%			
	路径点数量	路径总长度	路径总风险	路径综合代价
RRT*	165.22	123.85	138.93	127.58
RiskA*[13]	149.57	138.77	**27.69**	113.58
RC-A*	**114.78**	**106.57**	42.02	**94.87**

注: 表中数据为各算法指标与标准A*算法对应指标的比值, 标准A*算法对应值为100%。

价上本文 RC-A*算法性能更为优越。

4　结　论

1) 本文考虑了无人机在城市空域飞行时带来的安全风险影响, 建立了可以同时评价无人机路径效率和安全性的路径综合代价模型。

2) 设计了基于综合代价的启发式函数, 提出预期路径代价估计的动态调整策略, 能够根据算法搜索状态调整风险代价计算范围, 具备有效引导无人机规避城市环境中高风险区域的能力。

3) 提出基于风险约束的 RC-A*路径规划算法, 以城市真实区域和数据作为仿真场景, 设计了仿真实验。相比于标准 A*算法, 本文算法在 2 组实验中生成路径的总风险分别减少了 67.34% 和 57.98%。

4) 影响本文算法性能的主要参数是风险权重系数和归一化处理时使用的归一化风险值。

为使本文 RC-A*算法能处理多场景的无人机三维安全路径规划问题, 未来需要对算法的关键参数设置做进一步研究。

参考文献（References）

[1] Kille T, Bates P R, Lee S Y. Unmanned aerial vehicles in civilian logistics and supply chain management[M]. Hershey: IGI Global, 2019: 33-63.

[2] 范芮滔, 刘昊, 程明, 等. 博弈环境下的多无人机系统协同路径规划[J]. 北京航空航天大学学报, 2026, 52(2): 620-626.
Fan R T, Liu H, Cheng M, et al. Cooperative path planning for multiple unmanned aerial vehicles system in a game-theoretic environment[J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(2): 620-626(in Chinese).

[3] FAA. Urban air mobility (UAM) concept of operations (v2.0) [EB/OL]. (2023-04-26)[2024-11-20]. https://www.faa.gov/sites/faa.gov/files/Urban%20Air%20Mobility%20%28UAM%29%20Concept%20of%20Operations%202.0_1.pdf.

[4] Garrow L A, German B J, Leonard C E. Urban air mobility: a comprehensive review and comparative analysis with autonomous and electric ground transportation for informing future research[J]. Transportation Research Part C: Emerging Technologies, 2021, 132: 103377.

[5] 朱元军, 李妍, 高子昂, 等. 可接受风险水平下城市空域无人机路径规划方法研究综述[J]. 西华大学学报 (自然科学版), 2022, 41(1): 7-12.
Zhu Y J, Li Y, Gao Z A, et al. A review of UAS route planning in urban airspace with acceptable risk levels[J]. Journal of Xihua University (Natural Science Edition), 2022, 41(1): 7-12(in Chinese).

[6] Albert A, Leira F S, Imsland L. UAV path planning using MILP with experiments[J]. Modeling, Identification and Control: A Norwegian Research Bulletin, 2017, 38(1): 21-32.

[7] Li M, Sun Q P, Zhu M M. UAV 3-dimension flight path planning based on improved rapidly-exploring random tree[C]//Proceedings of the Chinese Control and Decision Conference. Piscataway: IEEE Press, 2019: 921-925.

[8] Ye M, Zhao J C, Guan Q L, et al. Research on eVTOL air route network planning based on improved A* algorithm[J]. Sustainability, 2024, 16(2): 561.

[9] Wu Y M, Li Z, Sun C X, et al. Measurement and control of system resilience recovery by path planning based on improved genetic algorithm[J]. Measurement and Control, 2021, 54(7-8): 1157-1173.

[10] Shao S K, Peng Y, He C L, et al. Efficient path planning for UAV formation via comprehensively improved particle swarm optimization[J]. ISA Transactions, 2020, 97: 415-430.

[11] Li Y, Zhang X J, Zhu Y J, et al. A UAV path planning method in three-dimensional urban airspace based on safe reinforcement learning[C]//Proceedings of the IEEE/AIAA 42nd Digital Avionics Systems Conference. Piscataway: IEEE Press, 2023: 1-7.

[12] 胡莘婷, 吴宇. 面向城市飞行安全的无人机离散型多路径规划方法[J]. 航空学报, 2021, 42(6): 452-463.
Hu X T, Wu Y. Risk-based discrete multi-path planning method for UAVs in urban environments[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(6): 452-463(in Chinese).

[13] Primatesta S, Guglieri G, Rizzo A. A risk-aware path planning strategy for UAVs in urban environments[J]. Journal of Intelligent & Robotic Systems, 2019, 95(2): 629-643.

[14] 张洪海, 张连东, 刘皞, 等. 城市低空物流无人机航迹规划模型研究[J]. 交通运输系统工程与信息, 2022, 22(1): 256-264.
Zhang H H, Zhang L D, Liu H, et al. Track planning model for logistics unmanned aerial vehicle in urban low-altitude airspace[J]. Journal of Transportation Systems Engineering and Information Technology, 2022, 22(1): 256-264(in Chinese).

[15] 王飞, 杨清平. 面向多无人机物流配送的双层任务规划方法[J]. 北京航空航天大学学报, 2026, 52(1): 94-103.
Wang F, Yang Q P. Two-layer task planning method for multi-UAV logistics distribution[J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(1): 94-103(in Chinese).

[16] Pang B Z, Hu X T, Dai W, et al. UAV path optimization with an integrated cost assessment model considering third-party risks in metropolitan environments[J]. Reliability Engineering & System Safety, 2022, 222: 108399.

[17] Pang B Z, Low K H, Lv C. Adaptive conflict resolution for multi-UAV 4D routes optimization using stochastic fractal search algorithm[J]. Transportation Research Part C: Emerging Technologies, 2022, 139: 103666.

[18] JARUS. Specific operations risk assessment (SORA) main-

body[EB/OL]. (2024-05-13)[2024-11-20]. http://jarus-rpas.org/wp-content/uploads/2024/06/SORA-v2.5-Main-Body-Release-JAR_doc_25.pdf.

[19] JARUS. Specific operations risk assessment (SORA) Annex-B [EB/OL]. (2024-05-13)[2024-11-20]. http://jarus-rpas.org/wp-content/uploads/2024/06/SORA-v2.5-Annex-B-Release.JAR_doc_27.pdf.

[20] Zhu Y J, Zhang X J, Li Y, et al. Grid matrix-based ground risk map generation for unmanned aerial vehicles in urban environments[J]. Drones, 2024, 8(11): 678.

Risk-constrained safe path planning for unmanned aerial vehicles in urban airspace

ZHU Yuanjun[1, 2], LI Yan[1, 2], ZHANG Xuejun[1, 2, *], ZHANG Weidong[2, 3]

(1. School of Electronic & Information Engineering, Beihang University, Beijing 100191, China;
2. State Key Laboratory of CNS/ATM, Beihang University, Beijing 100191, China;
3. School of Cyber Science and Technology, Beihang University, Beijing 100191, China)

Abstract: This study addressed the safe path planning problem for unmanned aerial vehicles (UAVs) in urban airspace to support the development of the low-altitude economy. A grid-based modeling approach is used to represent the discrete three-dimensional space. A three-dimensional safe path planning model is created to reduce the total path cost, taking into account elements like UAV efficiency, operational risk limitations, and the configuration of urban airspace. The risk-constrained A* (RC-A*) algorithm is proposed to solve this problem. The suggested method integrates a model for assessing operational risks that takes into account the UAV's performance metrics, the density of ground workers, and strategies for risk mitigation. It includes a cost function that integrates distance costs and risk costs, a risk-based heuristic function, and a turning angle constraint to enhance search efficiency. Simulation trials grounded in a real-world context illustrate that the proposed algorithm is capable of devising secure trajectories for UAVs within urban three-dimensional environments. In the two groups of experiments, the operations risk values of paths are reduced by 67.34% and 57.98% compared to the standard A* algorithm.

Keywords: urban transportation; unmanned aerial vehicles; path planning; risk assessment; risk constraint

Received: 2024-11-27; **Accepted**: 2025-02-14; **Published Online**: 2025-03-27 15:57

URL: link.cnki.net/urlid/11.2625.V.20250327.1510.001

Foundation item: Anhui Province Science and Technology Innovation Project (202423h08050007)

* **Corresponding author**. E-mail: zhxj@buaa.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0853

基于YOLOv11的舰船关键部位检测算法

王瑶，曹司磊*，刘明刚，王颖颖
(海军航空大学，烟台 264001)

摘 要：在当前及未来海上维权及海域监测活动中研究如何迅速准确获取舰船关键部位信息，有效判读海域实时情况，具有非常重要的实际意义。基于深度学习的目标检测算法能够区分多类型目标信息，但针对舰船关键部位检测算法的研究较少，且对多通道特征图间的关联性分析不足，对尺度不同的舰船关键部位目标的特征利用率较低，容易错失重要特征信息而使检测精度降低。对此，提出一种基于YOLOv11的舰船关键部位检测算法，提升对关键部位的精准高效检测水平。对当前舰船关键部位检测存在的重难点问题进行深入剖析，结合现有算法进行对比研究；根据实际问题提出舰船关键部位检测的YOLOv11目标检测算法的改进方案；构建可见光舰船关键部位数据集，通过设计对比实验及消融实验，充分证明了所提算法对舰船关键部位检测的精准性及时效性，能够为实现复杂海洋环境中对多类型舰船关键要害部位的精细区分、有效监测海上舰船信息提供可行技术支持和理论支撑。

关 键 词：舰船目标；关键部位；YOLOv11；注意力机制；特征融合
中图分类号：E919
文献标志码：A **文章编号**：1001-5965(2026)11-3969-13

随着科学技术发展和材料设备的革新，智能化、自主化、精确化已成为海上斗争形式发展的主流趋势。海洋环境复杂多变，多类型舰船密集分布，有效监测海域实时信息、掌握舰船动态是维护海洋安全的重要途径。当前对舰船目标的检测方式没有区分舰船的关键部位，如雷达、驾驶舱、天线、船首，而舰船姿态、关键部位位置严重影响监测设备对舰船目标的精准判读。且海上舰船目标种类繁多、形态各异，在复杂海洋环境中对多类型舰船关键部位的精细区分，要能够有效区分背景与舰船信息，要求有效应对舰船移动所产生的几何形变对检测带来的影响。传统的海上舰船检测算法大多需要人为设置特征，算法复杂程度高、实时性不强、鲁棒性低。随着计算机技术、人工智能技术等新兴技术的进步革新和在多领域的深入应用，基于深度学习的目标检测算法逐渐显现出特有优势，且已广泛应用于对舰船的检测识别工作中。在复杂场景中，使用基于深度学习的目标检测技术能够大幅提升精度及效率，使海上舰船目标检测识别算法迅速从传统算法向深度学习领域发展。

文献[1]通过聚合密集注意力特征法获得高分辨率特征图像，并通过密集连接和迭代融合方法增强模型泛化性，有效提升了网络对舰船目标的检测精度；文献[2]使用高帽及低帽变换的方法对输入图像进行处理，并使用阈值分割法和归并算法获取候选区域，基于深度学习的分类思想检测舰船目标，相比传统算法，网络检测目标的精度及速度提升显著；文献[3]通过在候选框中获取目标候选特征，改进了YOLO网络，提升了分辨率高的卫星图像中舰船目标的检测精度。文献[4]将坐标注意力

收稿日期：2024-12-03；**录用日期**：2025-07-17；**网络出版时间**：2025-09-04 15:16
网络出版地址：link.cnki.net/urlid/11.2625.V.20250904.1419.001
基金项目：青年面上专项基金(ZR2024QE034)
* **通信作者**. E-mail：caosileimail@163.com

引用格式：王瑶，曹司磊，刘明刚，等. 基于YOLOv11的舰船关键部位检测算法[J]. 北京航空航天大学学报，2026，52(11)：3969-3981. Wang Y，Cao S L，Liu M G，et al. Detection algorithm of ship key parts based on YOLOv11[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3969-3981 (in Chinese).

(coordinate attention, CA)机制引入YOLOx模型中,并在网络的IM-YOLO-S颈部结构中应用双向特征金字塔网络(bidirectional feature pyramid network, BiFPN)算法,提升了网络对小尺度舰船目标的检测性能;文献[5]基于合成孔径雷达(synthetic aperture radar, SAR)图像构建检测多尺度舰船目标的跨连接特征金字塔网络(cross connected feature pyramid network, CCFPN),对深层及浅层特征图进行融合,并使用通道拼接方式提升了特征图中的信息量,运用多路空洞卷积增强对浅层目标特征的提取能力,能准确检测复杂背景中的多尺度舰船目标;文献[6]在YOLOv3-tiny中应用了特征映射方法,使模型的预测层能更多提取关键目标特征,提升了小尺寸舰船分布密集区域的目标检测精度。

当前多种目标检测算法能够实现不同场景下的舰船目标检测任务,但对于未来日益复杂海战场环境及精准打击需求,仍存在以下几点不足:

1)将舰船目标看作整体进行检测识别,未对关键部位进行精准检测,没有充分利用细粒度特征,不能提供精准的舰船目标指引信息;

2)海上舰船目标种类多,形态各异,现有算法在对多通道特征图间的关联性分析薄弱,对不同尺度舰船目标的特征利用率不高,易丢失关键特征信息而降低检测精度;

3)反舰设备雷达/红外制导体制受自然环境及电磁干扰影响严重,在实现反舰设备精准目标选择方面存在一定技术瓶颈;使用红外/雷达图像进行舰船目标检测不仅易受到多种干扰还会丢失舰船类型、关键部位等重要信息。当前针对舰船目标的数据集较少,尤其是可见光图像数据集,对舰船关键部位的分类数据极为缺乏。

针对当前舰船目标检测算法的不足及图像采集过程中目标特性变化剧烈的问题,本文提出基于YOLOv11的可见光舰船图像关键部位检测算法。具体如下:①针对海上航行舰船目标尺寸由于运动造成几何变化而影响精准检测的问题,利用第4代可变形卷积(deformable convolutionsv4, DCN v 4)重构的新模块替换YOLOv11主干网络中C3k2原来的bottleneck块,无需增加太多模型的训练参数,能够更准确地估计移动舰船目标空间形变。②针对舰船关键部位属于小目标检测范畴、检测难度大的问题,利用可变核卷积(arbitrary kernel convolutional, AKConv)改进跨阶段部分网络模块(volumetric grid spatial cross stage partial network block, VoVGSCSP)结构,构建AKConv跨阶段部分网络模块(arbitrary kernel convolutional-volumetric grid spatial cross stage partial network block, AVB),再和BiFPN结合构建新型颈部网络Bi-AVB-FPN,以丰富多尺度特征融合,增强特征语义信息,帮助模型更准确地定位关键舰船部位的目标区域。③针对边缘设备资源普遍有限且检测算法适用性低的问题,在Neck部分引入了轻量级分组混洗卷积(grouped spatial convolution, GSConv)模块,以减少计算量和内存损失。通过改进不仅可以实现更高的检测精度,特别是在小尺度目标检测方面,还可以降低功耗和能耗。④针对SAR图像、红外图像获取易受复杂电磁环境及自然环境干扰影响的问题,自建可见光舰船关键部位数据集。

2024年提出的YOLOv11目标检测网络属于一阶目标检测网络,模型性能得到显著提升,相对其他基于深度学习的目标检测算法表现出精度及速度方面的突出优势,且可见光图像具有特征突出、信息多样、直观易读的特性,受温度、风力等自然环境及干扰影响较小,包含丰富的光谱信息,能够较好抵抗烟幕等遮挡干扰影响,有利于低空、超低空图像信息全面完整表达,研究基于YOLOv11的可见光舰船图像关键部位检测能够更好地适应复杂环境,准确检测识别多类型关键目标信息。本文通过自建可见光数据集训练并测试改进的要害部位检测网络性能,证明本文算法能够实现对海上舰船关键部位精准实时的检测,网络具有更高的准确性和实时性,对复杂海洋环境适应能力更强。

1 舰船关键部位检测算法

1.1 关键部位检测算法

目前常用的关键部位检测算法可分为自上而下(Top-Down)和端到端2种。

Top-Down算法先检测目标信息,再搜索目标内部关键部位信息,主流算法有CPN(corner proposal network)、Hourglass算法、CPM(convolutional pose machibes)算法、HRNet(high resolution network)算法等。

Top-Down算法主要处理步骤为:①通过基于深度学习的目标检测算法如快速区域卷积神经网络(fast region-based convolutional neural networks, Faster R-CNN)、YOLO等检测目标类别信息,并根据目标边界框位置进行裁剪并缩放至指定尺寸;②将第1步获得的区域输入经过特定训练的用于关键部位检测的网络,如HRNet、Stacked Hourglass Network、掩码区域卷积神经网络(mask region-based convolutional neural networks, Mask R-CNN)关键点分支等进行处理,生成热力图,每张热力图对应一

个关键部位中心点, 热力图中数值最高的位置表示最有可能是关键部位中心点的位置, 再通过对热力图解码获取中心点具体坐标值; ③对获取的坐标做非极大值抑制(non-maximum suppression, NMS)等后续处理, 降低冗余, 提升检测准确度, 也可能采取反向传播等矫正操作, 以调整关键部位中心点位置。

Top-Down 算法利用目标检测算法获取目标位置信息, 简化了关键要害部位检测的后续流程, 并针对多目标情况能够进行单独处理, 该处理方式能更加准确地获取关键部位中心点位置信息, Top-Down 算法流程如图 1 所示。但该算法计算复杂度较高, 训练时间长, 检测速度较慢, 不适合对实时性要求较高的场景; 且该算法非常依赖目标检测结果的准确性, 易产生较大误差。

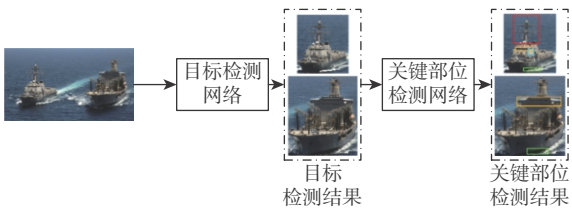


图 1　自上而下的关键部位检测算法

Fig. 1　Top-down key parts detection algorithm

端到端的算法利用一个统一网络框架对目标及关键部位进行检测, 并在图中用框展示出对应区域, 如图 2 所示。这类算法的网络结构较为简洁, 但求解过程中容易忽视目标和关键部位之间的联系, 在应对特征不显著情况及检测小目标问题中表现不佳。



图 2　端到端的关键部位检测算法

Fig. 2　End-to-end key location detection algorithm

1.2　舰船目标检测算法

舰船目标及要害部位检测算法可分为传统的基于人工设计特征的算法和基于深度学习的算法。传统的海上舰船目标检测算法众多, 使用较为广泛的有针对 SAR 图像的恒虚警率法[7]、基于自适应 Canny 算子对舰船红外图像进行边缘检测的算法[8]、对普通光学舰船目标利用小波变化进行检测的算法等。传统的海上舰船目标检测算法图像获取难度大, 大多需要人为设定目标特征, 工作量大, 设置特征也较为困难, 且受多种干扰因素影响, 检测精度不高。

2006 年, Hinton 等在《科学》杂志提出“多隐层神经网络”使卷积神经网络(convolutional neural network, CNN)崛起[9]。深度学习诞生后, 以其优越特性使目标检测技术由传统的机器学习迅速向基于深度学习的方式转变, 并广泛应用于军事目标侦查监控、智能安防系统、舰船目标检测[10]等领域。在检测海上舰船目标方面, 相比传统算法, 深度 CNN 有效利用大量数据, 通过成熟训练, 能够自动提取目标信息, 得到泛化性高的目标特征, 能够较好地应对形状变化、背景、光照、遮挡等影响, 鲁棒性强。基于深度学习的目标检测算法分为一阶目标检测算法和二阶目标检测算法。二阶目标检测算法将目标检测问题划分为 2 个步骤: ①针对输入图像生成候选区; ②对候选区作分类及位置回归。代表算法有 R-CNN、Fast R-CNN、Faster R-CNN 等。一阶目标检测算法把检测流程简化为端至端的回归, 无需候选区, 仅在卷积网络中完成目标特征提取、分类和回归工作, 极大提升了网络检测速度, 更适用于实时应用场景。典型算法有单次多框检测器(single shot multibox detetor, SSD)、YOLO 等。

1.3　研究难点问题

目前, 关键部位检测算法在实现对舰船关键部位的精准检测方面普遍存在以下几点问题:

1) 处理关键部位可变形能力不足。海上舰船分布密集, 舰船目标类型众多, 不同类型舰船的关键部位数量及分布存在差异, 且在舰船目标运动过程中, 受位移、姿态变换影响及图像采集设备性能、运动等因素干扰, 获取到的图像信息中关键部位易出现几何变化, 现有的检测算法对该种差异难以作出灵活调整。

2) 模型复杂度与效率的平衡关系难以协调。在网络提升目标检测精度的同时, 往往伴随着模型复杂度和计算量的增加, 难以适用于实时监测环境。

3) 对遮挡重叠目标及小目标的检测精度不高。对于目标存在遮挡、重叠情况及小目标检测方面性能不足, 网络敏感度不高。舰船的关键部位属于小目标物体, 只占舰船整体的较小部分, 尤其在存在遮挡重叠情况下, 网络能够获取的特征信息有限, 且不同要害部位之间也会对检测结果产生干扰。在复杂海洋环境中, 背景信息与目标信息的分布会存在不平衡性, 这些都对舰船关键部位定位产生干扰。

4) 深浅层特征信息融合欠佳。CNN 通过下采样和池化操作提取深浅层特征信息, 浅层特征包含丰富的目标位置及细节信息而缺少高层语义信息, 深层特征包含更多抽象信息和整体信息, 是检测关键部位特征的关键。现有算法对深浅层特征信息融合欠佳, 需要更好地融合不同层的特征信息, 以

提升网络检测效果。

针对当前算法适用场景、存在问题及提升对舰船关键部位精准检测的需要，本文以最新的YOLOv11目标检测算法为基础，提出针对复杂海洋环境中舰船关键部位检测算法，提升网络检测性能。

2 本文改进方案

为实现对舰船目标关键部位检测，结合海域监控实时性需求，选用YOLOv11算法进行改进。YOLOv11算法通过大幅减少参数极大提升了网络效率及运行速度，对比YOLOv10算法减少了2%的推理时间，成为实时任务场景的最佳选择。在COCO数据集中，YOLOv11算法具有更高的平均精度均值(mean average precision, mAP)，对比YOLOv8算法的参数量减少22%，网络更为轻量，且很好地平衡了速度与精度的关系，YOLOv11算法的总体设计使其具备捕捉复杂图像信息的优势，在困难环境(光线不足或场景杂乱)中的目标检测能力更强。YOLOv11网络能够在手机、云服务器或物联网设备等边缘设备高效部署运行，具有极强的灵活性，能够适用不同任务场景及工作环境。

针对复杂环境中动态舰船目标关键要害部位检测的重难点问题，为进一步提升检测的准确性、高效性及对复杂环境的适应能力，对YOLOv11算法作出如下改进。

2.1 C3k2_DCNv4结构

在多类型关键要害部位目标的舰船检测中，检测目标大多是由不同角度拍摄成像的非规则的形状，而普通卷积的卷积核通常是规整的方形结构，难以精准覆盖目标区域。为进一步提升对多尺度形态舰船要害部位检测精度，引用DCNv4[11]。使用DCNv4卷积重构的新模块替换YOLOv11主干网络中C3k2原来的Bottleneck块，以更准确地估计动态舰船目标的空间形变，提升网络对由于运动造成的舰船关键部位几何变化的适应能力。

YOLOv11中应用Bottleneck模块[12]由1×1及3×3的卷积层组成，完成对输入数据的特征提取和降维操作，模块结构如图3所示。

Bottleneck结构使用1×1卷积层降低了特征图维度，但卷积层数量增加，经过多个卷积层和变换维度操作，有可能会出现总体计算量增加的情况，特别在资源受限的任务场景中会提升训练和部署模型的难度；Bottleneck结构使用1×1卷积层执行降维、升维操作，在反向传播时，梯度信息通过这些卷积层会产生较多损失，影响训练模型的效果。

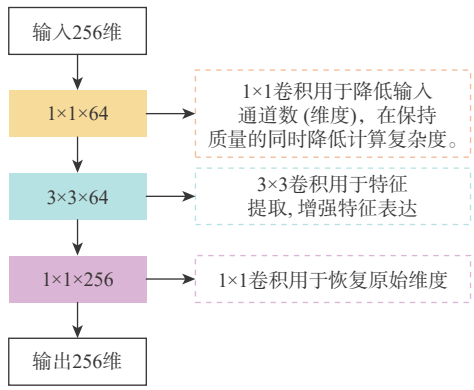


图3 Bottleneck模块

Fig. 3 Bottleneck module

2024年提出的DCNv4是一种高效动态稀疏操作算子，在提取特征图时，与前期版本(如DCNv3、DCNv2、DCN)相比，提供了更广泛的特征级采样。DCNv4集成了一种调制机制，该机制不仅可以学习样本的偏移量，还可以对学习到的特征幅度进行调制，这使DCNv4能够控制其样本空间和相对影响[13]。

DCNv4能够显著提升网络收敛及处理速度，在图像分类、语义和实例分割、图像生成等任务中性能优势显著。DCNv4主要优势有：①摒弃空间聚合中的softmax归一化，DCNv4使用动态自适应窗口，能够根据输入特征计算权重，取消权重归一化的限制，增强了表达能力及动态特性；②改进内存访问，使用共享的聚合权重和采样偏移，使单线程能同步处理同组中的多个通道，避免了非必要的读取内存和运算等操作，加快了网络收敛及处理速度；③DCNv4引入向量化加载，能够一次读取多个通道数据，降低访问内存的指令数，进一步提高了访问内存的效率。

由图4可知，注意力机制与DCNv3通过有限的动态权值(0,1)聚合空间特征；注意力机制的采样点集即窗口是相同的，而DCNv3针对每个位置应用专用窗口。卷积的聚合权值无界(−∞,+∞)，范围更加灵活，对每个位置应用专业滑动窗口，但窗口形状及聚合权值与输入无关。DCNv4结合了卷积与DCNv3的优点，使用自适应的聚合窗口和无界值范围的动态聚合权值。DCNv4中通过一个线程处理同一组内的多个通道，这些通道共享聚合权重和采样偏移量，该方式能够减少读取内存及计算双线性插值系数等工作，且能够合并多个内存访问指令。图4中使用星形符号表示查询像素；使用离散小方框标识参与聚合计算的响应像素采样位置，每个响应像素会分配对应的有界及无限聚合权重，权值大小通过不同颜色表示。

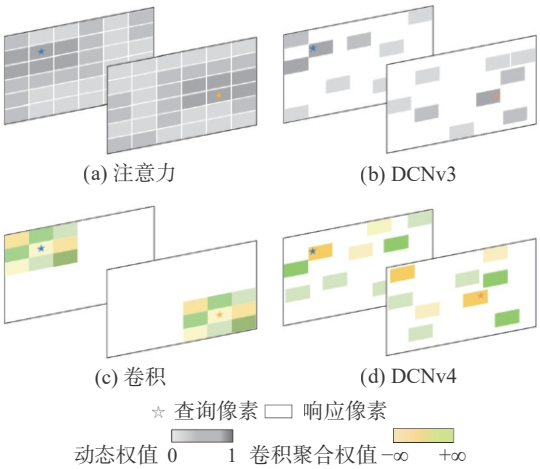


图 4　网络性能对比

Fig. 4　Comparison of network performance

如表 1 所示, 配备了 DCNv4 的 FlashInternImage Backbone 在提升速率的同时, 最终性能也优于原始版本 InterImage Backbone。

表 1 中, AP(S)、AP(M)、AP(L) 分别表示不同尺寸包围框对应的检测精度。

通过引入 DCNv4 改进 YOLOv11 模型的主干网络, 可以自适应地改变卷积核的形状, 尽可能地覆盖舰船关键区域, 从而获得更丰富的特征信息, 实现更精准的舰船关键部位的特征提取。

2.2　多尺度特征金字塔网络

对舰船键关键部位属于小尺寸目标, 检测难度大的问题, 需要增强模型的颈部网络以丰富特征信息的融合, 更有助于定位舰船关键部位的目标区域。因此, 本实验将 AKConv 引入 VoVGSCSP 模块中, 用 AKConv 作为双分支卷积 Concat 操作后得到新型卷积, 替换普通卷积 Conv, 构建新的模块 AVB, 将颈部网络的前两层 C3k2 模块替换, 以进一步提升模型精度。

表 1　DCNv4 性能对比[13]

Table 1　Performance comparison of DCNv4[13]

模型	参数量	帧率/(帧·s^{-1})		AP/%	AP(S)/%	AP(M)/%	AP(L)/%
		FP32	FP16				
Swin-T	48.2×10^6	37	50	51.1	34.3	53.9	66.1
ConvNext-T	48.5×10^6	39	54	51.0	33.5	53.9	65.8
InternImage-T	48.7×10^6	33	37	53.9	37.7	57.7	68.7
FlashInterImage-T	48.5×10^6	39	48	57.7	37.9	58.6	69.8

2.2.1　BiFPN

BiFPN[14] 为特征金字塔网络(feature pyramid network, FPN)的拓展, 在金字塔层级内增加双向互联, 使网络中的信息能同时从上至下和从下至上传输, 网络结构对比如图 5 所示, P_n 表示金字塔特征层下采样倍率。

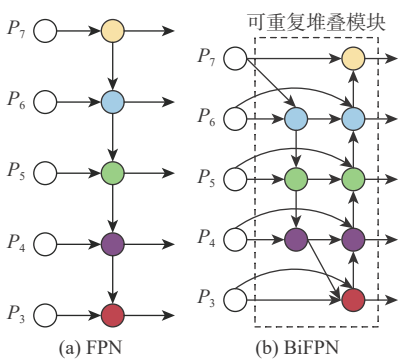


图 5　网络结构对比

Fig. 5　Structure comparison of network

BiFPN 网络以 ResNet 等 CNN 为骨干网络, 从其中多层提取目标特征组成特征金字塔, 在金字塔每层级间应用双向连接, 加强了低层高层间特征流通, 同时双向连接能从上下方向整合金字塔中各层信息以有效获取多尺度特征信息。BiFPN 还应用了特征加权融合方式, 融合不同层间特征, 能在训练中得到权重, 以保证最优的整合特征。

海上舰船目标广泛分布, 类型多样, 获取图像中包含多种尺寸、不同形态的舰船目标, BiFPN 的作用模式能更好获取多尺度的特征表达, 有效增强了网络处理不同复杂度和尺寸目标的能力, 对目标大小存在显著差异的场景十分重要。

2.2.2　AKConv

AKConv[15] 可改变核卷积通过不规则卷积核函数提取特征, 能够为多种变化的目标提供拥有任意采样尺寸和形状的卷积核, 填补了传统卷积的不足。在 COCO2017 及 VisDrone-DET2021 数据集上进行目标检测实验及对比实验, AKConv 显现出更优秀的性能, 具体如下。

1) 样本形状灵活。对比常规卷积固定的样本形状, AKConv 允许卷积有不同大小和形状, 能够灵活适应形变目标, 极大提升了网络的检测准确度。

2) 参数量及运算效率。AKConv 通过改变卷积尺寸能够降低参数量及运算量, 从而提升模型运

算效率及性能。

3）优化网络性能。作为轻量级的模型，AKConv 能够代替常规卷积以降低模型的参数量及计算开销，且能够保持模型性能，同时提升网络泛化能力及效率。

4）可扩展性。AKConv 能够扩展为更大尺寸的内核，为改进网络性能提供更多选项，能够适应多种场景需求，具备广泛的适用性。

图 6 为尺寸为 5 的卷积初始样本，AKConv 能够设计不同的初始采样形状实现任意形状的采样。

卷积核内采样点数量不同的 AKConv 在 COCO-2017、VOC 7+12 及 Vis-Drone-DET2021 数据集中的表现如表 2 所示，mAP 为平均精度，mAP50 表示交并比为 0.5 时的 mAP。结果充分体现了 AKConv 的优势。

AKConv 结构如图 7 所示，其中，C 为通道数，H 为特征图高度，W 为特征图宽度，$2N$ 为二维采样点总数。

受舰船目标航行及图像获取设备运动影响，会造成获取目标的几何变化而影响网络检测效果，通过引入 AKConv，为动态舰船目标检测提供多种尺寸和形状的卷积核，提升对动态变化场景的适应能力，增强检测准确性。

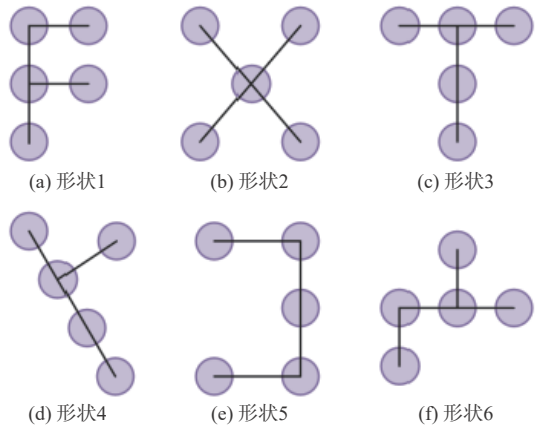


图 6 采样形状

Fig. 6 Sample shape

2.2.3 VoVGSCSP 模块

经过卷积操作获取的图像低层信息包含目标更丰富的细节特征，而高层信息则含有更多的语义信息及空间特征，将不同层级信息有效融合，实现跨层连接互通，能够进一步提升对海上多类型动态舰船目标的检测精度。

VoVGSCSP 模块[16]将输入特征映射至体素化网络中来获取更多空间中的局部特征信息，并引用跨阶段局部网络（cross stage partial network,

表 2 引入不同数量 AKConv 的网络性能对比[15]

Table 2 Performance comparison of networks with different numbers of AKConv introduced[15]

模型	AKConv卷积数量	精确率/%	召回率/%	mAP50/%	mAP/%	浮点运算量/次	参数量
基线模型		77.3	69.8	76.4	50.2	13.2×10^9	6.06×10^6
YOLOv7-tiny	3	80.1	68.4	76.1	50.3	12.4×10^9	5.56×10^6
	4	78.2	70.3	76.2	50.7	12.4×10^9	5.66×10^6
	5	77.0	71.1	76.5	50.8	12.6×10^9	5.75×10^6
	6	79.6	69.9	76.9	51.0	12.9×10^9	5.85×10^6
	8	78.6	70.1	76.7	51.2	13.4×10^9	6.04×10^6
	9	81.0	69.3	76.7	51.3	13.7×10^9	6.14×10^6

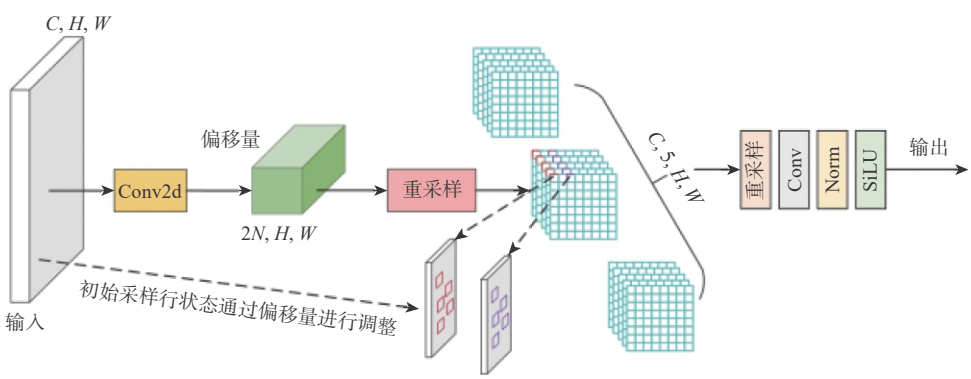


图 7 AKConv 结构

Fig. 7 Structure of AKConv

CSPNet)思想, 利用跨阶段局部连接的方法融合和分离特征以维持特征表达的丰富性并降低计算冗余, 提高网络效率。VoVGSCSP 能高效融合多个不同层次的特征信息, 提高特征表达能力, 更好地平衡模型网络性能及运算效率间的平衡, 更适用于实时场景。模块结构如图 8 所示。

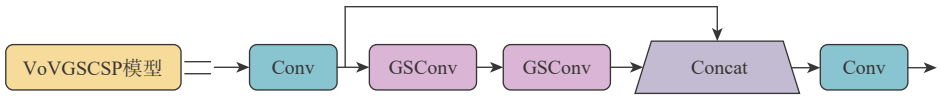


图 8　VoVGSCSP 结构

Fig. 8　Structure of VoVGSCSP

使用 AKConv 替换 VoVGSCSP 模块的普通卷积, 构建新的模块 AVB 模块, 并使用 AVB 模块替换颈部网络的前 2 层 C3k2 模块, 能够在提升对动态多类型舰船目标检测精度的同时, 维持较好的运算速率, 符合实时性及精准检测需求。

2.3　GSConv 结构

针对边缘设备资源普遍有限且检测算法适用性低的问题, 在 Neck 部分引入了轻量级 GSConv 模块[17]。该模块采用了分组卷积和空间卷积相结合的优化策略, 以减少计算量和内存损失。

为加快 CNN 的运算过程, 输入 CNN 的图像基本都要在骨干网络中进行此类转换: 空间信息向通道逐步传递。但每次对特征图作空间(宽度、高度)压缩及通道扩展时都会产生部分语义信息的丢失。通道密集卷积(channel dense convolution, SC)能够最大程度保留每个通道的隐藏连接, 而通道稀疏卷积(channel sparse convolution, DSC)彻底断开了这些连接。GSConv 则以更低的时间复杂度, 最大可能地保存这些连接。卷积计算的时间复杂度由浮点运算量定义。SC、DSC、GSConv 在不考虑偏置情况下的时间复杂度 T 为

$$T_{\mathrm{SC}} \sim O(W \times H \times K_1 \times K_2 \times C_1 \times C_2) \tag{1}$$

$$T_{\mathrm{DSC}} \sim O(W \times H \times K_1 \times K_2 \times 1 \times C_2) \tag{2}$$

$$T_{\mathrm{GSConv}} \sim O\left(W \times H \times K_1 \times K_2 \times \frac{C_2}{2} \times (C_1 + 1)\right) \tag{3}$$

式中: W 和 H 分别为输出特征图宽度和高度; K_1、K_2 为卷积核大小; C_1、C_2 分别为输入及输出特征图的通道数。

在 PASCAL VOC 2007+12 数据集中对比 SC、DSC、ShuffleNet、GhostNet 及 GSConv 卷积模块对模型性能的作用意义如表 3 所示, 加粗显示最优结果。

表 3　卷积模块对比[17]

Table 3　Comparison of convolution modules[17]

卷积模块	mAP50/%	mAP95/%	浮点运算量/次
SC	58.9	35.8	4.2×10^9
DSC	56.9	34.6	$\mathbf{3.3\times10^9}$
ShuffleNet	56.5	34.1	$\mathbf{3.3\times10^9}$
GhostNet	59.3	37.0	3.8×10^9
GSConv	**59.8**	**38.1**	3.7×10^9

GSConv 还可以根据实际硬件性能动态分配计算资源, 以平衡计算成本和检测性能, 不仅可以实现更高的检测精度, 而且可以降低功耗和能耗。特别是在小尺寸特征图方面, GSConv 卷积产生的计算负担比标准卷积低, 这在一定程度上提高了对小目标的检测精度。

GSConv 结构如图 9 所示。结合本节改进措施, 对 YOLOv11 网络结构进行改进, 网络总体结构模型如图 10 所示。

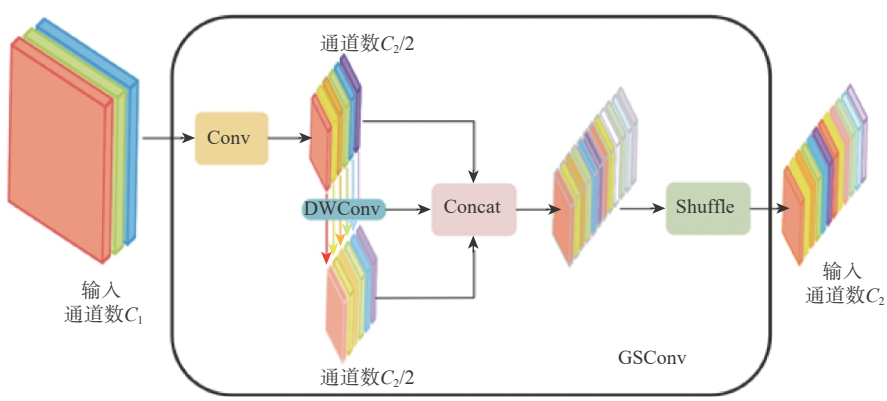


图 9　GSConv 结构

Fig. 9　Structure of GSConv

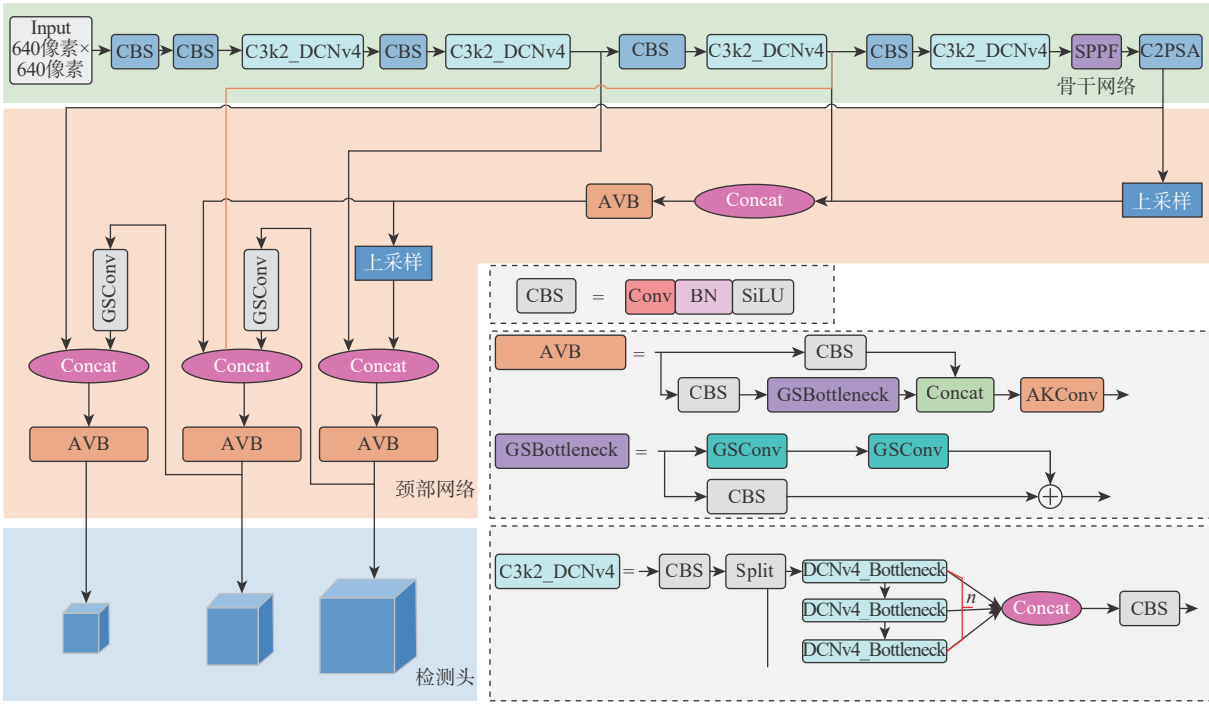


图 10 本文改进的 YOLOv11 网络结构

Fig. 10 Network structure of the improved YOLOv11

3 数据集构建

3.1 数据集组成

目前针对舰船目标的数据集多为 SAR 图像和红外图像，且主要针对舰船主体，尚没有公开的针对舰船关键部位可见光数据集。为贴合实际海洋环境及图像采集设备低空、超低空飞行视角，探索利用本文算法实现对舰船及其关键部位的精准检测识别，通过网络收集、已有数据集节选、实景拍摄等方式选取包含可见光舰船正视及侧视图像，数据集中包含多种类型舰船，存在遮挡、小目标场景，共 5 589 张图像。将舰船关键部位分为驾驶舱、天线桅杆、雷达、水线及卫通。包含关键部位图像数量如表 4 所示。

表 4 数据集结构

Table 4 Structure of dataset

要害部位	数量/张
驾驶舱	6 945
天线桅杆	7 197
雷达	3 237
水线	8 158
卫通	4 137

数据集中部分图像如图 11 所示。数据集采用 PASCAL VOC 格式，使用 labelImg 工具标注。在标注重要目标时，由于检测框是矩形的，难免会框选到无关信息，尤其是标注水线检测框时，过于狭长的结构会增加检测难度。因此，在框选水线时，特



图 11 数据集部分图像

Fig. 11 Dataset partial images

别注意框定接近水平且受环境噪声干扰较弱的位置，在减少标注框过于狭长问题的同时，避免了大面积框选舰船主体信息；对于驾驶舱、天线桅杆、船首等关键部位以目标边缘为基准来标注。

图像标注如图 12 所示。图像格式为.jpg，为加速网络训练过程，将图像像素大小统一为 640 像素×640 像素，命名为 000001 格式，并对图像进行标注。将数据集中 80% 图像划分为训练集，20% 划分为测试集。

3.2 实验条件及评价指标

3.2.1 实验条件

实验在 Ubuntu18.04 操作系统中完成，使用 Pytorch 1.10 深度学习框架，cuda11.1+cudnn8.0.4+opencv4.5.8 环境；硬件环境为：Intel(R) Xeon(R) Platinum i9-13900k, Nvidia GeForce RTX 4 090；使用 python 语言实现编程操作。

输入图像像素大小为 640 像素×640 像素，初始学习率为 0.01，采用随机梯度下降更新学习率，



图 12　数据集标注

Fig. 12　Dataset annotation

动量为 0.937, 权重延迟为 0.000 5。在训练过程中使用 Mosaic 数据增强的方式, 每次读取 4 张图像, 分别进行翻转、缩放等操作后拼接, 使检测背景更加丰富。设置标签平滑为 0.01, 防止模型过拟合, 增加模型的泛化性。所有的模型皆训练 500 个 epoch, batchsize 设置为 32, worker 线程数 16。

3.2.2　评价指标

TP(true positive): 准确判定为正样本的样本, 记为 T_P; TN(true negatives): 准确判定为负样本的样本, 记为 T_N; FP(false positive): 负样本判定为正样本, 记为 F_P; FN(false negative): 正样本被判定为负样本, 记为 F_N; Q 为查询的总次数。

1) 准确率 P 为全部被检测是正的样本真正属于该类的比, 表达式为

$$P=\frac{T_P}{T_P+F_P} \tag{4}$$

2) 召回率 R 为目标被检测为正类的数量占所有被检测为目标类总数的比例, 表达式为

$$R=\frac{T_P}{T_P+F_N} \tag{5}$$

3) A_P 为准确率-召回率曲线(PR 曲线)与横轴之间的图形面积, 曲线横轴为 R 值, 表示分类器涵盖正样本的能力, 纵轴为 P 值, 表示对正类的预测精度, PR 曲线表示了两值间的变化情况, 分为连续的 PR 曲线和离散的 PR 曲线 2 种, 表达式为

$$A_P=\begin{cases}\int_0^1 PR\mathrm{d}r\\ \sum_{k=1}^{n}P(k)\Delta r(k)\end{cases} \tag{6}$$

式中: $P(k)$为第 k 个采样点对应的精确率; $\Delta r(k)$为相邻 2 个采样点之间召回率的变化量。

4) mAP 为所有查询结果排序的 AP 的平均值, 即预测正确的部分占预测结果的比例。表达式为

$$m_{AP}=\sum_{q=1}^{Q}A_P(q)/Q \tag{7}$$

5) 检测时间, 单位 ms。数值越小则检测单张图像时间越短, 算法速度越快。

3.3　实验结果分析

使用本文自建可见光舰船要害部位数据集训练优化的基于 YOLOv11 的舰船要害部位检测算法, 训练集与测试集比例为 8:2。训练过程中使用马赛克数据增强方式, 在网络收敛后, 得到成熟的网络模型。

本文算法损失函数曲线如图 13 所示, loss 函数为无量纲指标, 数值大小表征模型预测结果与真实标签的偏差程度。可以得出, 网络经过充分的迭代训练, 损失值平缓下降, 最终趋于稳定至收敛, 最后收敛的损失函数值较小, 没有过拟合、欠拟合问题; 在损失函数下降过程中, 没有出现大幅度的波动情况, 证明本文算法网络模型设计合理, 规模深度及数据集构建完善, 使网络得到充分训练和平稳收敛。

本文算法 PR 曲线如图 14 所示。不同类型目标检测精度如表 5 所示。

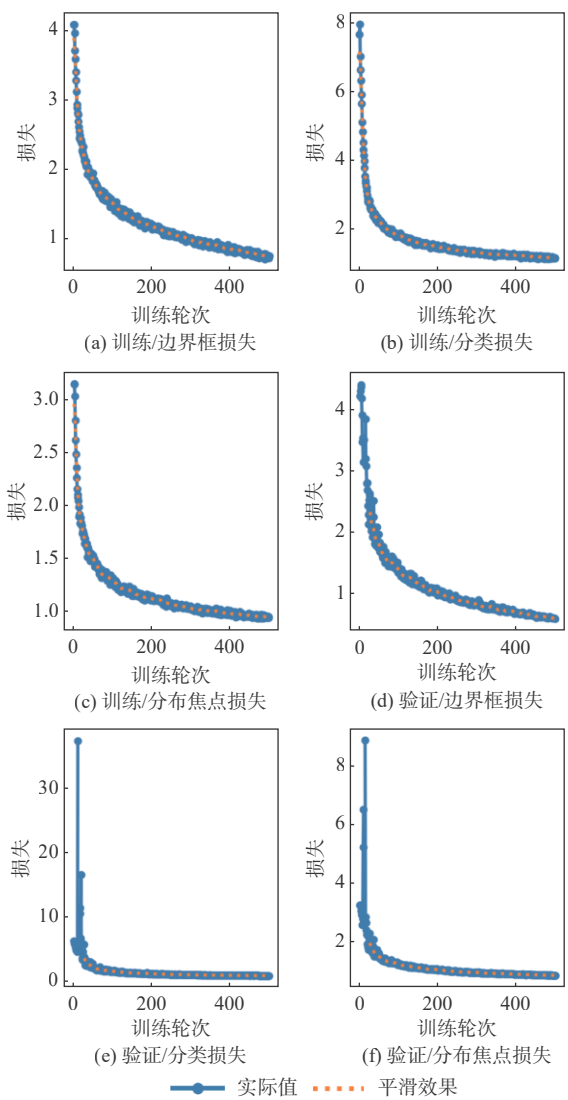


图 13　本文算法损失函数曲线

Fig. 13　Proposed algorithm loss function curves

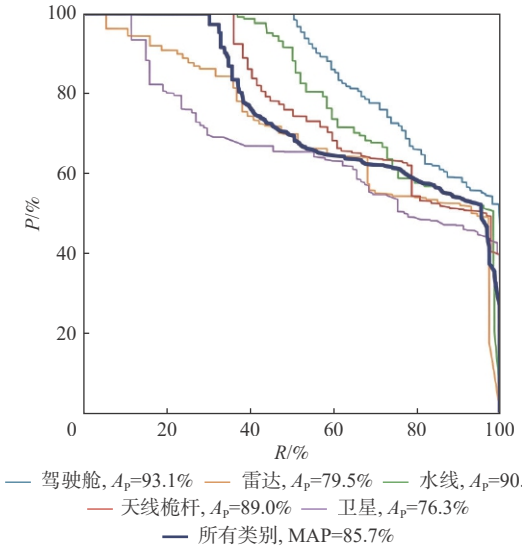


图 14 本文算法 *PR* 曲线

Fig. 14 Proposed algorithm *PR* curves

表 5 要害部位检测精度

Table 5 Detection accuracy of critical parts

类型	AP/%
驾驶舱	93.1
雷达	79.5
水线	90.5
天线桅杆	89.0
卫通	76.3

由各类要害部位检测结果统计知，基于 YOLOv11 改进的本文要害部位检测算法对多类型舰船要害部位检测精度达到 85.7%，检测精度高，检测时间为 1.1 ms，能够满足作战实时性要求。驾驶舱检测精度达到 93.1%，检测精度最高，主要由于驾驶舱特征较为突出且相对其他部位像素占比大，易于提取特征；水线检测精度达到 90.5%，在标注水线时，减小了矩形包围框大小，尽量只框选水线部分而减少背景因素的选取，提升了网络训练的鲁棒性，对水线的检测准确度高。本文算法网络对雷达、卫通的检测精度分别为 79.0% 和 76.3%，体现了该网络能够较为准确地获取像素占比较少的关键部位信息。本文算法网络的检测效果如图 15 所示，目标关键部位使用不同颜色框选展示。

由图 15 知，本文算法能够有效检测出图像中舰船目标的关键要害部位，对于多角度舰船目标均表现出较好的检测性能，检测精准度高，标注框位置准确，对像素占比较小的关键要害部位仍能做到有效检测提取目标信息；特别是在面对恶劣海况、舰船关键部位受到遮挡干扰的情况下，仍能准确检测得到关键部位信息，基本无漏检情况。

为进一步验证本文算法的性能优势，并应对在



图 15 本文算法检测效果

Fig. 15 The proposed algorithm detection effect

反舰设备实际作战环境中对要害部位检测精度、速度的要求及硬件设备容量的限制，在相同实验环境及参数设置下分别对 SSD 算法[18]、CenterNet-Hourglass 算法[19]、YOLOv8n 算法[20]、YOLOv10n 算法[21]、YOLOv11n 算法[22]进行训练，迭代次数为 500 epoch，输入图像分辨率不变，使用相同的训练方式，对网络性能进行测试，统计网络基本性能参数如表 6 所示，最优结果加粗显示。

本文提出的基于 YOLOv11 的关键部位检测算法检测精度为 85.7%，对比 SSD 算法、CenterNet-Hourglass 算法、YOLOv8n 算法、YOLOv10n 算法、YOLOv11n 算法分别提升 11.4%、8.1%、6.0%、7.6%、4.9%。本文算法检测精度有明显提升；检测单张图像时间为 1.1 ms，明显快于 SSD 算法、CenterNet-Hourglass 算法，对比 YOLO 系列算法中的 YOLOv10n 算法、YOLOv11n 算法也分别提升 0.4 ms、0.3 ms，网络实时性更强。且本文算法参数量对比其他算法最少，能更好适应硬件平台资源受限的应用场景。

不同算法的检测效果图如图 16 所示。可以看出，本文算法对 5 类关键要害部位的检测漏检率更低，基本能完整检测出图像中存在的要害部位，对比检测精度也明显高于其他对比算法。

3.4 消融实验

本文针对复杂海洋环境中运动舰船目标关键部位检测，对 YOLOv11 算法提出多个模块的改进，为验证每个模块作用价值，设计消融实验验证各改进方案对检测结果的影响。实验环境及实验参数设置与对比实验相同，对比算法性能如表 7 所示，其中，最优结果加粗显示。

由表 7 可知，未进行改进的 YOLOv11 算法检测精度为 80.8%，检测单幅图像的时间为 1.4 ms，应

表 6　关键部位检测对比实验

Table 6　Comparative experiment of key parts detection

算法	精确率/%	召回率/%	mAP50/%	参数量	时间/ms
SSD[18]	60.2	78.9	74.3	164 765 132	3.4
CenterNet-Hourglass[19]	61.9	80.1	77.6	95 432 146	3.3
YOLOv8n[20]	62.7	86.3	79.7	3 006 623	1.0
YOLOv10n[21]	64.2	80.5	78.1	2 696 366	1.5
YOLOv11n[22]	65.3	82.1	80.8	2 583 127	1.4
本文算法	**70.6**	**87.7**	**85.7**	**2 437 559**	**1.1**



(a) YOLOv8n[20]



(b) YOLOv10n[21]



(c) 本文算法

图 16　不同检测算法效果图

Fig. 16　Renderings of different detection algorithms

用 C3k2_DCNv4 结构后, 算法平均检测精度提升 3.1%, 检测时间减少 0.4 ms, 这是因为在 C3k2_DCNv4 结构中, 利用基于 DCNv4 重构的新模块替换了 YOLOv11 主干网络 C3k2 中原来的 Bottleneck 块, 能够提升网络对抗运动产生的几何形变干扰情况, 从而增强网络对运动舰船目标空间形变更精准的估计能力, 能有效提高网络适应海上船舶目标运动造成的几何变化的能力, 更准确地估计移动船舶目标空间形变, 且使用 DCNv4 能精简训练过程, 减少模型训练参数, 因此, 应用 C3k2_DCNv4 结构后, 网络的检测精度及检测效率均有显著提升。

应用 Bi-AVB-FPN 后, 算法检测精度进一步提升 1.3%, 检测时间降低 0.1 ms, Bi-AVB-FPN 网络能够有效增强模型的颈部网络, 丰富目标特征信息的融合, 从而提升网络对小目标的检测能力, 更有助于定位舰船关键要害部位的目标区域; Bi-AVB-FPN 网络中, 引用 CSPNet 思想, 利用跨阶段局部连接的方法融合和分离特征, 在维持特征表达的丰富性的同时有效降低了计算冗余, 减少了模型的参数量, 加快了检测速率。

最后在模型的 Neck 部分引入了轻量级 GSConv 模块, 以减少计算量和内存损失, 平衡计算成本和检测性能的关系, 算法参数量得到进一步降低, 同时检测精度提升了 0.5%, 检测时间为 1.1 ms, 增加

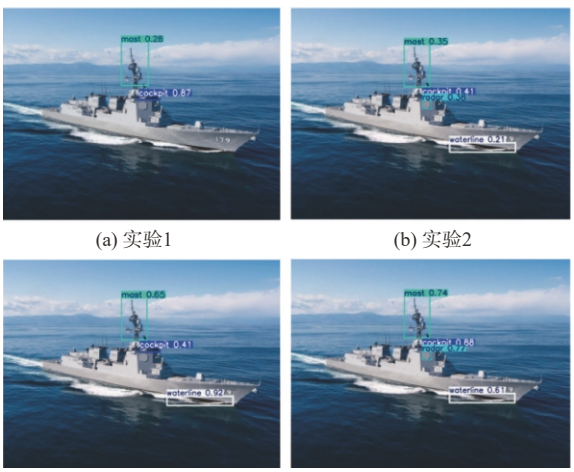
表 7　消融实验结果对比

Table 7　Comparison of ablation experiment results

C3k2_DCNv4	Bi-AVB-FPN	GSConv	精确率/%	召回率/%	mAP50/%	参数量	时间/ms
×	×	×	65.3	82.1	80.8	2 583 127	1.4
√	×	×	68.6	87.4	83.9	2 571 439	1.0
√	√	×	70.3	86.7	85.2	2 527 319	0.9
√	√	√	**70.6**	**87.7**	**85.7**	**2 437 559**	**1.1**

了 0.2 ms，主要是因为对算法进行改进后，在一定程度上增加了模型的复杂性，所以检测时间有所增加，但整体网络模型参数量有效降低，能够更好适应硬件条件受限的场景，算法检测精度对比未改进时提升 4.9%，对关键要害部位小目标检测性能得到提升，能够精准检测多尺度、多角度要害部位信息，且检测时间减少了 0.3 ms，进一步提升了网络检测速率。

在消融实验中，对 YOLOv11 算法不同模块改进的检测效果如图 17 所示。可以看到，经过不断改进的算法检测效果不断提升，检测精准度更高，漏检率更低，最终得到的优化网络能够完整检测出船舶的关键部位，且检测准确度及包围框的尺寸位置都更贴近实际目标特征。



(a) 实验1 (b) 实验2

(c) 实验3 (d) 实验4

图 17 不同模块改进检测效果

Fig. 17 Detection renderings of different improved modules

4 结 论

1）本文以提升对海上舰船关键部位精准实时检测为目的，针对现有算法动态目标尺度变化鲁棒性不强、检测精度及速度难以平衡的问题，提出以 YOLOv11 为基础的舰船关键部位检测算法，自建可见光数据集对网络进行训练，并设计对比实验和消融实验，证明优化的网络模型在复杂海洋环境中对动态舰船目标关键部位精准实时检测的能力。

2）本文算法对比改进前，检测精度由 80.8% 提升至 85.7%，提升 4.9%，检测单幅图像时间由 1.4 ms 减少至 1.1 ms，且算法参数量减少，有效简化了算法模型，为搭载到 NVIDIA Jetson TX2 等嵌入式平台构建任务式计算机，提供了轻量化的便利条件。

下一步将对网络在实际场景中的应用、提升复杂环境适应性开展研究，考虑结合红外图像探索全天时海上信息的获取判读。

参考文献（References）

[1] Gao F, He Y S, Wang J, et al. Anchor-free convolutional network with dense attention feature aggregation for ship detection in SAR images[J]. Remote Sensing, 2020, 12(16): 2619.

[2] 白玉, 迟文恺, 谢宝蓉, 等. 结合目标提取和深度学习的红外舰船检测[J]. 电讯技术, 2023, 63(2): 193-198.
Bai Y, Chi W K, Xie B R, et al. Infrared ship detection by combining target extraction and deep learning[J]. Telecommunication Engineering, 2023, 63(2): 193-198(in Chinese).

[3] Tang G, Liu S B, Fujino I, et al. H-YOLO: a single-shot ship detection approach based on region of interest preselected network[J]. Remote Sensing, 2020, 12(24): 4192.

[4] 刘忻伟, 朴永杰, 郑亮亮, 等. 面向航天光学遥感复杂场景图像的舰船检测[J]. 光学精密工程, 2023, 31(6): 892-904.
Liu X W, Piao Y J, Zheng L L, et al. Ship detection for complex scene images of space optical remote sensing[J]. Optics and Precision Engineering, 2023, 31(6): 892-904(in Chinese).

[5] 林鑫伟, 徐志京, 黄海. 复杂背景下的 SAR 图像多尺度舰船检测[J]. 中国航海, 2023, 46(2): 17-24.
Lin X W, Xu Z J, Huang H. Multi-scale detection of ship target against complex background out of SAR image[J]. Navigation of China, 2023, 46(2): 17-24(in Chinese).

[6] 王玺坤, 姜宏旭, 林珂玉. 基于改进型 YOLO 算法的遥感图像舰船检测[J]. 北京航空航天大学学报, 2020, 46(6): 1184-1191.
Wang X K, Jiang H X, Lin K Y. Remote sensing image ship detection based on modified YOLO algorithm[J]. Journal of Beijing University of Aeronautics and Astronautics, 2020, 46(6): 1184-1191(in Chinese).

[7] 李双伟. 基于红外偏振成像的近岸舰船目标识别和抗干扰技术研究[D]. 烟台: 烟台大学, 2016: 12-15.
Li S W. Research on inshore ship target recognition and antijamming technology based on infrared polarization imaging[D]. Yantai: Yantai University, 2016: 12-15(in Chinese) .

[8] 乔延军. 面向户外增强现实的地理实体目标识别与检测[D]. 武汉: 武汉大学, 2017: 10-30.
Qiao Y J. Object recognition and detection of geographical entity based on outdoor augmented reality[D]. Wuhan: Wuhan University, 2017: 10-30(in Chinese) .

[9] Hinton G E, Salakhutdinov R P. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.

[10] 苏娟, 杨龙, 黄华, 等. 用于 SAR 图像小目标舰船检测的改进 SSD 算法[J]. 系统工程与电子技术, 2020, 42(5): 1026-1034.
Su J, Yang L, Huang H, et al. Improved SSD algorithm for small-sized SAR ship detection[J]. Systems Engineering and Electronics, 2020, 42(5): 1026-1034(in Chinese).

[11] Ahn S, Chang J W, Kang S J. An efficient accelerator design methodology for deformable convolutional networks[C]//Proceedings of the IEEE International Conference on Image Processing. Piscataway: IEEE Press, 2020: 3075-3079.

[12] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[EB/OL]. (2015-12-10)[2024-11-20]. https://doi.org/10.48550/arXiv.1512.03385.

[13] Xiong Y W, Li Z Q, Chen Y T, et al. Efficient deformable ConvNets: rethinking dynamic and sparse operator for vision applications[C]//Proceedings of the IEEE/CVF Conference on Computer

Vision and Pattern Recognition. Piscataway: IEEE Press, 2024: 5652-5661.

[14] Tan M X, Pang R M, Le Q V. EfficientDet: scalable and efficient object detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 10778-10787.

[15] Zhang X, Song Y Z, Song T T, et al. AKConv: convolutional kernel with arbitrary sampled shapes and arbitrary number of parameters[EB/OL]. (2023-11-20)[2024-11-22]. https://arxiv.org/abs/2311.11587v1.

[16] Li Y K, Shen H B, Fu Y P, et al. A method of dense point cloud SLAM based on improved YOLOV8 and fused with ORB-SLAM3 to cope with dynamic environments[J]. Expert Systems with Applications, 2024, 255: 124918.

[17] Li H L, Li J, Wei H B, et al. Slim-neck by GSConv: a lightweight-design for real-time detector architectures[EB/OL]. (2024-07-02)[2024-11-22]. https://doi.org/10.48550/arXiv.2206.02424.

[18] Liu W, Anguelov D, Erhan D, et al. SSD: single shot multibox detector[C]//Proceedings of the Computer Vision-ECCV 2016. Berlin: Springer, 2016: 21-37.

[19] Newell A, Yang K, Deng J. Stacked hourglass networks for human pose estimation[C]//Proceedings of the European Conference on Computer Vision. Berlin: Springer, 2016: 486-499.

[20] Yaseen M. What is YOLOv8: an in-depth exploration of the internal features of the next-generation object detector[EB/OL]. (2024-08-28)[2024-11-20]. https://arxiv.org/abs/2408.15857.

[21] Wang A, Chen H, Liu L H, et al. YOLOv10: real-time end-to-end object detection[C]//Proceedings of the Advances in Neural Information Processing Systems 37. Vancouver: NeurIPS, 2024: 107984-108011.

[22] Khanam R, Hussain M. YOLOv11: an overview of the key architectural enhancements[EB/OL]. (2024-11-23)[2024-11-25]. https://arxiv.org/abs/2408.15857.

Detection algorithm of ship key parts based on YOLOv11

WANG Yao，CAO Silei*，LIU Minggang，WANG Yingying

(Naval Aviation University，Yantai 264001，China)

Abstract：In contemporary and forthcoming maritime rights safeguarding and oceanic surveillance endeavors, it is critically important to investigate methods for swiftly and precisely acquiring data on essential components of vessels and adeptly analyzing real-time marine conditions. Despite the capability of deep learning-based object identification algorithms to identify various types of target information, there is a deficiency in research focused on algorithms for recognizing critical components of ships, and the examination of the relationship between multi-channel feature maps is inadequate. The feature utilization rate of key parts of ships with different scales is low, which may lead to the loss of important feature information and a decrease in detection accuracy. To address this issue, a ship key part detection method based on YOLOv11 is proposed to improve the accuracy and efficiency of key part detection. This manuscript initially performs a thorough examination of the critical and challenging issues in the present detection of essential ship components and engages in a comparative analysis with existing methods. Then, an improved YOLOv11 object detection network for ship key part detection is proposed based on actual problems. Ultimately, a dataset of key components for visible light ships has been established, and through the implementation of comparative and ablation experiments, it is thoroughly evidenced that the proposed algorithm developed in this study exhibits high precision and promptness in identifying ship key components, thereby offering viable technical assistance and a theoretical foundation for the meticulous differentiation of essential and critical parts across various ship types in intricate marine settings and the efficient surveillance of maritime vessel information.

Keywords：ship targets; critical parts; YOLOv11; attention mechanism; feature fusion

Received：2024-12-03；**Accepted**：2025-07-17；**Published Online**：2025-09-04 15：16

URL：link.cnki.net/urlid/11.2625.V.20250904.1419.001

Foundation item：Youth-General Program Category(ZR2024QE034)

* **Corresponding author**. E-mail：caosileimail@163.com

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0582

基于 AR-PPO 的端到端无人机自主导航方法

李涵玮[1]，李新凯[1,*]，张海[2]，姜凌峰[1]，孟月[3]，张宏立[3]

(1. 新疆大学 电气工程学院，乌鲁木齐 830017；2. 新疆大学 工程训练中心，乌鲁木齐 830017；
3. 新疆大学 智能科学与技术学院（未来技术学院），乌鲁木齐 830017)

摘　　要：针对基于深度强化学习 (DRL) 的无人机导航方法面临的部分环境不可观测、训练难度高等问题，提出一种基于动作屏蔽-循环-近端策略优化 (AR-PPO) 的端到端无人机自主导航方法。引入门控循环神经网络处理历史信息，为策略网络引入历史基准信息以解决复杂环境下部分信息不可观测问题；设计适用于连续动作空间强化学习任务的动作屏蔽方法，排除非法动作的干扰并加快模型训练速度；建立演员-评论家框架的三维连续动作空间 DRL 端到端模型并于训练环境进行训练。与主流 DRL 方法进行对比实验，AR-PPO 训练收敛速度最快，能取得最高奖励，在 4 种泛化测试环境中均取得了 85% 以上的成功率，在实机实验中能够安全地进行避障导航任务，表明所提方法能够有效实现无人机的精确避障与安全导航。

关 键 词：自主导航；深度强化学习；近端策略优化；复杂环境；无人机
中图分类号：V279; TP18
文献标志码：A　　**文章编号**：1001-5965(2026)11-3982-13

无人机作为一种能够飞行的特殊机器人，因其体积小、动作灵活、适宜在复杂环境下完成机动，从而广泛应用于各种军用及民用领域[1]。现有大多数导航方法均是基于地图的导航，包括 SLAM 建图、全局路径规划、局部路径规划、动作执行等方法[2]。这种基于地图的导航方法已广泛应用于各类移动机器人，但该方法严重依赖高精度的地图，各环节耦合性强，任何一个环节出错均会导致导航失败[3]。

由于无人机载荷的限制，使其难以独立实现快速精确的建图与规划，近年来，学者们开始开展不依赖地图的导航研究[4]，尝试用深度强化学习 (deep reinforcement learning, DRL) 构建导航策略，将机器人的运动策略用神经网络表示，通过机器人与环境不断交互试错的方式学习运动策略[5]。Singla 等[6] 使用深度 Q 网络（deep Q-network，DQN）并加入具有时间注意力的循环网络，使其算法拥有更高的避障能力；魏瑶等[7] 将门控循环单元（gated recurrent unit, GRU）引入双深度 Q 网络（double deep Q-network, DDQN）处理时间维度信息，提高了算法在部分可观测环境中的性能。但上述研究为无人机预设了简单的前进、后退、转向等离散动作，降低了训练难度。显然，离散动作空间使无人机的导航与避障能力受到了极大的限制，不利于无人机自主导航能力的提升。

部分学者将无人机拓展到三维连续动作空间，使其能够自由选择飞行速度或飞行距离，同时拥有更加平滑的飞行动作和更合理的飞行轨迹。张耀中等[8] 基于深度确定性策略梯度（deep deterministic policy gradient, DDPG）算法研究了无人机对敌方来袭目标的追击问题，经训练后无人机能较好地完成追击任务；唐蕾等[9] 使用改进双延迟深度确定性策

收稿日期：2024-08-02；**录用日期**：2024-10-30；**网络出版时间**：2024-11-07 14:00
网络出版地址：link.cnki.net/urlid/11.2625.V.20241107.1129.002
基金项目：国家自然科学基金 (62263030)；新疆维吾尔自治区自然科学基金 (2023D01C187)；新疆维吾尔自治区“天山英才”培养计划 (2023TSYCCX0037)
* **通信作者**. E-mail：lxk@xju.edu.cn

引用格式：李涵玮，李新凯，张海，等. 基于 AR-PPO 的端到端无人机自主导航方法 [J]. 北京航空航天大学学报，2026，52（11）：3982-3994.
Li H W，Li X K，Zhang H，et al. End-to-end autonomous navigation method for drones based on AR-PPO [J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：3982-3994（in Chinese）.

略梯度(twin-delayed deep deterministic policy gradient, TD3)算法实现了无人机连续三维动作空间避障, 结果表明, 该算法效果优于 DDPG 算法; 张云燕等[10]使用 DDPG 算法实现了依靠深度相机的无人机连续三维动作空间避障, 实验证明 DDPG 算法的避障效果优于三维向量场直方图算法。上述研究都是基于无人机当前状态完全已知, 在简单环境下可行, 但在复杂场景中, 部分状态不可测时将导致无人机导航性能降低。

一些学者对考虑历史信息的无人机强化学习导航方法进行了研究。赵静等[11]基于近端策略优化(proximal policy optimization, PPO)算法实现了上述无人机避障方法, 但其动作空间为坐标轴方向的线速度, 无人机仅能面向初始方向飞行, 无法实现转向掉头等动作, 飞行场景为规则的管道之内, 飞行距离短, 场景简单。寇凯等[12]同样采用了上述方法, 但选择方形、柱形等简单障碍物, 无法充分表现无人机在复杂场景的自主避障优势。

综上所述, 行之有效的 DRL 无人机自主导航方法应当至少包含以下内容: 被设计于三维连续动作空间与观测空间下, 以获得更高的动作灵活性; 考虑历史信息, 以解决部分环境信息不可观测问题; 训练于复杂环境下并进行泛化实验, 以确保策略的有效性和泛用性。然而, 三维的任务空间、历史信息和复杂环境必然会增加训练时间与训练难度, 因此, 需要采取措施提高 DRL 算法的训练速度。

由此, 本文提出了一种适用于复杂场景基于动作屏蔽-循环-近端策略优化(action masking-temporal-proximal policy optimization, AR-PPO)的端到端自主导航方法, 主要创新有:

1) 在三维观测空间与动作空间中设计了连续动作的线速度、角速度控制方式, 赋予无人机良好的转向与掉头能力, 并拥有更加平滑的飞行轨迹和更高效的避障能力。

2) 为 PPO 模型引入 GRU 网络处理历史信息以解决飞行环境信息部分不可观测问题, 提高强化学习模型稳定性, 并使模型能够完成更加复杂的任务。

3) 为解决复杂环境带来的训练难度大和训练时间长等问题, 结合基于奖励的动作软约束与离散动作空间下的动作掩码硬约束, 设计了适用于连续动作空间的动作屏蔽方法, 通过减少非法动作的干扰以提高训练速度。

1　基于 DRL 的无人机导航策略

无人机导航是指无人机能够从起点出发, 依靠自身传感器执行动作躲避障碍物并安全地运动至目标位置。这一过程可以使用马尔可夫决策过程(Markov decision process, MDP)来描述, 然而, 无人机所搭载的传感器(如深度相机)仅能观测到正前方一定视角内的部分环境信息, 无人机侧面、后面、上下方和障碍物后等信息都难以获得。因此, 本文将无人机的导航任务定义为部分可观察马尔可夫决策过程 (partially observable Markov decision process, POMDP), 去除环境状态完全可观测的假设。具体用$(\boldsymbol{S},\boldsymbol{A},\boldsymbol{P},\boldsymbol{R},O,\boldsymbol{H})$表达, 其中: $\boldsymbol{S}$为无人机的状态空间, 采用由观测集合O接收基于隐藏状态$p(\boldsymbol{o}|\boldsymbol{s})$的观测结果; $\boldsymbol{A}$为无人机的动作空间, 包括无人机的不同执行动作; $\boldsymbol{P}$为状态转移概率矩阵, 由于无人机飞行存在干扰且运动环境未知, 因此, 设定$\boldsymbol{P}$未知; $\boldsymbol{R}$为无人机的动作奖励, 表示无人机在执行动作后根据环境信息和自身状态获取的奖励; O为无人机的观测集合, 包括环境信息、无人机状态、导航目标等。

在 POMDP 条件下, 状态转移概率矩阵$\boldsymbol{P}$与当前观测状态$\boldsymbol{o}_t$有关, $\boldsymbol{o}_t$与隐藏状态的转移函数$p(\boldsymbol{o}_t|\boldsymbol{s}_t)$相关, 包含当前状态$\boldsymbol{s}_t$的部分信息, 本文通过定义历史状态$\boldsymbol{H}$来解决无人机的部分可观测性问题, 在 POMDP 的基础上设置合理的动作奖励, 基于 DRL 的无人机导航策略求解式为

$$\pi^*_{\text{std}} = \arg\max_{\pi} \sum_{t} E_{(\boldsymbol{s}_t,\boldsymbol{a}_t)\sim\boldsymbol{P}}(r(\boldsymbol{s}_t,\boldsymbol{a}_t)) \tag{1}$$

式中: π为无人机的策略; E为期望; $\boldsymbol{s}_t$为第t步的状态; $\boldsymbol{a}_t$为无人机在$\boldsymbol{s}_t$状态下根据π策略选择的动作; $r(\boldsymbol{s}_t,\boldsymbol{a}_t)$为无人机在$\boldsymbol{s}_t$状态下执行$\boldsymbol{a}_t$动作获取的奖励; π^*_{std}为无人机经训练后得出使累计奖励最大的策略。

鉴于 PPO 强化学习算法在泛用性、训练速度、探索能力等方面的优势, 且其更加适用于连续动作空间强化学习问题[13], 本文以该算法开展无人机的导航问题研究。

2　基于 PPO 的改进算法设计

2.1　PPO 算法概述

PPO 算法是一种用于强化学习的优化算法。其由 OpenAI 在 2017 年提出, 主要用于解决 Policy Gradients 方法中训练不稳定和样本效率低的问题。PPO 算法具备策略梯度(policy gradient, PG)算法与信任域策略优化 (trust region policy optimization, TRPO)算法的部分优点, 采样数据过程与优化目标函数过程交替进行, 虽然标准的 PG 算法要求对每个数据样本执行一次梯度更新, 但 PPO 算法提出了新目标函数, 可以实现对数据样本的小批量更新。与传统

的PG算法相比，PPO算法对样本的利用效率更高；与更加复杂的TRPO算法相比，PPO算法的实现更为简单且效果相似[14]。

PPO算法可以根据网络更新方式分为PPO-Penalty算法与PPO-Clip算法，由于PPO-Clip算法具有更优秀的性能，因此，本文选用PPO-Clip算法作为研究的核心算法。PPO-Clip算法相对于其他强化学习算法的核心区别在于使用了策略损失函数：

$$\begin{cases} L^{\mathrm{CLIP}}(\theta)=\hat{E}_t\left(\min\left(\gamma_t(\theta)\hat{A}_t,\gamma_t'(\theta)\hat{A}_t\right)\right) \\ \gamma_t(\theta)=\dfrac{\pi_\theta(\boldsymbol{a}_t|\boldsymbol{s}_t)}{\pi_{\theta_{\mathrm{old}}}(\boldsymbol{a}_t|\boldsymbol{s}_t)} \\ \gamma_t'(\theta)=\mathrm{clip}(\gamma_t(\theta),1-\varepsilon,1+\varepsilon)\hat{A}_t \end{cases} \tag{2}$$

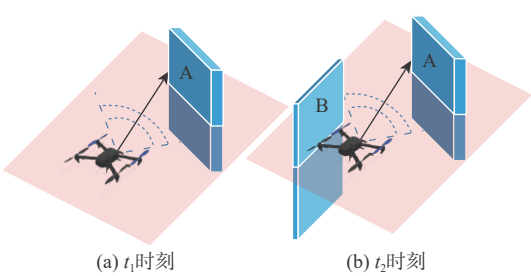
式中：ε为截断超参数，一般设置为0.2；$\gamma_t(\theta)$表示新旧策略的差异，用来控制新策略的更新幅度，其值越趋近于1，表明新旧策略差异越小；clip()为截断函数，将网络更新比例$\gamma_t(\theta)$限制在$[1-\varepsilon,1+\varepsilon]$区间内以确保算法的稳定性；$\hat{A}_t$为优势函数，表示在状态下动作相对均值的偏差，一般采用广义优势估计(generalized advantage estimation, GAE)来计算[15]：

$$\begin{cases} \hat{A}_t^{G_{\mathrm{AE}}(\gamma,\lambda)}=\displaystyle\sum_{l=0}^{\infty}(\gamma\lambda)^l\delta_{t+l}^V \\ \delta_t^V=r_t+\gamma V_\omega(\boldsymbol{s}_{t+1})-V_\omega(\boldsymbol{s}_t) \end{cases} \tag{3}$$

式中：V为价值估计函数，$V_\omega(\boldsymbol{s}_{t+1})$和$V_\omega(\boldsymbol{s}_t)$分别为下一时刻和当前时刻的预期累计奖励总和；$r_t$为$t$时刻智能体获得的奖励；$\gamma$为折扣因子。

2.2 门控循环网络

常规的PPO网络能够有效解决MDP问题，然而在POMDP条件下，无人机无法在当前时刻获取环境的所有信息，而环境信息的缺失将使无人机在复杂环境中难以得出行之有效的策略。如图1所示，无人机在t_1与t_2时刻仅能直接观测到障碍物A，无法判断障碍物B的存在，因此，仅靠观测$\boldsymbol{o}_t$不足以得出最优的动作。



(a) t_1时刻　(b) t_2时刻

图1　部分可观测状态

Fig. 1　Partially observable state

在环境部分可观测条件下，当前状态$\boldsymbol{s}_t$被观测$\boldsymbol{o}_t$所替代，观测$\boldsymbol{o}_t$中仅包含状态$\boldsymbol{s}_t$的部分信息。通过引入GRU对历史信息进行筛选与总结得出当前历史信息$\boldsymbol{h}_t$，强化学习模型能够依靠$\boldsymbol{h}_t$与$\boldsymbol{o}_t$得出组成更加完善的状态信息并实现更好的避障效果[16]，引入GRU后的PPO即为循环-近端策略优化(recurrent-PPO, R-PPO)。

GRU为一种常用的循环神经网络结构，为解决长期依赖问题而设计，在一定程度上解决了长短时记忆(long-short term memory, LSTM)网络存在的训练复杂、参数多等问题，相比于LSTM，GRU的参数更少，计算量更小，从而训练速度更快。同时，GRU在一些任务上表现出色，能够更有效地处理数据的依赖关系，同时避免了LSTM中出现的梯度消失和梯度爆炸等问题[17]，GRU前向计算式为

$$\begin{cases} \boldsymbol{z}_t=\sigma(\boldsymbol{W}_z\cdot[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_z) \\ \boldsymbol{c}_t=\sigma(\boldsymbol{W}_c\cdot[\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_c) \\ \tilde{\boldsymbol{h}}_t=\tanh(\boldsymbol{W}_h\cdot[\boldsymbol{c}_t\odot\boldsymbol{h}_{t-1},\boldsymbol{x}_t]+\boldsymbol{b}_h) \\ \boldsymbol{h}_t=\boldsymbol{h}_{t-1}\odot\boldsymbol{z}_t+\tilde{\boldsymbol{h}}_t\odot(\boldsymbol{I}-\boldsymbol{z}_t) \end{cases} \tag{4}$$

式中：$\boldsymbol{W}$为权重矩阵；$\boldsymbol{b}$为偏置；σ与tanh为激活函数；$\boldsymbol{I}$为全1向量；更新门$\boldsymbol{z}_t$控制时刻$t-1$的隐藏状态$\boldsymbol{h}_{t-1}$与时刻t的状态输入$\boldsymbol{x}_t$有多少保存至隐藏状态$\boldsymbol{h}_t$；重置门$\boldsymbol{c}_t$控制时刻$t-1$的隐藏状态$\boldsymbol{h}_{t-1}$有多少保存至候选隐藏状态$\tilde{\boldsymbol{h}}_t$；“⊙”表示向量元素相乘。GRU网络结构如图2所示。

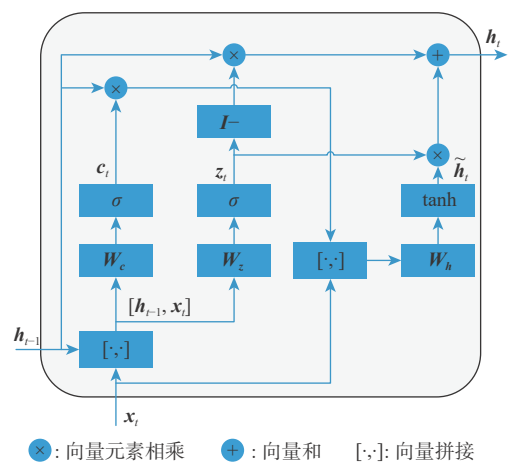


图2　GRU网络结构

Fig. 2　GRU network structure

2.3 动作屏蔽方法

在DRL任务场景中，动作是体现学习效果最直接的因素，直接影响了智能体的行为和环境状态的变化，而在实际应用中，智能体的可执行动作存在很多约束。为排除非法动作的干扰并提高训练效率和速度，需要设计适用于本文的动作屏蔽方法。

以无人机为例，其自身运动性能与环境障碍物都会限制其动作可行性。通常情况下，对动作的惩罚性奖励有助于约束无人机的无效动作，这种方式

被称为软约束。但采用奖励函数设计的方式来约束无人机会付出极大的训练代价并容易导致模型发散[18]。模型发散将会干扰网络的更新与策略的优化, 不断的动作重复同样使无人机无法探索更加有效的动作策略, 拖慢了训练效率。在离散动作强化学习任务中, 可以采用动作掩码的方法解决该问题, 但该方法无法应用于连续动作空间的强化学习任务中。动作掩码的基本思想是, 为 Actor 神经网络输出的动作概率加上一层掩码, 合法动作将正常输出对应的动作概率, 非法的动作将被掩码屏蔽。

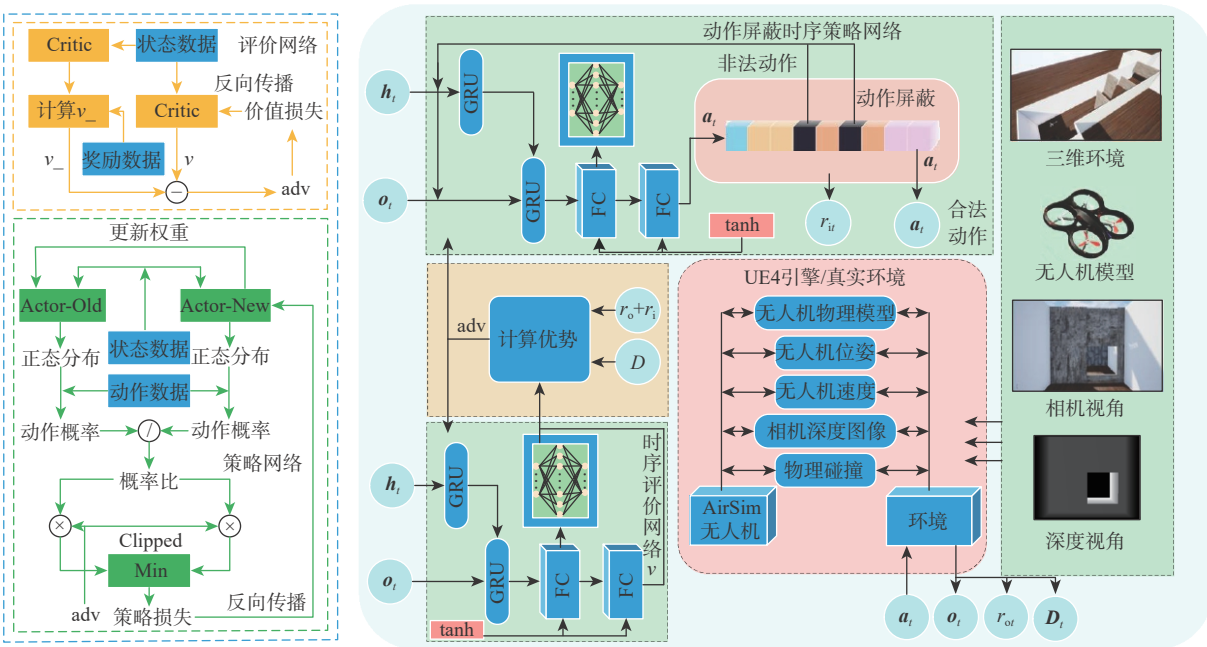
在本文的连续动作空间强化学习任务中, 结合动作掩码与奖励函数设计的基本思想, 提出了非法动作集合A_f与屏蔽概率分布ε_{a}以实现连续动作空间强化学习任务中的动作屏蔽方法, 将动作屏蔽加入 R-PPO 即为 AR-PPO。

非法动作集合A_f内包括绝对非法动作集合与概率非法动作集合, 绝对非法动作代表动作$\boldsymbol{a}_0$在当前状态$\boldsymbol{s}_0$下完全不可行或无效, 如撞向障碍物或飞向地图外等; 相对非法动作代表动作$\boldsymbol{a}_0$在当前状态$\boldsymbol{s}_0$下暂时可行, 但状态$\boldsymbol{s}_0,\boldsymbol{s}_1,\cdots,\boldsymbol{s}_t$下的动作$\boldsymbol{a}_0,\boldsymbol{a}_1,\cdots,\boldsymbol{a}_t$整体构成了连续的不可行动作或无效动作, 如原地转圈或反复转向。屏蔽概率分布f表示当前动作$\boldsymbol{a}_t$被屏蔽的概率, 绝对非法动作的屏蔽概率$f_0=1$, 相对非法动作的屏蔽概率$f_0\in(0,1)$, 屏蔽概率的计算式为

$$\begin{cases} f_{\mathrm{a}} = M(0,1)\sum_{t=0}^{n} f_t \\ f_t = F(\boldsymbol{a}_t|\boldsymbol{s}_t) \end{cases} \tag{5}$$

式中: $M(0,1)$为概率累计重置; f_{a}为t步动作后的屏蔽累计概率, 当累计概率为 1 时, 当前动作$\boldsymbol{a}_t$将被屏蔽并获得负奖励, 网络将重新输出动作直到动作合法。由此, 在训练过程中将屏蔽大量无效或重复的训练动作, 加快训练速度。

非法动作集合A_f中一部分非法动作由人工于训练前定义, 如约束无人机的平均速度, 限制转向速度; 另一部分需要依靠无人机的当前状态$\boldsymbol{s}_t$实时构建与更新, 如通过 AirSim 命令获取无人机当前动作的可行性或通过代码设计判断当前动作是否陷入循环。基于 AR-PPO 的导航方法示意图如图 3 所示, 其中, $v_$为网络预测价值, v 为目标价值, r_{i} 为内部奖励, r_{o} 为外部奖励, FC 表示全连接层, D 为无人机一项状态集合。



(a) 网络更新流程　　(b) 本文方法结构

图 3　AR-PPO 导航方法

Fig. 3　AR-PPO navigation method

图 3(b) 为本文方法的整体研究结构, 依靠 AR-PPO 算法在仿真环境中探索并收集数据更新网络, 策略网络与平均网络均为 GRU 时序网络连接 2 层线性层构成, 策略网络线性层后接入动作屏蔽算法。UE4 仿真环境与真实环境能够互相替换, 确保该算法能够同时用于仿真实验和实机实验。图 3(a) 为网络更新流程, 评价网络中 adv 即为式 (3) 计算所得优势值, 通过优势值计算损失函数进行反向传播实现网络更新; 策略网络则通过评价网络所得优势值与状态、动作数据经过式 (2) 计算损失函数进

行反向传播实现网络更新。

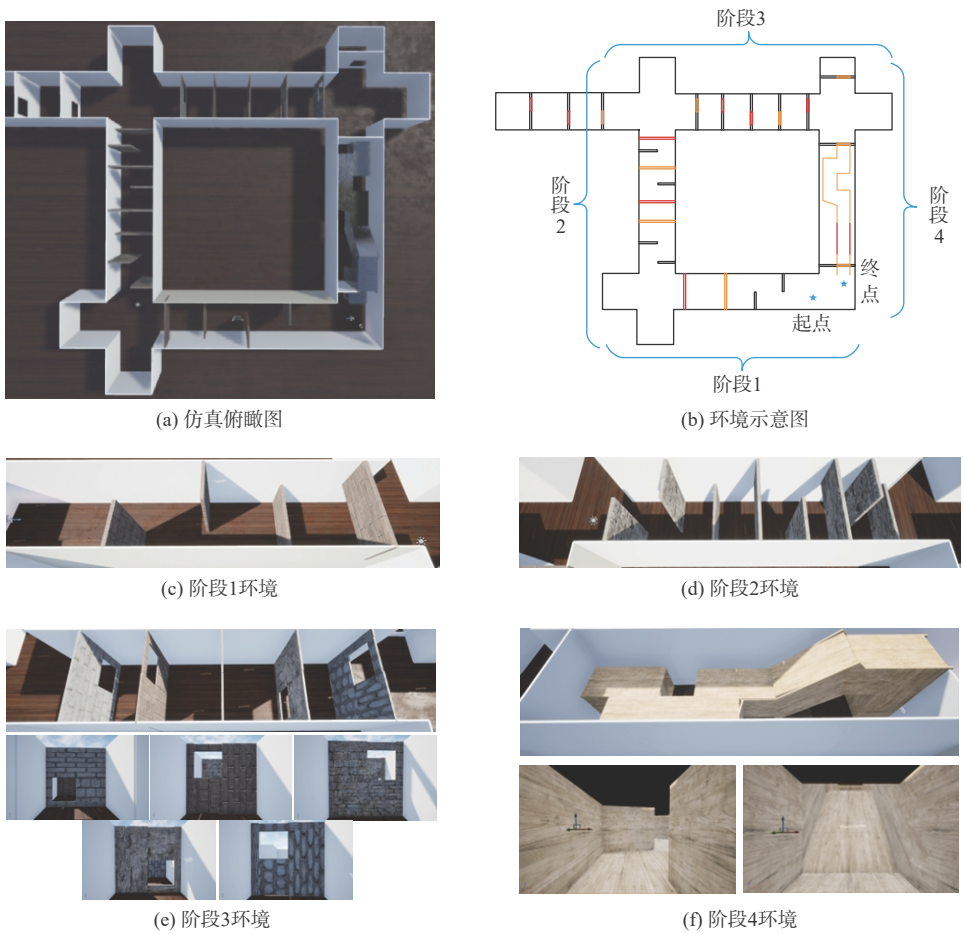
3 基于DRL的无人机导航方法设计

3.1 训练环境设计

无人机相比于无人车拥有更高维度的动作空间与状态空间，若使用常规的柱形或方形障碍物将会使无人机的z轴失去作用，因此，必须采用更加复杂的障碍物环境。

由于AirSim基于虚幻引擎的优越物理与视觉仿真效果，本文选用AirSim构建仿真环境。为加快训练速度和简化训练难度，训练环境被分为4个难度不同的训练阶段，但整体训练过程依然是连续的，无人机的每次训练都需要依次进行所有阶段的训练而不是对每个阶段单独训练。若单独对每个阶段训练，每阶段的最佳策略可能会影响其他阶段的策略，因此，需要整体训练以得出最为泛用的导航策略。

完整训练环境如图4所示，图4(b)平面示意图中红色线条代表该墙体、窗口、管道位于高处，无人机需要从下方绕行或从窗口或管道内穿越，黄色反之，无人机需要从上方绕行或穿越。无人机需要由起点开始依次经过4个阶段的不同障碍物，最终返回到达终点。阶段1采用较为简单的障碍物，训练初期易于获取的奖励将有利于有效导航策略的形成；阶段2将阶段1的障碍物缩短间隔并随机排列，提高了训练难度；阶段3采用较为困难的窗口障碍物，无人机的可通行区域更小；阶段4使用管道空间，无人机需要在狭窄的管道中精确执行动作以穿越管道。无人机完成某一阶段后需要自行根据环境变化改变飞行方向，确保自身飞向正确的方向而不是岔路。



(a) 仿真俯瞰图　(b) 环境示意图

(c) 阶段1环境　(d) 阶段2环境

(e) 阶段3环境　(f) 阶段4环境

图4 仿真训练环境

Fig. 4 Simulation training environment

3.2 观测空间设计

观测空间O中的数据主要可以分为两部分：通过深度相机获取环境信息和无人机飞行中的自身状态。本文采用双目深度相机作为观测环境的传感器。深度相机像素分辨率设置为256像素×144像素，视角场约为80°×60°，若将其直接作为观测量输入会导致训练难度过大，不利于实体无人机的部署，因此，将深度图像进行栅格化，每一栅格像素分辨率为32像素×24像素，为保证无人机正前方信息的完整提取并保留距离无人机最近的障碍物信息，采用栅格交点一定范围内的最小深度值，最终得出7×5的深度矩。

为避免利用位置信息需要全局定位的问题, 观测空间O中不包含无人机的全局坐标, 改为采用无人机与目标的相对信息, 常见的方案为: ①无人机与目标点的总距离d_{xyz}; ②无人机航向与目标方向的夹角θ_{xyz}; ③无人机与目标点的三轴方向的相对距离d_x、d_y、d_z。

相比于无人车, 无人机的自身状态需要考虑更高维度的相对信息, 采用以上无人车的常见方案所得到的信息均不够直观, 无人机需要较长时间来尝试与理解信息的含义。因此, 本文采用无人机航向与目标方向的水平夹角θ与高度差h作为观测信息。使用该方案能够减小无人机的训练难度, 在相同的测试环境下, 采用原始 PPO 使用以上观测空间方案的训练结果如图 5 所示。

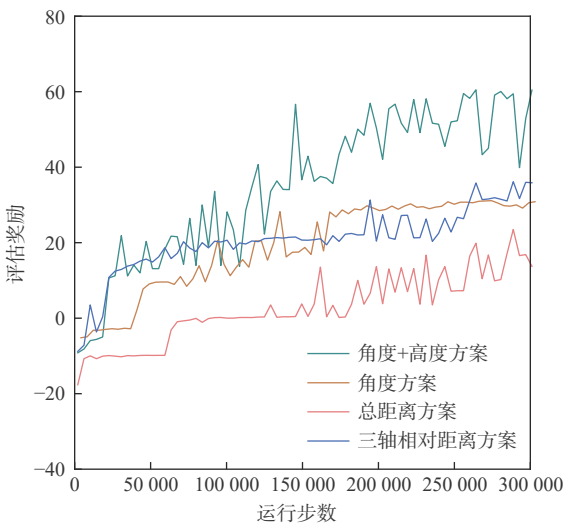


图 5　状态方案对比

Fig. 5　Comparison of state plans

由图 5 可以看出, 采用总距离的方案效果最差, 在训练过程中奖励一直低于其他方案; 仅使用角度的方案效果略好于总距离方案, 但状态信息的不足使其难以实现有效的飞行策略; 采用三轴相对距离的方案在训练前期效果较好, 但在训练中后期奖励增幅不大, 较多的状态量尽管包含了更多的环境信息, 但增大了强化学习训练的难度。采用水平夹角与高度差的方案效果最好, 所包含的环境信息足够完成导航任务, 训练中期就能够取得设计最大奖励。因此, 观测空间O设计为

$$\begin{cases} O=\{d_1,d_2,\cdots,d_n,\theta,h\} \\ \theta=\psi_{\text{yaw}}+\theta_{\text{goal}} \\ h=h_{\text{goal}}-h_{\text{uav}} \end{cases} \tag{6}$$

式中: d_i为经处理后的深度信息; ψ_{yaw}为无人机当前时刻偏航角; θ_{goal}为目标方向与无人机初始方向的夹角; h_{goal}为目标高度; h_{uav}为无人机当前高度。

3.3　动作空间设计

由于简单的离散动作空间在复杂训练环境中难以完成训练目标, 因此, 本文采用三维连续动作空间。连续动作空间允许无人机在一个连续的范围内选择动作, 而不是被限制在离散的动作集合中。这种灵活性使无人机可以更精细地调整其行为, 适应不同的环境和任务需求。无人机的动作空间$\boldsymbol{A}$可以采用速度控制、姿态控制、位置控制等方案。相比于其他方案, 速度控制更直接, 仅需调整速度即可改变无人机的运动状态, 操作相对简单, 运动轨迹更为平滑, 可以在空间中以各种曲线路径飞行。最重要的是速度控制不需要考虑无人机的具体的位置信息, 更适合快速应对变化。采用偏航角速度而不是直接指定偏航角度能够使飞行轨迹更加平滑, 无人机将能够实现平滑的转向和掉头动作。同时, 偏航角速度ω、线速度v_z与观测中的夹角θ、高度差h对应, 能够加快有效导航策略的学习速度。

综上所述, 本文采用速度控制连续动作空间设计, 动作$\boldsymbol{a}_t$由无人机机体坐标系下x轴方向的线速度v_x(单位: m/s)、偏航角速度ω(单位: rad/s), z轴方向的线速度v_z(单位: m/s)组成。

3.4　奖励函数设计

基于 DRL 算法的导航任务通常只设定到达目标的正奖励和碰撞的负奖励。然而, 这种奖励设计会产生奖励稀疏的问题, 在实际导航任务中, 如果目标点与起点之间的距离较远, 那么奖励稀疏问题就会更加显著影响训练样本效率和训练收敛速度[19]。

为解决奖励稀疏的问题, 本文在稀疏奖励基础上引入密集奖励, 密集奖励函数需要提供足够的反馈信息, 以便智能体可以准确地评估其行动的好坏。这要求奖励函数能够捕捉到任务的关键信息, 如智能体与目标之间的距离、避开障碍物的难易程度等。密集奖励函数还需要避免引入不良的副作用或不必要的偏差。如果奖励函数设计不当, 可能会导致智能体学到错误的策略或出现不稳定的学习行为。因此, 设计密集奖励函数需要仔细权衡各种因素, 以确保其在实际应用中的有效性和可靠性。

参考无人机的观测空间与动作空间设计奖励函数, 奖励函数设置如式 (7) 所示, 包括 2 个稀疏奖励与 1 个密集奖励。

$$r_t=\begin{cases} R_{\text{goal}} & d_t<d_{\text{r}} \\ R_{\text{done}} & \text{失败} \\ R_{\text{m}}+|h-h_{\text{r}}|+r_{\text{v}} & \text{其他} \end{cases} \tag{7}$$

2 个稀疏奖励分别为: 每当无人机通过训练环境中的一个阶段并与阶段目标点的距离d_t小于设

定值d_r时，无人机将获得一个较大的正奖励R_{goal}，即无人机在训练中最多可获得 3 次该奖励；当无人机与环境发生物理碰撞时认为本轮任务失败，无人机将获得一个较大的负奖励R_{done}并重置环境开始下一轮训练。

密集奖励包括恒定给予的负奖励R_m，无人机与目标高度差大于h_r时给予的负奖励$|h-h_r|$，无人机向目标前进时给予的正奖励r_v。

4 训练与结果

4.1 训练设置

在训练流程中，将奖励函数计算所得奖励定义为外部奖励，即由外部环境获取的奖励；动作屏蔽所产生奖励为内部奖励，即由算法自身计算所得奖励，2 种奖励均参与网络更新，但内部奖励不计入测试环境的结果输出。无人机的每一步动作都需要将自身状态、相机信息、目标位置输入强化学习网络，网络根据当前策略输出动作并验证其合法性，将合法动作命令发布给无人机执行并计算奖励。最终，当无人机完成一定步数的训练后，将收集的训练数据用于网络更新。AR-PPO 算法伪代码如下：

输入： 目标位置 Goal、初始位置 Pose、最大步数 Step。

输出： 实现研究任务的无人机避障模型。

1: 初始化网络与环境

2: for s = 0 to Step do

3: 重置 Airsim 环境,获取$\boldsymbol{o}_t$

4: 初始化历史信息$\boldsymbol{h}_t$

5: for t = 0 to 4 096 do

6: 根据 Done 选择是否重置环境并重新获取$\boldsymbol{o}_t$与重置$\boldsymbol{h}_t$

7: 根据$\boldsymbol{o}_t$与$\boldsymbol{h}_t$从策略网络获取动作$\boldsymbol{a}_t$与$\boldsymbol{h}_{t+1}$

8: 通过动作屏蔽算法判断$\boldsymbol{a}_t$是否合法并得出内源奖励r_{it}

9: 执行或屏蔽$\boldsymbol{a}_t$并获取环境奖励$\boldsymbol{r}_{ot}$与观测$\boldsymbol{o}_{t+1}$

10: 根据 Airsim 判断无人机是否 Done

11: 存储$\boldsymbol{o}_t$、$\boldsymbol{a}_t$、r_{it}、r_{ot}、$\boldsymbol{h}_t$、$\boldsymbol{o}_{t+1}$、$\boldsymbol{h}_{t+1}$数据

12: end for

13: 存储无人机飞行轨迹

14: 通过式 (3) 计算价值函数$V_{\phi k}$优势估计$\hat{A}_t$

15: 通过优势估计$\hat{A}_t$计算评价网络损失函数并反向传播

16: 通过式 (2) 计算策略网络损失函数并反向传播

17: 再次执行 4 096 步循环并更新网络

18: for i = 0 to 5 do

19: 重置 Airsim 环境

20: 在环境中测试策略θ_{k+1}，记录测试奖励

21: end for

22: 计算 5 次测试的平均奖励与方差并绘制奖励曲线

23: 保存强化学习模型

24: end for

在训练环境中进行实验以验证算法。模型训练在一台操作系统为 Ubuntu 20.04 LTS，搭载 GTX 3060 显卡、i7-12700H CPU、32 GB 内存的计算机中进行，激活函数设置为 tanh。AR-PPO 算法超参数与各算法超参数如表 1 所示，AR-PPO 算法超参数主要采用 Open-AI 推荐参数，SAC、TD3、DDPG 超参数则采用 ElegantRL 小雅强化学习库推荐设置，确保各算法超参数设置合理以提高训练速度和稳定性。

表 1 模型超参数设置

Table 1 Model hyperparameters setting

算法	学习率	折扣率	Horizon	经验池	探索噪声	策略噪声	软更新	裁剪系数	广义优势估计平滑函数	熵系数	小批次
AR-PPO/PPO	2×10^{-4}	0.97	4 096					0.25	0.95	0.01	512
SAC	1×10^{-3}	0.97	4 096	1×10^{6}			5×10^{-3}				
TD3	1×10^{-4}	0.97	4 096	1×10^{6}	0.05	0.10					
DDPG	1×10^{-4}	0.97	4 096	1×10^{6}	0.05						

在训练环境中训练 10^6 步，每轮训练开始时无人机会被重置于起始位置并重新起飞，当无人机到达目标点、发生碰撞、单轮步数到达 600 步时视为本轮结束。每进行 8 192 步训练，将模型调整为评估状态以测试当前策略性能，并保存训练结果。

4.2 训练结果

为在训练阶段评估 AR-PPO 算法，选择目前较为常见的 DRL 算法进行对比实验，使用与 AR-PPO 算法相同的奖励函数、训练设计，每种算法训练 10^6 步，对比算法均采用 ElegantRL 小雅强化学习开源库实现，选择对比算法包括 DDPG 算法、TD3 算法、SAC 算法。实验每进行 8 192 步，将模型设置为评估模式进行测试，取测试中的奖励平均值并记录均差。训练效果如图 6 所示，在训练结束时，只

有 AR-PPO 算法能够取得最高奖励, 这说明在相同的训练环境中, AR-PPO 算法的训练效率优于其他算法。

在训练过程中, 使用 AirSim 保存无人机训练过程中的飞行轨迹, 采用 AR-PPO 算法训练过程中无人机轨迹图如图 7 所示, 由于实际仿真环境中墙体厚度的存在, 因此, 图中轨迹与墙体之间有一定误差。

图 7(a)中红色路径为训练过程中无人机经过的全部路径, 颜色越深说明经过次数越多。可以看出, 无人机在训练的第 1、第 2 阶段探索了所有岔路, 这说明此时无人机仍不能正确处理目标方向与远离障碍物之间的取舍。而在第 3、第 4 阶段无人机的航行轨迹被限制在一个个窗口与管道之间, 无人机需要谨慎调整自身姿态和飞行速度, 因此, 第 3、第 4 阶段轨迹细长。图 7(b)为训练完成后将模型进行多次测试所得无人机飞行轨迹, 测试中无人机飞行策略稳定、动作较为平稳, 能够安全完成导航任务。

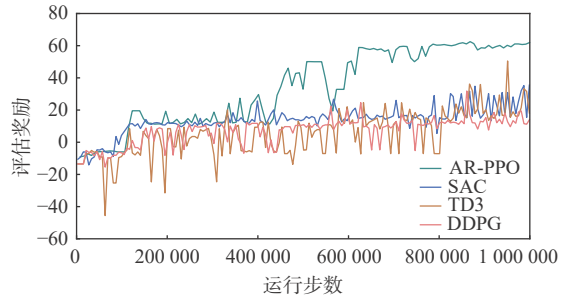
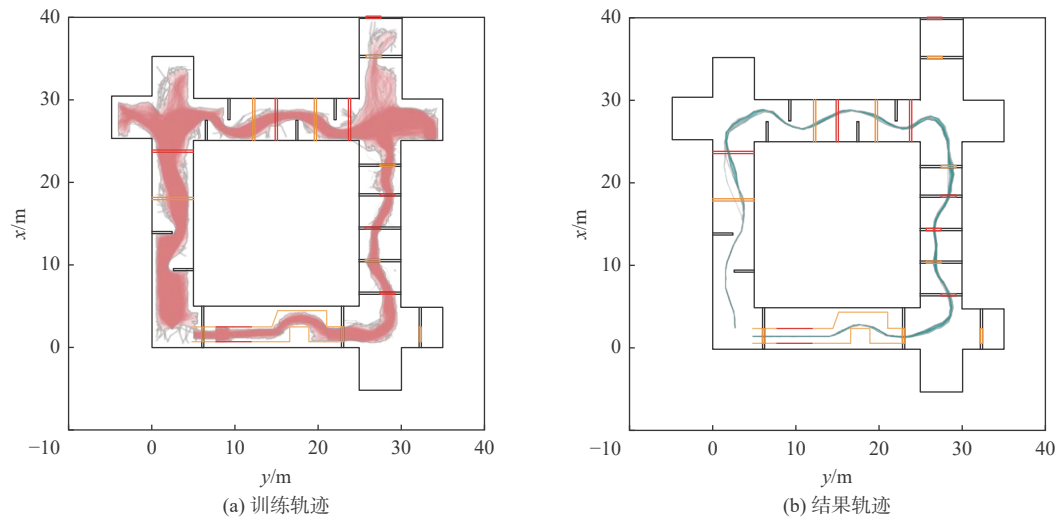


图 6　训练效果对比

Fig. 6　Comparison of training effects



(a) 训练轨迹　　(b) 结果轨迹

图 7　训练轨迹与结果轨迹

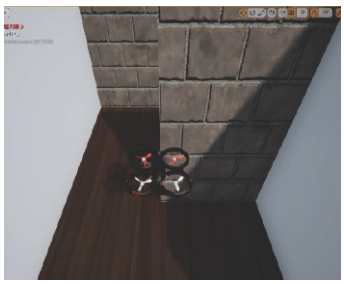
Fig. 7　Training trajectory and result trajectory

将无人机固定于 3 个选定位置并进行强化学习训练, 保存动作屏蔽算法输出的合法动作与被屏蔽的非法动作, 连接动作起始点与目标点, 得出如图 8 所示的动作屏蔽图。图中, x 轴方向为无人机朝向, 浅红色线条为会撞向障碍物的非法动作, 浅蓝色线条为可执行的合法动作。在训练过程中, 非法动作会被动作屏蔽算法拦截并给予负奖励。只有合法动作会被真正输入至无人机并执行, 由此节约大量的试错时间和重复探索时间, 加快训练速度。

4.3　泛化实验

将 AR-PPO 算法与对比算法训练所得模型应用于不同的测试环境, 以验证各模型的泛化能力, 每种算法模型进行 100 次测试, 实验过程中各模型取得结果如表 2 所示, 4 种测试环境与算法测试轨迹如图 9 所示, 图中仅展示对比算法中成功率最高的一种算法。

由表 2 可知, AR-PPO 算法在不同环境中表现最好, 能够在与训练环境不同的场景中达到 85% 以上的导航成功率, ; SAC 算法能够在环境 1、环境 2、环境 3 中到达目标点, 成功率低于 AR-PPO 算法但高于其他算法, 环境 4 中则只能飞行 7 m, 无法穿过狭窄通道; TD3 算法成功率低于 SAC 算法但优于 DDPG 算法; DDPG 算法在各个环境成功率都最低, 表现最差。其中, 环境 4 仅有 AR-PPO 算法能够成功抵达目标, 这说明对比算法在训练中未能学习到如何穿越狭窄通道或无法将策略迁移至未知环境。图 9 中仅展示 AR-PPO 算法与对比算法中最佳算法的飞行轨迹, 环境 1 除各算法均能到达靠近目标点的位置, 但不能稳定越过最后 2 道障碍; 环境 2 中 TD3 算法到达目标点概率较低, SAC 算法则能够以 2 条不同路径到达目标点, 但飞行速度较慢; 环境 3 各算法均能够以一定概率到达目标点, 但只有 AR-PPO 算法拥有稳定的策略以同一轨迹到达目标点; 环境 4 除 AR-PPO 算法以外, 对比算法无



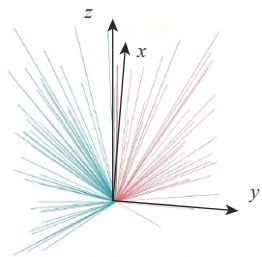
(a1) 右侧障碍环境



(b1) 上方障碍环境

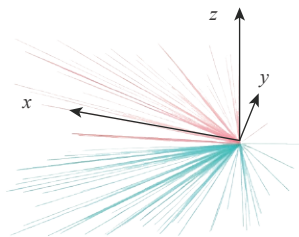


(c1) 窗口障碍环境



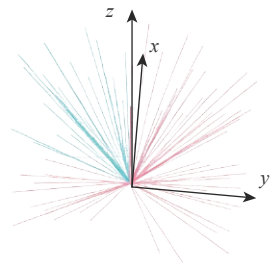
(a2) 动作结果

(a) 右侧障碍环境与动作结果



(b2) 动作结果

(b) 上方障碍环境与动作结果



(c2) 动作结果

(c) 窗口障碍环境与动作结果

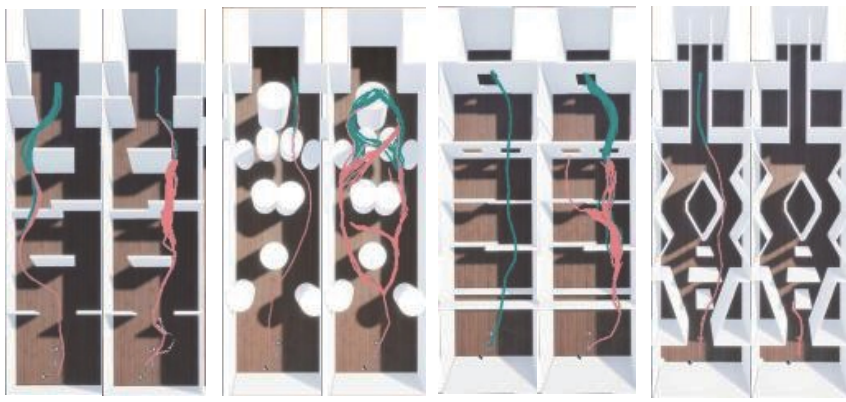
图 8 动作屏蔽效果

Fig. 8 Action block effect

表 2 实验结果

Table 2 Experimental results

环境	目标成功到达率/%				最高单步平均奖励				飞行距离众数/m			
	AR-PPO	DDPG	TD3	SAC	AR-PPO	DDPG	TD3	SAC	AR-PPO	DDPG	TD3	SAC
环境1	85	9	48	44	0.70	0.18	0.42	0.31	30	12	30	26
环境2	96	4	36	64	0.77	0.18	0.38	0.68	30	27	18	30
环境3	100	21	51	57	0.82	0.42	0.65	0.67	30	16	30	30
环境4	92	0	0	0	0.82	0.14	0.14	0.14	30	7	7	7



(a1) AR-PPO (a2) TD3

(a) 环境1

(b1) AR-PPO (b2) SAC

(b) 环境2

(c1) AR-PPO (c2) SAC

(c) 环境3

(d1) AR-PPO (d2) SAC

(d) 环境4

未到达目标点 到达目标点

图 9 迁移实验轨迹

Fig. 9 Migration experiment trajectory

法越过第 1 道障碍，这表明其不能在狭窄通道中完成导航任务，AR-PPO 算法则能够在狭长的通道中谨慎地调整姿态并完成飞行任务。

以上实验结果表明，由 AR-PPO 算法在训练环境中所得的强化学习模型在未经调整的情况下，能够直接部署于新的未知环境实现有效的避障与导航，即该模型具有良好的泛化性能。

4.4 消融实验

设计消融实验评估 AR-PPO 算法各组件的影响，将原始 PPO 作为基准模型作为对比，R-PPO 算

法为移除动作屏蔽的时序 PPO 算法, A-PPO 算法为移除 GRU 的动作屏蔽 PPO 算法, 于训练场景中将模型分别进行训练, 训练设置与上文相同, 最终获得奖励曲线如图 10 所示, 将训练后算法模型应用于测试环境验证模型导航能力, 各算法所得结果如表 3 所示。

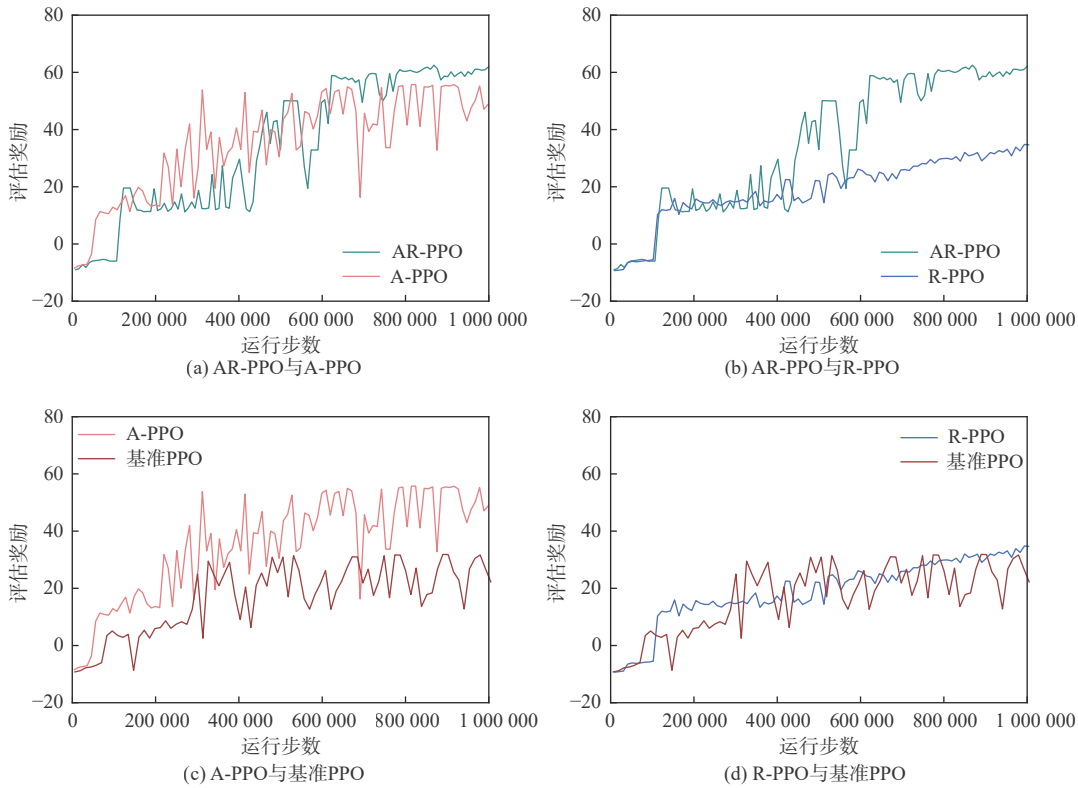


图 10　消融实验

Fig. 10　Experimental of ablation

表 3　消融对比结果

Table 3　Comparison results of ablation

环境	目标成功到达率/%			最高单步平均奖励			飞行距离众数/m		
	AR-PPO	A-PPO	R-PPO	AR-PPO	A-PPO	R-PPO	AR-PPO	A-PPO	R-PPO
环境1	85	47	87	0.70	0.71	0.68	30	26	30
环境2	96	64	84	0.77	0.79	0.75	30	30	30
环境3	100	73	24	0.82	0.81	0.65	30	30	25
环境4	92	3	0	0.82	0.47	0.14	30	7	14

由图 10 可得, 仅加入动作屏蔽的 A-PPO 算法在训练前期与中期均能以最少的训练步数取得最高的累计奖励, 训练速度快于作为基准的原始 PPO 算法; 加入动作屏蔽与 GRU 的 AR-PPO 算法取得高奖励所需要的步数同样高于移除动作屏蔽的 R-PPO 算法, 由此可以得出, 动作屏蔽能够有效减少非法动作的干扰并提高训练速度。在训练后期, A-PPO 算法的累计奖励曲线高于 R-PPO 算法与基准 PPO 算法但低于 AR-PPO 算法, 奖励曲线反复震荡不平稳, 阴影部分面积大, 累计奖励均差大, 模型策略不稳定, 这说明动作屏蔽能够加快训练速度, 但不能使模型在部分可观测环境下稳定收敛。仅加入 GRU 的 R-PPO 算法在训练前中期均最慢, 同样, AR-PPO 算法的训练速度在前中期慢于移除 GRU 的 A-PPO 算法, 由此可得 GRU 的加入拖慢了网络的训练速度。在训练后期, R-PPO 算法的阴影区域明显小于未加入 GRU 的基准 PPO 算法; AR-PPO 算法的阴影区域同样小于移除 GRU 的 A-PPO 算法且曲线振荡幅度较小, 能够稳定地取得较高累计奖励, 证明 GRU 的加入能够提高模型的稳定性, 使模型在部分可观测环境下完成训练目标。

由表 3 可知, A-PPO 算法在各个环境均能够取得一定的成功率且单步奖励更高, 这表明 A-PPO 算法能够快速取得较高的奖励但策略不够稳定; R-PPO 算法在环境 1、环境 2 中成功率与 AR-PPO 算法相近, 高于 A-PPO 算法, 由于该模型在 10^6 步的

训练中并未完成完整的训练流程，在环境3和环境4中导航效果较差。这表明R-PPO算法所得模型策略稳定，但训练速度较慢。测试实验结果能够印证奖励曲线所得结论。综上，实验结果与测试结果表明动作屏蔽与GRU均在AR-PPO算法起到重要作用，其负面效果均在可接受范围内或能够被其他组件所弥补。

4.5 实机测试

将仿真训练环境的模型移植到实际环境进行实机测试是一个具有挑战性的研究，而无人机所面临的坠毁风险更不利于实机测试的实现。相比于仿真环境，实际环境下无人机的导航将面临更多的困难。在实机测试中，无人机在起飞、导航、降落环节均有可能出现问题，实际相机所得深度信息精度与准确性相比仿真相机较低。但AR-PPO算法仍然能够顺利完成避障任务。

因此，考虑到飞行场地大小、实机不确定性和测试风险，实验中搭建的障碍物较为典型，实体无人机采用常见四旋翼无人机机体，搭载D435I深度相机，PIXhawk V5飞控，Nvidia NX机载电脑，安装Ubuntu 18.04系统。将训练所得AR-PPO模型部署于机载电脑中进行实机测试，测试结果如图11所示。

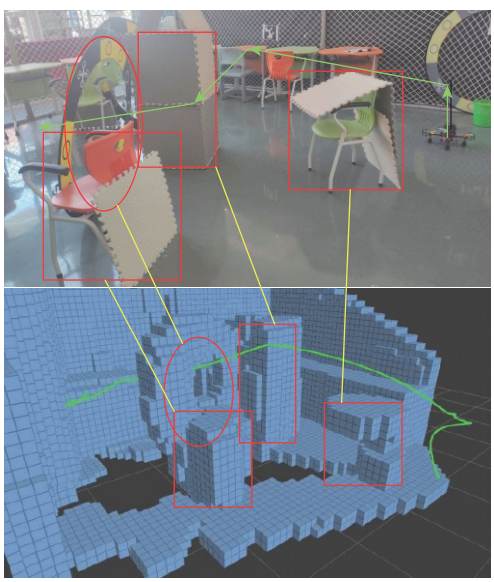


图11 实机测试环境

Fig. 11 Real machine testing environment

图11中所建三维点云地图是通过D435i深度相机生成，绿色轨迹由无人机实时位置生成，仅用于展示实体无人机在实际环境中的飞行轨迹，不会参与导航策略，有必要说明，无人机在实际飞行中的观测信息比生成的点云地图更为精准。由飞行轨迹可知，将强化学习模型部署于实体无人机后，无人机能够依靠训练所得策略在实际环境下安全完成避障任务。

5 结 论

1）本文提出了一种基于PPO的AR-PPO改进算法，通过引入GRU和动作屏蔽方法设计提高了强化学习模型的策略稳定性与训练效率。

2）设计适用于无人机自主导航的训练环境、观测空间、动作空间、奖励函数，通过改进奖励函数，选择合理的观测空间状态量改善训练效果。

3）通过AirSim仿真训练，无人机在复杂场景中能够迅速获得稳定可行的强化学习策略。将该强化学习模型部署于其他环境中测试，结果表明，该策略能够在不同环境中展现优秀的导航效果。

4）通过消融实验验证AR-PPO算法各组件效果，结果证明各组件能够协同提高算法的训练效率和学习能力。

5）将仿真训练所得强化学习模型部署于实体无人机进行实际测试，结果证明本文方法在实际环境下能够顺利完成避障导航任务。

必须指出，由于缺少全局地图，在新的未知环境中如何提高飞行策略的最优性仍需进一步研究。

参考文献（References）

[1] Han S F, He Y, Fang H, Recent development in automatic guidance and autonomous vehicle for agriculture: a review [J]. Journal of Zhejiang University, 2018, 44(4): 381-391.

[2] 徐国艳, 熊绎维, 周彬, 等. 基于PPO的移动平台自主导航[J]. 北京航空航天大学学报, 2022, 48(11): 2138-2145.
Xu G Y, Xiong Y W, Zhou B, et al. Autonomous navigation based on PPO for mobile platform[J]. Journal of Beijing University of Aeronautics and Astronautics, 2022, 48(11): 2138-2145(in Chinese).

[3] 董豪, 杨静, 李少波, 等. 基于深度强化学习的机器人运动控制研究进展[J]. 控制与决策, 2022, 37(2): 278-292.
Dong H, Yang J, Li S B, et al. Research progress of robot motion control based on deep reinforcement learning[J]. Control and Decision, 2022, 37(2): 278-292(in Chinese).

[4] 户高铭, 蔡克卫, 王芳, 等. 基于深度强化学习的无地图移动机器人导航[J]. 控制与决策, 2024, 39(3): 985-993.
Hu G M, Cai K W, Wang F, et al. Mapless navigation based on deep reinforcement learning for mobile robots[J]. Control and Decision, 2024, 39(3): 985-993(in Chinese).

[5] Marchesini E, Farinelli A. Discrete deep reinforcement learning for mapless navigation[C]//Proceedings of the IEEE International Conference on Robotics and Automation. Piscataway: IEEE Press, 2020: 10688-10694.

[6] Singla A, Padakandla S, Bhatnagar S. Memory-based deep reinforcement learning for obstacle avoidance in UAV with limited environment knowledge[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(1): 107-118.

[7] 魏瑶, 刘志成, 蔡彬, 等. 基于深度循环双 Q 网络的无人机避障算法研究[J]. 西北工业大学学报, 2022, 40(5): 970-979.
Wei Y, Liu Z C, Cai B, et al. Study on UAV obstacle avoidance algorithm based on deep recurrent double Q network[J]. Journal of Northwestern Polytechnical University, 2022, 40(5): 970-979(in Chinese).

[8] 张耀中, 许佳林, 姚康佳, 等. 基于 DDPG 算法的无人机集群追击任务[J]. 航空学报, 2020, 41(10): 309-321.
Zhang Y Z, Xu J L, Yao K J, et al. Pursuit missions for UAV swarms based on DDPG algorithm[J]. Acta Aeronautica et Astronautica Sinica, 2020, 41(10): 309-321(in Chinese).

[9] 唐蕾, 刘广钟. 改进 TD3 算法在四旋翼无人机避障中的应用[J]. 计算机工程与应用, 2021, 57(11): 254-259.
Tang L, Liu G Z. Application for improved TD3 algorithm in obstacle avoidance of quad-rotor UAV[J]. Computer Engineering and Applications, 2021, 57(11): 254-259(in Chinese).

[10] 张云燕, 魏瑶, 刘昊, 等. 基于深度强化学习的端到端无人机避障决策[J]. 西北工业大学学报, 2022, 40(5): 1055-1064.
Zhang Y Y, Wei Y, Liu H, et al. End-to-end UAV obstacle avoidance decision based on deep reinforcement learning[J]. Journal of Northwestern Polytechnical University, 2022, 40(5): 1055-1064(in Chinese).

[11] 赵静, 裴子楠, 姜斌, 等. 基于深度强化学习的无人机虚拟管道视觉避障[J]. 自动化学报, 2024, 50(11): 2245-2258.
Zhao J, Pei Z N, Jiang B, et al. Virtual tube visual obstacle avoidance for UAV based on deep reinforcement learning[J]. Acta Automatica Sinica, 2024, 50(11): 2245-2258(in Chinese).

[12] 寇凯, 杨刚, 张文启, 等. 基于 SAC 的无人机自主导航方法研究[J]. 西北工业大学学报, 2024, 42(2): 310-318.
Kou K, Yang G, Zhang W Q, et al. Exploring UAV autonomous navigation algorithm based on soft actor-critic[J]. Journal of Northwestern Polytechnical University, 2024, 42(2): 310-318(in Chinese).

[13] Yu C, Velu A, Vinitsky E, et al. The surprising effectiveness of PPO in cooperative multi-agent games[C]//Proceedings of the Advances in Neural Information Processing Systems 35. San Diego: Neural Information Processing Systems Foundation, Inc., 2022: 24611-24624.

[14] Dey R, Salem F M. Gate-variants of gated recurrent unit (GRU) neural networks[C]//Proceedings of the IEEE 60th International Midwest Symposium on Circuits and Systems. Piscataway: IEEE Press, 2017: 1597-1600.

[15] Schulman J, Wolski F, Dhariwal P, et al. Proximal policy optimization algorithms[EB/OL]. (2017-07-17)[2024-07-20]. https://arxiv.org/pdf/1707.06347v1.

[16] Baker B, Kanitscheider I, Markov T, et al. Emergent tool use from multi-agent autocurricula[C]//Proceedings of the International Conference on Learning Representations. Appleton: ICLR, 2020.

[17] Ouahouah S, Bagaa M, Prados-Garzon J, et al. Deep-reinforcement-learning-based collision avoidance in UAV environment[J]. IEEE Internet of Things Journal, 2022, 9(6): 4015-4030.

[18] Xue Y T, Chen W S. A UAV navigation approach based on deep reinforcement learning in large cluttered 3D environments[J]. IEEE Transactions on Vehicular Technology, 2023, 72(3): 3001-3014.

[19] Engstrom L, Ilyas A, Santurkar S, et al. Implementation matters in deep RL: a case study on PPO and TRPO[C]//Proceedings of the International Conference on Learning Representations. Appleton: ICLR, 2020.

End-to-end autonomous navigation method for drones based on AR-PPO

LI Hanwei[1], LI Xinkai[1,*], ZHANG Hai[2], JIANG Lingfeng[1], MENG Yue[3], ZHANG Hongli[3]

(1. School of Electrical Engineering, Xinjiang University, Urumqi 830017, China;
2. Engineering Training Center, Xinjiang University, Urumqi 830017, China;
3. School of Intelligent Science and Technology (School of Future Technology), Xinjiang University, Urumqi 830017, China)

Abstract: We propose an end-to-end autonomous navigation method for drones based on action masking-temporal-proximal policy optimization (AR-PPO) to address problems with deep reinforcement learning (DRL) algorithms for drone navigation, such as partial observability of the environment and high training difficulty. First, we introduce a gated recurrent network to process historical information, allowing the policy network to incorporate historical baseline information to tackle the problem of partial observability in complex environments. Second, we design an action masking method suitable for continuous action space reinforcement learning tasks, which excludes the interference of illegal actions and accelerates the model training speed. Then, we establish an actor-critic framework for a three-dimensional continuous action space DRL end-to-end model, which directly outputs control actions based on sensor perception results. Finally, we conduct comparative experiments with mainstream DRL methods. With an over 85% success rate in four generalized test contexts, the AR-PPO approach has the fastest training convergence speed and the largest rewards. Drones can safely perform obstacle avoidance navigation in real machine experiments. The results show that the proposed method effectively enables precise obstacle avoidance and safe navigation for drones.

Keywords: autonomous navigation; deep reinforcement learning; proximal policy optimization; complex environment; drone

Received: 2024-08-02; **Accepted**: 2024-10-30; **Published Online**: 2024-11-07 14:00

URL: link.cnki.net/urlid/11.2625.V.20241107.1129.002

Foundation items: National Natural Science Foundation of China (62263030); Natural Science Foundation of Xinjiang Uygur Autonomous Region (2023D01C187); Tianshan Talents Training Program of Xinjiang Uygur Autonomous Region (2023TSYCCX0037)

* **Corresponding author**. E-mail: lxk@xju.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0569

自适应斥力势场的无人机航迹规划

郭靖[1]，鲜勇[1,*]，任乐亮[1]，李少朋[1,2]

(1. 火箭军工程大学 导弹工程学院，西安 710025；2. 清华大学 自动化学院，北京 100083)

摘 要：针对多障碍复杂场景下传统人工势场(APF)存在的势场函数设计困难、场景适应性差的难题，提出一种基于深度确定性策略梯度(DDPG)算法的三维自适应斥力势场的航迹规划(TAPF)方法。建立基于强化学习的斥力势场学习智能体，实现“端到端”的斥力输出，提高了斥力场的适应性；设计动态三角形描述斥力场范围，有效解决传统圆形斥力场导引的多余路径问题；根据无人机(UAV)航迹规划的特点，设计TAPF方法的状态空间、动作空间及奖励函数。仿真结果表明：所提方法规划出的路径更短，规划效果更优，对于复杂场景适应性具有更好的鲁棒性。

关 键 词：无人机；航迹规划；强化学习；人工势场；神经网络；避障

中图分类号：TB391.9

文献标志码：A **文章编号**：1001-5965(2026)11-3995-14

随着科技的不断进步和无人机(unmanned aerial vehicle, UAV)技术的迅猛发展，无人机在军事侦察[1]、灾害救援[2]、物流配送[3]、农业勘察[4]等多个领域的应用日益广泛，成为现代社会中不可或缺的重要工具。无人机航迹规划技术作为其核心组成部分，对无人机技术的重要性日益显著。该技术不仅关乎任务执行的效率和安全性，还直接影响无人机在复杂环境中的自主飞行能力和适应性。深入研究无人机航迹规划，旨在实现避障同时保证航迹最短，对于推动无人机技术发展，拓展其应用领域，具有重要的理论意义和实践价值。

针对无人机的航迹规划算法，国内外很多研究人员进行了广泛而深入的研究。目前大致可将算法分为两大类：一类是传统算法如Dijkstra算法[5]、A*算法[6]、模拟退火算法[7]、人工势场(artificial potential field, APF)法[8]等；另一类是智能优化算法如遗传算法[9]、蚁群算法[10]、粒子群算法[11]、人工蜂群算法[12]等。而在实际应用过程中，APF法因其实时性高、计算量小、运算速度快等优势，被广泛运用在无人机航迹规划任务中。尽管APF法存在诸如势场函数难以设计、参数凭经验调节等问题，但凭借其实时性的优势得到了许多研究者的关注，众多研究者对其缺陷进行了相应的改进，主要包括以下3方面：①势场函数的改进，文献[13]基于Frenet坐标系统改进斥力场函数，通过引入安全椭圆模型和预测距离概念调整势场影响区域，使车辆能在静态和动态条件下成功避障，文献[14]通过将引力影响因子添加到斥力场的生成中，改进斥力场函数，从而避免引力与斥力合力为零的情况，克服了目标不可达问题；②参数优化与调整，文献[15]利用反向传播(back propagation, BP)神经网络对APF函数的系数进行调整，得到能够自适应环境的系数，再将APF作为神经网络输出端的特征进行提取，提高了算法的适应性，文献[16]通过研究APF引力参数对运动路径的影响，构建了APF因子的模型，利用梯度下降法求解最短路径；③与其他算法结合，文献[17]结合A*算法和APF法，通过调整代价函数和引入偏航引力增益系数，提高了路径规划的安全

收稿日期：2024-07-25；**录用日期**：2024-11-15；**网络出版时间**：2024-12-06 10:59
网络出版地址：link.cnki.net/urlid/11.2625.V.20241205.1253.002
基金项目：国家自然科学基金(62103432)；陕西省高校科协青年人才支持计划(20210108)
*通信作者. E-mail：xy603xy@163.com

引用格式：郭靖，鲜勇，任乐亮，等. 自适应斥力势场的无人机航迹规划[J]. 北京航空航天大学学报，2026，52(11)：3995-4008.
Guo J，Xian Y，Ren L L，et al. Adaptive repulsive potential field for UAV trajectory planning[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：3995-4008 (in Chinese).

性和效率，文献[18]通过精选路径中间点，并仅保留APF法中对目标点的引力作用，为蚁群算法提供路径规划启发，还显著降低了初始阶段路径搜索的随机性，从而实现了算法的快速收敛。

随着人工智能技术的持续进步，机器学习算法已经成为无人机航迹规划领域的关键驱动力。这些算法通过从大量数据中学习并优化决策过程，显著提升了无人机在复杂环境中的航迹规划能力。许多学者结合强化学习算法和APF法进行了相关研究，文献[19]提出了一种基于改进近端策略优化(proximal policy optimization, PPO)算法的智能决策算法，通过引入自适应学习率和状态空间压缩技术，提高了算法在复杂环境中的收敛速度、稳定性和适应性。文献[20]提出了一种改进深度确定性策略梯度(deep deterministic policy gradient, DDPG)算法，通过将势场信息引入到奖励函数中，提高了无人机在复杂三维环境中在线轨迹规划的能力。与传统算法相比，强化学习算法在路径规划中提供了显著的优势，包括更强的环境适应性和灵活性，能够自主学习并优化复杂的决策过程，同时在不断变化的环境中实时调整策略以避免障碍和减少风险。不少研究人员利用这些优势对APF法进行改进，通过学习调整增益系数来提高APF法面对复杂环境时的适应能力。文献[21]采用深度学习优化斥力系数以适应动态环境。结合遗传算法和APF法，以找出特定环境下的最佳斥力系数。随后用这些系数训练一个残差神经网络，使其能够预测出变化环境中所需的斥力系数，生成更加高效和适应性强的无人机飞行路径。文献[22]通过双延迟深度确定性策略梯度(twin delayed deep deterministic policy gradient, TD3)算法对类似APF法的扰动流体算法系数进行训练，得到适应环境的系数组合，再结合扰动流体法进行规划，在满足任务需求的前提下提高了算法的环境适应性。

用强化学习算法学习得到适应环境的系数虽然一定程度上能够解决APF法的缺陷，但在面对复杂环境时，自适应系数能够调整的能力与范围有限，且APF法的势场函数大多靠经验进行设计，环境适应性较差。而使用强化学习算法直接学习APF的势场函数相比于学习斥力增益系数，有2点优势：① 摒弃了依赖人工设定和调整势场参数的繁琐过程，转而采用端到端的自适应函数学习方法，该方法使算法能够直接从环境数据中学习并适应最佳的斥力势场，无需外部干预，显著提升了算法的适应性和泛化能力；② 通过利用神经网络强大的非线性拟合能力，不仅学习到了具体的势场函数，还隐式地优化了势场中的参数配置，相比传统的学习参数方法，这种方式虽然可能在训练阶段需要更多的计算资源，但其在处理复杂多变的场景时，展现出了更高的效率和更强的适应性。

针对上述分析，本文提出一种基于深度确定性策略梯度算法的三维自适应斥力势场的航迹规划(three-dimensional self-adaptive repulsive potential field trajectory planning, TAPF)方法，通过建立端到端的强化学习模型直接输出斥力的大小，摆脱了对人工设计的依赖，增强了对环境的适应能力。另外，提出并设计了三角斥力势场，解决了避障结束后持续受到斥力使路径过长的问题。实验结果表明，本文方法能更有效地应对复杂飞行场景，生成更高质量的安全航迹，满足巡航导弹对航迹规划的快速性和准确性要求。

1 无人机航迹规划问题描述

无人机的航迹规划就是在给定无人机起始点、目标点、飞行环境信息(包括地形、障碍物、禁飞区等)及无人机的性能参数的条件下，寻找一条从起始点到目标点的最优或可行飞行路径。

1.1 无人机运动学约束

由于无人机在飞行过程中受自身性能参数和气动特性的限制，需要考虑的性能约束主要包括最大航程、最大转弯角、最短直行距离、最大俯仰角和最小飞行高度等约束条件。

1) 最大航程约束。无人机所携带的能量是有限的，这就直接限制了其续航能力，即无人机能够达到的最大航程$S_{\max}$。因此，在进行航迹规划时，必须考虑到这一关键的航迹距离约束，假定无人机的任务航程为L。假设航迹点共有n个，无人机的任务航程L满足：

$$\begin{cases} L \leqslant S_{\max} \\ \sum_{i=1}^{n} l_i \leqslant L \\ l_i = V\Delta t \end{cases} \tag{1}$$

式中：l_i为单个节点的航程；V为无人机的飞行速度；Δt为决策周期。

2) 最大转弯角约束。假设无人机实际转弯角为α_i，限制条件下的最大转弯角为$\alpha_{\max}$，这种限制条件可以用数学公式来表达，即

$$\begin{cases} \alpha_i = \dfrac{\boldsymbol{A}_i^{\mathrm{T}}\boldsymbol{A}_{i+1}}{\|\boldsymbol{A}_i\|_2\|\boldsymbol{A}_{i+1}\|_2} \\ -\alpha_{\max} \leqslant \alpha_i \leqslant \alpha_{\max} \end{cases} \tag{2}$$

式中：$\boldsymbol{A}_i$为第i段航程在水平地面上的投影向量，

$\boldsymbol{A}_i=(x_i-x_{i-1},y_i-y_{i-1})$; $\alpha_{\max}$为最大转弯角。转弯角α_i约束如图 1 所示。

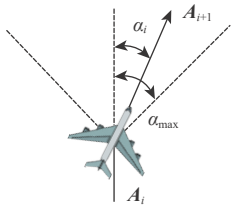


图 1　转弯角约束

Fig. 1　Yaw angle constraint

3) 飞行高度约束。综合考虑安全性和性能因素, 无人机在飞行过程中需严格遵守一定的高度范围。飞行高度约束为

$$h_{\min}<h<h_{\max} \tag{3}$$

式中: h为无人机飞行高度; $h_{\min}$为无人机离地面最低飞行高度; $h_{\max}$为无人机最大可飞高度。

4) 最大俯仰角约束。为确保飞行安全, 无人机在飞行过程中的俯仰角必须控制在一定范围内, 即不得超过其最大允许俯仰角$\gamma_{\max}$。转弯角与俯仰角的关系如图 2 所示, 俯仰角的约束条件为

$$\frac{|z_i-z_{i-1}|}{\sqrt{|(x_i-x_{i-1})^2+(y_i-y_{i-1})^2|}}\leqslant\tan\gamma_{\max}\quad i=2,3,\cdots,n \tag{4}$$

式中: z_i为第i段航程起始高度; $\gamma_{\max}$为最大俯仰角。

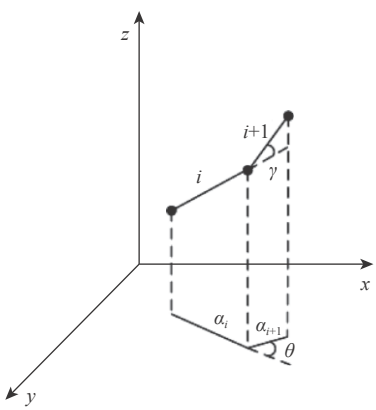


图 2　俯仰角和转弯角关系示意图

Fig. 2　Schematic diagram of relationship between pitch and deflection angles

1.2　无人机飞行环境建模

假设$A(x,y)$为规划空间中的任意一点, x,y分别为横、纵坐标, 则二维规划空间可以表示为

$$\{(x,y)|x_{\min}\leqslant x\leqslant x_{\max},y_{\min}\leqslant y\leqslant y_{\max}\} \tag{5}$$

本文提出的基于 DDPG 算法的 TAPF 方法建立在连续环境空间和动作空间的基础上, 智能体可以位于环境中的任何位置, 在满足动作约束的区间范围可以朝任何方向运动, 采用矢量图方法进行建模更为简便。如图 3 所示, 将平面投影为圆形的防空阵地和预警探测雷达分别以最大打击半径和最大探测半径处理为不可触碰的圆形障碍物; 将不规则障碍物向外进行膨化扩充, 并以其最小外界圆为半径, 同样处理为圆形障碍物, 以保证航迹与威胁源存在一定间隔。

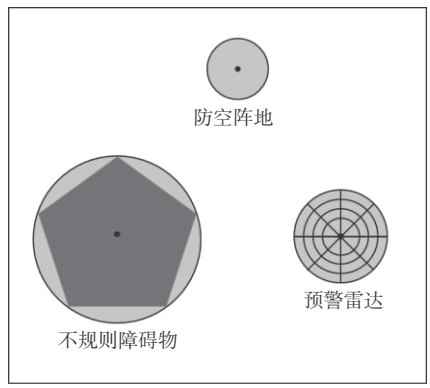


图 3　矢量环境地图

Fig. 3　Vectorized environmental map

2　本文算法原理

2.1　APF 法

APF 法是路径规划任务中常用的一种算法。其核心思想是在空间中引入势场, 即目标点产生引力势场, 障碍物产生斥力势场, 通过 2 个势场力的作用引导无人机避开障碍物, 到达目标点。

2.1.1　引力势场

在 APF 法中, 引力场源只有目标点, 目标点对轨迹上的点产生引力作用从而使轨迹向其汇合。一种常见的引力场计算方式为

$$U_{\text{att}}(\boldsymbol{P})=\frac{1}{2}\xi\|\boldsymbol{P}-\boldsymbol{P}_{\text{g}}\|_2^2 \tag{6}$$

式中: U_{att}为引力场; ξ为引力增益系数; $\boldsymbol{P}$为当前位置; $\boldsymbol{P}_{\text{g}}$为目标点位置。

根据引力势场表达式, 可以求出引力为

$$F_{\text{att}}=-\nabla U_{\text{att}}=\xi\|\boldsymbol{P}-\boldsymbol{P}_{\text{g}}\|_2 \tag{7}$$

当空间中一点坐标$\boldsymbol{P}$与目标点坐标$\boldsymbol{P}_{\text{g}}$的欧氏距离越大时, 引力越大, 引力场模型如图 4 所示。随着引力增益系数的增加, 引力场模型示意图由原来平缓的曲面变为较为陡峭的曲面, 有利于引导无人机更快地到达目标点。

2.1.2　斥力势场

针对空间中存在的每一个障碍物, 引入斥力场来修正原始轨迹, 轨迹与障碍物表面距离越小斥力场越大, 当距离超过一定范围时可以不用考虑斥力的影响, 使轨迹沿直线向目标点移动, 从而可以使

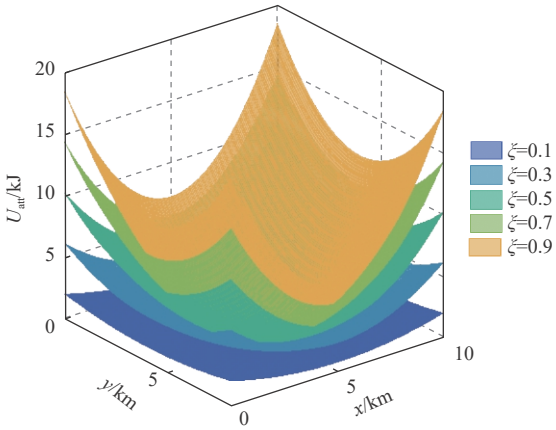


图4 不同引力增益系数下引力场模型示意图

Fig. 4 Schematic diagram of gravitational field model with different gravitational gain coefficients

轨迹长度减小。根据以上描述，一种常见的斥力场计算方式为

$$U_{rep}=\begin{cases}\dfrac{1}{2}\eta\left(\dfrac{1}{\|\boldsymbol{P}-\boldsymbol{P}_{obs}\|_2}-\dfrac{1}{\rho_0}\right)^2 & \|\boldsymbol{P}-\boldsymbol{P}_{obs}\|_2\leqslant\rho_0\\ 0 & \|\boldsymbol{P}-\boldsymbol{P}_{obs}\|_2>\rho_0\end{cases}\quad(8)$$

式中：U_{rep}为斥力场；η为斥力增益系数；$\boldsymbol{P}_{obs}$为障碍物中心坐标；ρ_0为斥力作用范围。

根据斥力势场表达式，可以求出斥力为

$$F_{rep}=-\mathrm{grad}(U_{rep}(\boldsymbol{P}))=\begin{cases}\eta\left(\dfrac{1}{\|\boldsymbol{P}-\boldsymbol{P}_{obs}\|_2}-\dfrac{1}{\rho_0}\right)^2 & \|\boldsymbol{P}-\boldsymbol{P}_{obs}\|_2\leqslant\rho_0\\ 0 & \|\boldsymbol{P}-\boldsymbol{P}_{obs}\|_2>\rho_0\end{cases}\quad(9)$$

斥力场模型如图5所示，随着斥力增益系数的增大，斥力场模型示意图中的斥力场强度显著增强。从较低的增益系数开始，斥力场的峰值逐渐升高，当增益系数达到较高水平时，斥力场的峰值也达到较高水平。

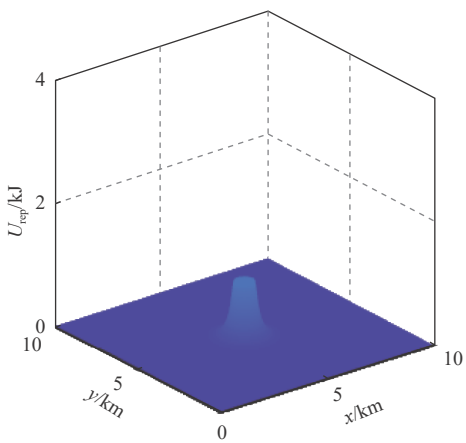
通常情况下，在无人机的路径规划问题中，存在一个目标点和一个或多个障碍物，因此，无人机所受到的合势场为

$$U_{all}=U_{att}(\boldsymbol{P})+\sum U_{rep}(\boldsymbol{P})\quad(10)$$

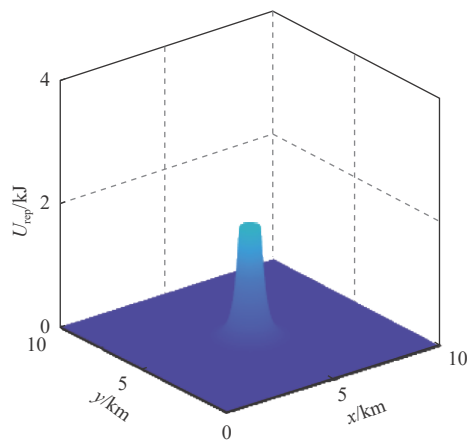
同样合力也为引力与斥力的叠加，无人机受到的合力为

$$F_{all}(\boldsymbol{P})=F_{att}(\boldsymbol{P})+\sum F_{rep}(\boldsymbol{P})\quad(11)$$

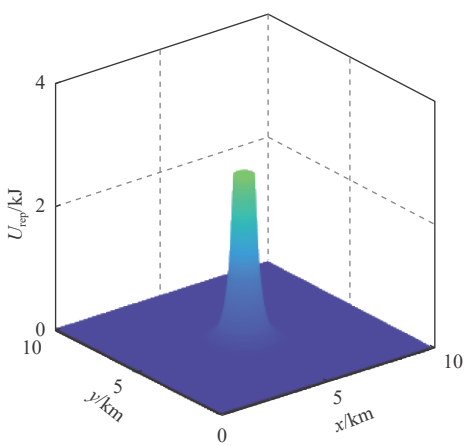
合势场模型如图6所示。可以看到，合势场在



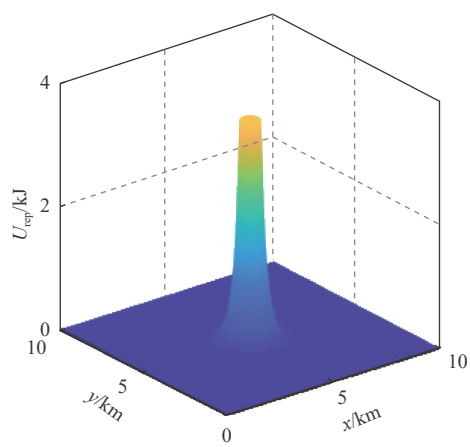
(a) η=0.5, $U_{rep,max}$=0.9 kJ



(b) η=1, $U_{rep,max}$=1.8 kJ



(c) η=1.5, $U_{rep,max}$=2.7 kJ



(d) η=2, $U_{rep,max}$=3.5 kJ

图5 不同斥力增益系数下斥力场模型示意图

Fig. 5 Schematic diagram of repulsive force field model with different repulsive force gain coefficients

障碍物附近隆起, 并同时向目标点位置凹陷, 从而引导轨迹在避障的同时向目标点移动。

2.2　DDPG 算法理论

DDPG 算法是一种确定性策略强化学习算法。相较于随机策略算法学习在某个状态下采取动作的概率分布而言, DDPG 算法会直接给出在该状态下的动作。确定性策略具有收敛速度快、学习效率高等优势, 但另一方面, 确定性策略相比随机策略缺少一些对环境的探索性, 因此, 确定性策略往往需要在采集数据阶段引入噪声来增强算法探索性。本文在测试了各种主流强化学习算法解决本文提出的航迹规划问题后, 综合考虑最终选择 DDPG 算法作为改进算法的底层算法。图 7 给出了本文算法的框图。

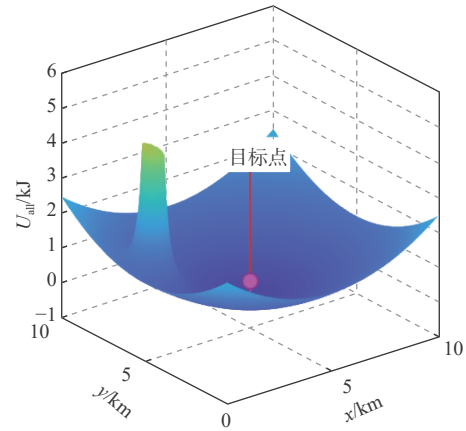


图 6　引力场与斥力场的叠加场模型示意图(单个斥力场)

Fig. 6　Schematic diagram of superimposed field model of gravitational and repulsive fields (single repulsive field)

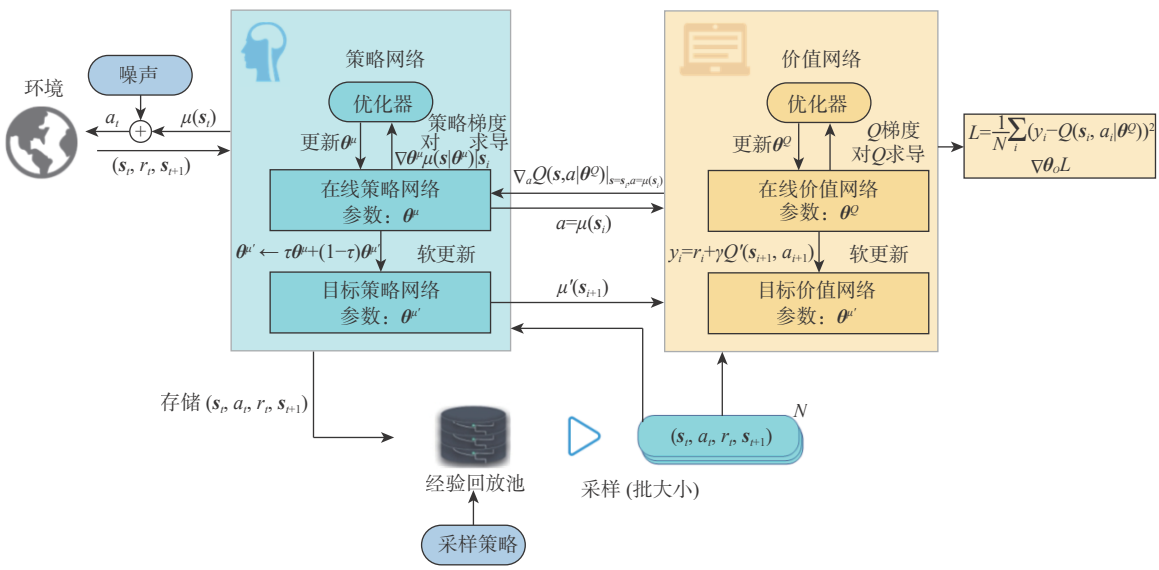


图 7　本文 DDPG 算法框图

Fig. 7　Detailed block diagram of the DDPG algorithm

3　自适应势场航迹规划

本文将障碍物看作强化学习的智能体, 通过在环境中与 UAV 的交互数据学习如何控制其产生的斥力场大小, 并学习障碍物之间如何通过合作产生叠加斥力场使 UAV 的规划航迹达到理想的最佳状态。将深度强化学习算法与 APF 算法结合得到本文提出的三维自适应势场航迹规划方法。值得注意的是, 本文 TAPF 方法由于其自身的斥力场会随着 UAV 的位置不同而不同, 因此, 其局部最小值点位也会随之改变, 且在训练模型时落入局部最小值区域后, 智能体会受到一定的惩罚, 因此, 本文 TAPF 方法有效避免了各类势场算法都存在的共性问题——局部最小值问题。另一方面, 通过学习训练直接输出斥力的大小, 解决了势场函数设计及参数调节困难的问题。

3.1　本文方法主要框架

在本文 TAPF 方法中, APF 为规划层, 负责航路的最终规划, 强化学习模型为学习与决策层, 通过大量智能体与环境交互的数据学习如何控制斥力场的大小。本文 TAPF 方法框架如图 8 所示, 其中, $\boldsymbol{P}$ 表示位置坐标, $\boldsymbol{s}$ 表示相对位置。UAV 在三维空间中某一点通过雷达等手段接收到障碍物的相对位置 $\boldsymbol{s}_{obsi}$ 及目标的相对位置 $\boldsymbol{s}_{goal}$, 将其输入对应障碍物的强化学习策略网络, 可得到对应障碍物在当前环境状态下决策出的斥力 F_{repi}, 重复该步骤可在 t 时刻得到所有障碍物的斥力 F_{rep}, 将其作为强化学习的动作输入规划层, 计算得到 UAV 的下一航路点, 并返回从状态 $\boldsymbol{s}_t$ 到 $\boldsymbol{s}_{t+1}$ 的奖励值 r_t, TAPF 方法将动作、状态、奖励存储到对应障碍物的数据缓存中, 以便模型之后的学习。为简化不必要的问题, 本文采用无限高圆柱体模拟障碍物。

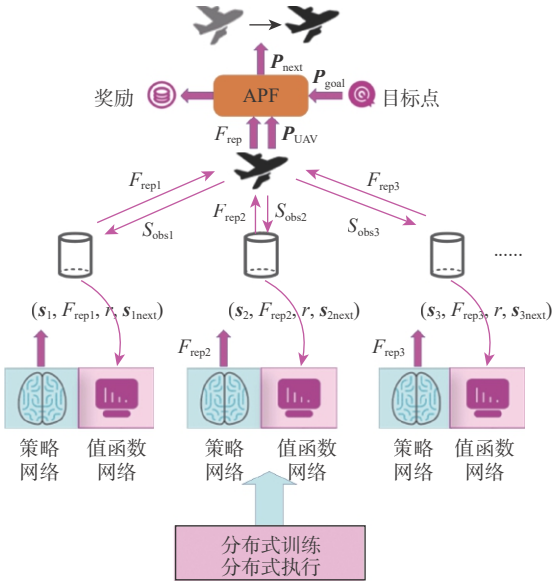


图 8 本文 TAPF 方法实现框架

Fig. 8 The TAPF method implementation framework

3.2 马尔可夫决策过程设计

无人机路径规划中的强化学习要素主要包括状态空间、动作空间和奖励函数。

1）状态空间。作为强化学习模型策略的输入，定义状态$\boldsymbol{s}$为三维空间中障碍物相对 UAV 的位置及目标点相对于 UAV 的位置：

$$\boldsymbol{s}=(\Delta x_{\text{obs}},\Delta y_{\text{obs}},\Delta z_{\text{obs}},\Delta x_{\text{goal}},\Delta y_{\text{goal}},\Delta z_{\text{goal}}) \tag{12}$$

式中：$(\Delta x_{\text{obs}},\Delta y_{\text{obs}},\Delta z_{\text{obs}})$为障碍物与 UAV 的相对位置；$(\Delta x_{\text{goal}},\Delta y_{\text{goal}},\Delta z_{\text{goal}})$为目标点与 UAV 的相对位置。

2）动作空间。基于无人机的运动学模型和 APF 法，本文主要学习 APF 法的斥力势场，因此，输出为斥力，可得

$$a=F_{\text{rep}}(\boldsymbol{P}) \tag{13}$$

式中：$F_{\text{rep}}(\boldsymbol{P})$为当前位置所受斥力的大小。

3）奖励函数。强化学习的奖励机制是影响算法学习效果至关重要的因素，奖励值需体现待解决问题的关键表征。另外，多个奖励值之间需统一数值范围，奖励方差应该尽量小，这可以避免累计奖励值的大幅度振荡，提升学习效率。一条拥有高性能指标的航路往往需满足轨迹平滑、距离较短、不与障碍物有交点等条件，而平滑性问题在基础的 APF 算法中已经基本保证，且经过大量实验，在航路距离较短的情况下往往能兼顾平滑性的要求，因此，奖励中将不再考虑平滑性约束。综上所述，本文设计了如下奖励机制：

$$R_t(a_t|\boldsymbol{s}_t)=\lambda_1R_1+\lambda_2R_2+\lambda_3R_3 \tag{14}$$

式中：λ_1、λ_2、$\lambda_3>0$为加权因子；R_1为避障奖励；R_2为航迹奖励；R_3为航向奖励。

若下一航路点$\boldsymbol{P}_{t+1}$与障碍物有交点时，对智能体进行惩罚：

$$R_1=-\frac{\|\boldsymbol{P}_{t+1}-\boldsymbol{O}_{\text{obs}}\|_2}{R_{\text{obs}}}-C_0 \quad \|\boldsymbol{P}_{t+1}-\boldsymbol{O}_{\text{obs}}\|_2\leqslant R_{\text{obs}} \tag{15}$$

式中：$\boldsymbol{O}_{\text{obs}}$为与航路有交点的障碍物“中心”，圆柱体障碍物取其水平截面圆的圆心；R_{obs}为障碍物半径，圆柱体取其水平截面圆的半径；C_0为常数惩罚项$(C_0>0)$，有助于智能体快速认识到其规划航路不满足碰撞检测。

若下一航路点$\boldsymbol{P}_{t+1}$与障碍物无交点时，设置的奖励值应该倾向于优化航路长度：

$$R_2=\begin{cases}-\dfrac{\|\boldsymbol{P}_{t+1}-\boldsymbol{P}_{\text{g}}\|_2}{\|\boldsymbol{P}_0-\boldsymbol{P}_{\text{g}}\|_2} & \|\boldsymbol{P}_{t+1}-\boldsymbol{P}_{\text{g}}\|_2>\varepsilon\\ -\dfrac{\|\boldsymbol{P}_{t+1}-\boldsymbol{P}_{\text{g}}\|_2}{\|\boldsymbol{P}_0-\boldsymbol{P}_{\text{g}}\|_2}+C_1 & \|\boldsymbol{P}_{t+1}-\boldsymbol{P}_{\text{g}}\|_2\leqslant\varepsilon\end{cases} \tag{16}$$

式中：$\|\boldsymbol{P}_{t+1}-\boldsymbol{P}_{\text{g}}\|_2$表示下一航路点与目标点的距离；$\|\boldsymbol{P}_0-\boldsymbol{P}_{\text{g}}\|_2$表示从起始点到目标点的距离；$\varepsilon$为小常数，用于判断$\boldsymbol{P}_{t+1}$是否已经抵达目标点附近，若到达，则额外奖励$C_1(C_1>0)$。

为避免无人机在避障时偏转角度过大、飞行距离增加，设计了航向奖励，当无人机偏离目标方向时，给予惩罚。表达式为

$$R_3=-0.1\frac{|\varphi|}{\pi} \tag{17}$$

式中：$|\varphi|$为无人机航向与目标点方向之间的夹角。

3.3 斥力势场改进

在传统的 APF 中，由斥力势场的表达式可知，无人机与障碍物之间的距离越近，所受到的斥力越大。当无人机进入斥力势场影响范围内时即受到障碍物的斥力，直到无人机飞离斥力影响范围，这会导致无人机在绕开障碍物时产生多余的避障路径。如图 9 所示，无人机此时已完成避障，但仍处于斥力影响范围内，会受到斥力的作用，产生多余的飞行距离。

本文对斥力势场影响范围进行改进，提出一种三角势场，即当无人机进入障碍物斥力影响范围时，判断无人机飞行方向是否位于当前位置与障碍物 2 条切线的夹角之间。若飞行方向位于切线夹角间，无人机受到斥力作用，绕开障碍物；若飞行方向在切线夹角之外，无人机尽管处于斥力影响范围内，但位于三角区外，此时不受斥力，仅受目标引力作用。与传统的斥力势场相比，该三角势场使无人机的路径明显缩短。三角势场如图 10 和图 11 所示。

当无人机进入障碍物斥力范围内时，判断此时飞行方向与当前位置到障碍物圆心向量的夹角是否小于 90°。若夹角大于 90°，则不受障碍物斥力，若夹角小于 90°，则判定为进入三角区斥力势场。设无人机的方向向量为$\boldsymbol{A}$，当前位置点到障碍物圆

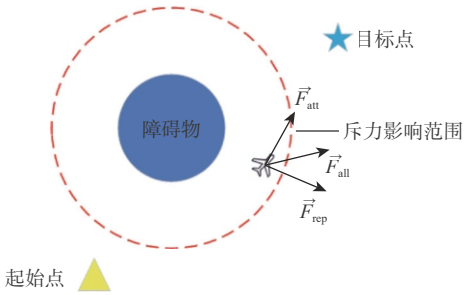


图 9　APF 算法原理图

Fig. 9　Schematic diagram of APF algorithm

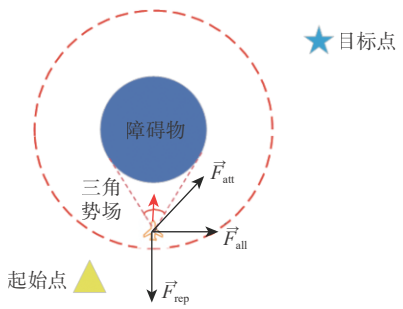


图 10　无人机进入三角势场

Fig. 10　UAV entry triangle potential field

的两条切线向量分别为$\boldsymbol{B}$和$\boldsymbol{C}$, 若航向角在两条切线形成的夹角之间, 则受到三角区势场的斥力, 若不在切线夹角之间, 则无人机不受斥力, 如下:

$$F_{rep}=\begin{cases}\eta\left(\dfrac{1}{\|\boldsymbol{P}-\boldsymbol{P}_{obs}\|_2}-\dfrac{1}{\rho_0}\right)^2 & (\boldsymbol{A}\times\boldsymbol{B})(\boldsymbol{A}\times\boldsymbol{C})>0\\ 0 & (\boldsymbol{A}\times\boldsymbol{B})(\boldsymbol{A}\times\boldsymbol{C})\leqslant 0\end{cases} \tag{18}$$

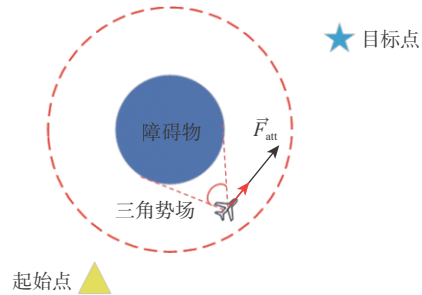


图 11　无人机离开三角势场

Fig. 11　UAV departure triangle potential field

3.4　训练流程设计

在本文 TAPF 方法的训练过程中, 无人机通过在环境中进行探索, 根据环境的反馈不断学习更加正确的策略, 训练流程如图 12 所示。无人机首先将自身位置、障碍物位置、目标点和地形等数据作为状态空间, 通过学习到的策略和噪声生成动作。在执行完动作后, 会对无人机是否到达目标点或发生碰撞进行判定, 若发生碰撞或到达目标点, 则初始化环境后重新开始训练, 若未发生碰撞或未到达目标点, 则通过奖励函数获得奖惩值, 用于更新神经网络, 重复训练过程, 直至网络收敛。

3.5　相关参数设计

在飞行参数方面, 三维航迹规划需要考虑无人机飞行的最小飞行高度h_{min}, 结合实验中地形模型数据与无人机的性能参数, 设定h_{min} = 1 km, 同时, 无人机最大离地飞行高度的期望值h_{max}=2 km。假设无人机全程以速度大小V做定速飞行, 且每个时间步为定值Δt, 因此, 各航迹段的长度l_i亦为定值,

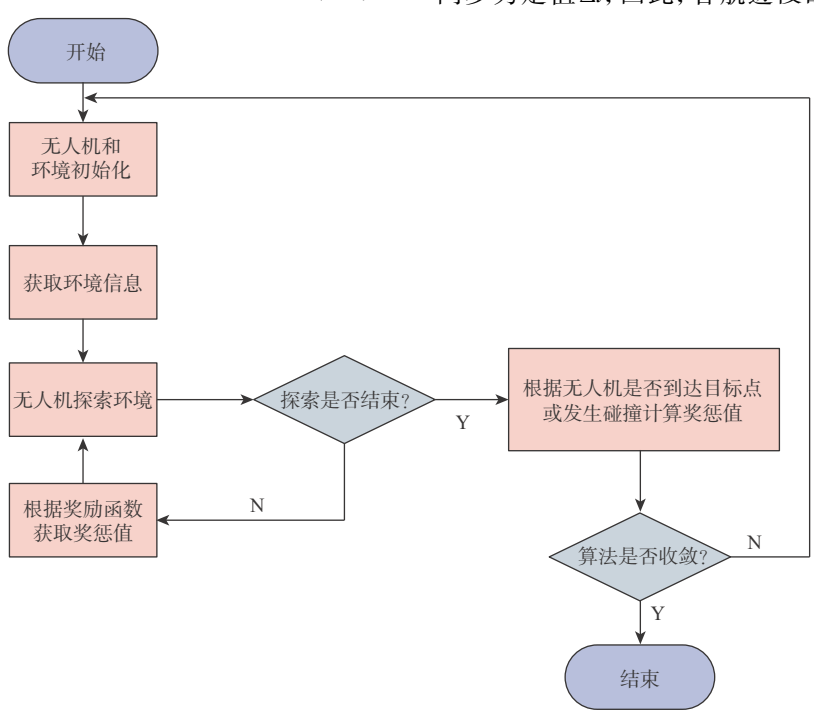


图 12　本文方法流程图

Fig. 12　The proposed method flow chart

即智能体的搜索步长一定，本节实验中设定为500 m。综合考虑航迹的平滑性、机动性及无人机的自身性能特性，设定转弯角α的取值范围为$[-15°,15°]$，俯仰角γ的取值范围为$[-6°,6°]$。

在APF参数设计方面，目标引力势场与障碍物斥力势场同样存在于整个三维规划空间中。设引力势场增益系数$k_{att}=2$，障碍物的斥力势场影响范围$\rho_0=1$ km。

在强化学习算法方面，本文使用基于PyTorch框架搭建的深度强化学习算法进行实验优化，主要参数设定如表1所示。

表1 本文DDPG算法参数

Table 1 Parameters of the DDPG algorithm

学习率	折扣系数	经验池容量	批处理数据	训练总步数	测试回合数
0.000 3	0.99	10^6	256	1 000	1 000

4 仿真实验与分析

4.1 实验设计

在三维在线航迹规划的实验中，设有训练环境和测试环境，并分别使用本文TAPF方法和自适应斥力参数人工势场(adaptive repulsive parameter artificial potential field, ARP-APF)方法[23]进行训练和测试，分析对比实验结果，同时指出算法改进后的优势所在。

4.1.1 训练环境

实验中地形模型构建采用数字高层模型(digital elevation model, DEM)，并采用双线性插值的方法计算非格网点的高程数据。如图13所示，飞行环境的大小为100 km×100 km，其水平维度上相邻网格数据点的间隔距离为20 km，垂直方向上相邻网格点间隔距离为1 km。

如图14所示，本实验以地形曲面为底面、以环境限高为高度随机构建2～5个位置不同的品红色圆柱障碍物模型，其截面圆的半径大小等于各威胁源的半径r_o，本实验中统一设定为1 km。起始点为红色圆，坐标值为(0, 0, 2) km，目标点为红色三角形，坐标值为(100, 100, 1) km。

4.1.2 测试环境

测试环境有3个，测试环境设置与训练实验环境相似。其中，地形环境模型都是以DEM为基础构建的100 km×100 km三维地形模型，但环境中威胁圆柱设置的大小、数量和位置有所不同。

测试环境1为固定半径障碍物的环境，如图15所示，该环节中共设置500次包含6个位置不同、半径相同的固定品红色圆柱，其中一个场景如图15所示，各圆柱中心线的水平二维坐标分别为：(55, 55) km、(63, 72) km、(32, 64) km、(30, 22) km、(45, 39) km、(58, 36) km，半径均为6 km。该环境的目的在于测试算法在路径规划上相较于其他算法具有更优的性能。

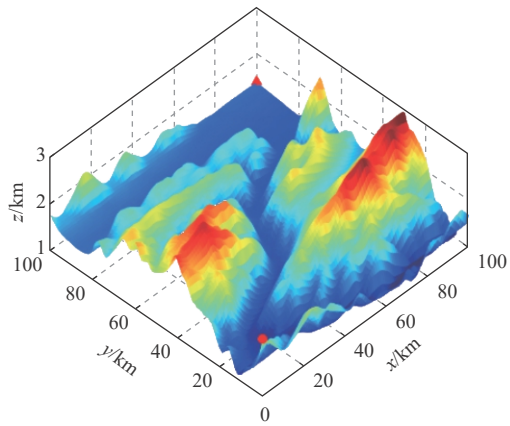


图13 三维地形模型

Fig. 13 Three-dimensional terrain model

测试环境2为与训练环境不同的随机半径障碍物的陌生环境。部分场景如图16所示，该环境中共设置500次包含6个位置不同、半径大小不一的圆柱障碍物。该环境的目的在于测试算法对于存在不同半径障碍物的陌生环境的泛化性和可靠性。

测试环境3为随机位置、固定半径障碍物的陌生环境。该环境中共设置500次包含2～6个位置不同的圆柱障碍物。该环境的目的在于测试三角区势场对于减少APF法多余路径的效果。

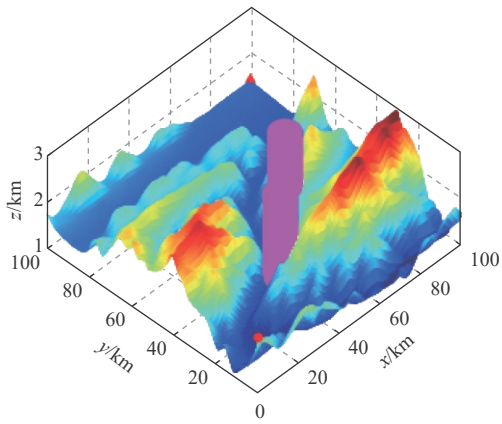
4.2 训练实验

实验中使用ARP-APF方法和本文提出的TAPF方法在随机2～6个障碍物环境中训练1 000个回合，以50回合为单位进行滑动平均处理后，得到奖励值变化曲线，如图17所示。可以看出，本文TAPF方法能够生成曲线的奖励值相对更高，且本文TAPF方法收敛速度比ARP-APF方法更快，接近200回合时就能够收敛。另外，本文TAPF方法的收敛稳定性更好，其收敛后曲线的波动相对原APF算法更小。综上所述，在训练实验中，相对原APF算法而言，本文TAPF方法的收敛稳定性更好，航迹规划能力有所提升。

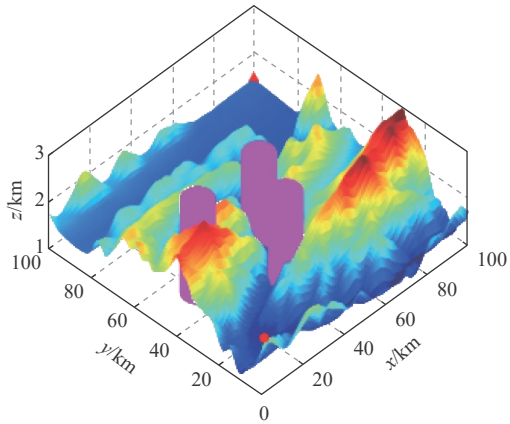
4.3 测试实验

4.3.1 固定半径障碍物环境的测试实验

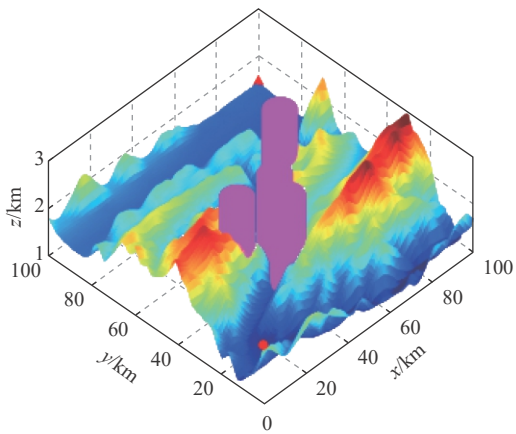
在陌生固定障碍物环境的测试实验中，分别将本文TAPF方法、ARP-APF方法及改进的APF(improve APF, IAPF)法[24]在测试环境1中测试500次，分别以平均成功率M_s、平均奖励M_r、平均距离M_l、平均规划用时M_t、平均水平机动角M_{turn}为指标统计实验结果，同时输出测试的航迹图。其



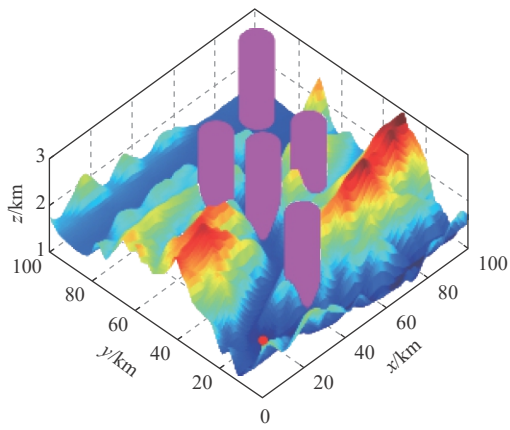
(a) 训练环境三维模型1



(b) 训练环境三维模型2



(c) 训练环境三维模型3



(d) 训练环境三维模型4

图 14　训练环境三维模型

Fig. 14　Three-dimensional model of training environment

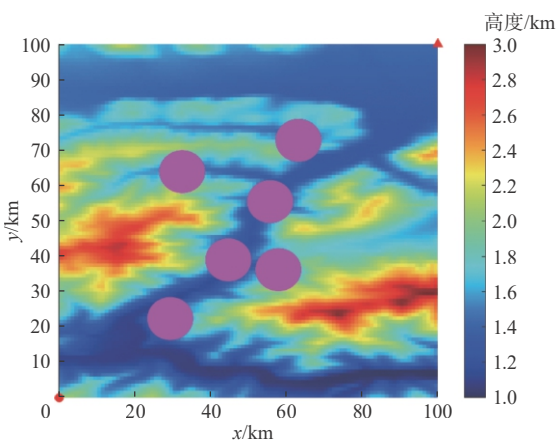


图 15　测试环境 1 模型俯视图

Fig. 15　Top view of test environment 1 model

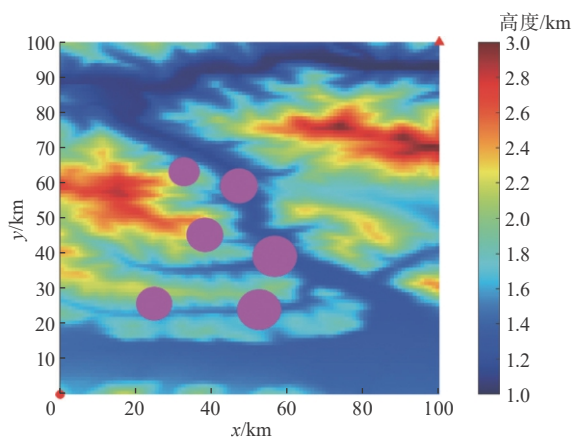


图 16　测试环境 2 模型俯视图

Fig. 16　Top view of test environment 2 model

中, 测试实验中各方法的指标如表 2 所示。

由表 2 可以看出, 在平均转弯角方面, 本文 TAPF 方法生成的航迹机动值明显小于 ARP-APF 方法和传统的 IAPF 法; 同时, 由于机动幅度变小, 生成的航迹更短, ARP-APF 方法平均需要 363.3 km 才能到达目标, 而本文的 TAPF 方法平均只需要 304.5 km 即可到达, 整体降低约 16.2%。此外, 从平均奖励值指标可以看出, 本文 TAPF 方法能够根据飞行环境的实际情况得出更为优秀的动作, 进而航迹的总奖励值也更大。由此, 在测试实验的陌生障碍物环境条件下, 本文 TAPF 方法进行三维在线航迹规划时比 ARP-APF方法和 IAPF 方法具有更优秀的表现。

从图 18 和图 19 的无人机三维航迹中可以看出, 本文 TAPF 方法机动幅度更小, 生成的路径更为平滑, 该结果与表 2 中的数据相符。

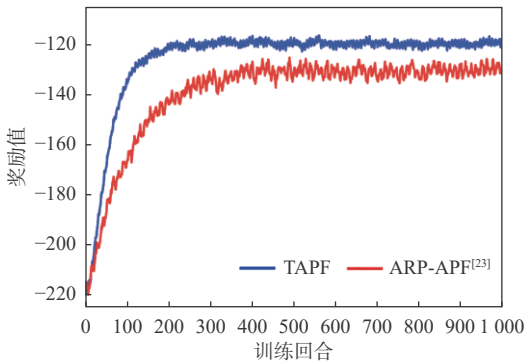


图 17 训练奖励值变化曲线

Fig. 17 Change curves of training reward value

4.3.2 随机半径障碍物环境的测试实验

测试环境 2 中的障碍物半径随机，在该随机半径障碍物的环境中测试 500 次后，统计各实验指标结果，如表 3 所示。可以看出，ARP-APF 方法和 IAPF 方法的成功率有所下降，但本文 TAPF 方法的成功率依然是 100%，具有较好的泛化性。由于障碍物影响，智能体在 2 种方法下都需要进行避障，因此，2 种方法的航迹长度、规划时间和机动值大小都有所增加。但本文 TAPF 方法规划出的航迹无论在航迹长度、奖励值大小还是平滑性方面都更好。

表 2 测试环境 1 中指标对比

Table 2 Comparison of metrics in test environment I

方法	M_s/%	M_r	M_l/km	M_t/s	M_{turn}/(°)
TAPF	100.0	−123.4	304.5	0.70	43.52
ARP-APF[23]	99.4	−137.3	363.3	0.80	59.01
IAPF[24]	97.0		424.5	0.65	75.32

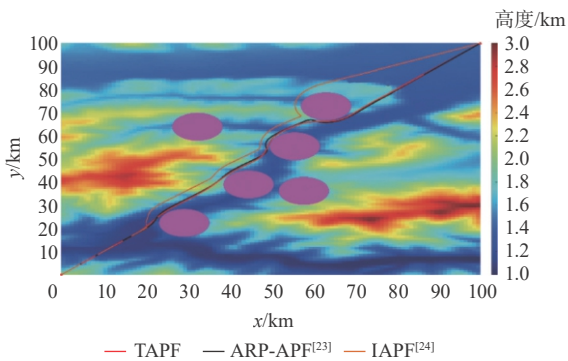


图 18 测试环境 1 中三维航迹俯视图 (测试 1)

Fig. 18 Top view of 3D trajectory in test environment 1

综合上述结果分析，本文 TAPF 方法在陌生环境中的在线航迹规划能力优于 ARP-APF 方法和 IAPF 方法，且能够稳定快速地生成更优的航迹。

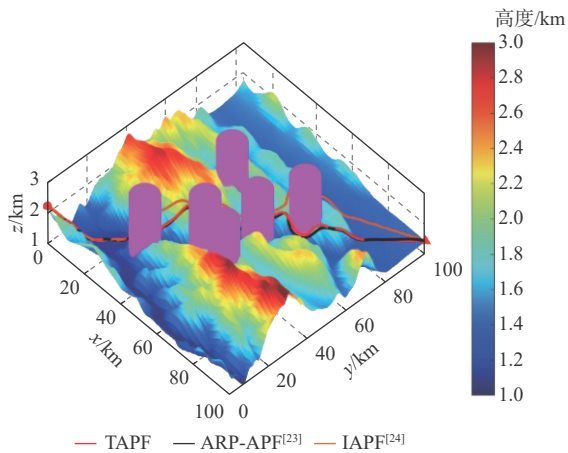


图 19 测试环境 1 中三维航迹模型图 (测试 1)

Fig. 19 Three-dimensional trajectory model map in test environment 1

表 3 测试环境 2 中指标对比

Table 3 Comparison of metrics in test environment 2

算法	M_s/%	M_r	M_l/km	M_t/s	M_{turn}/(°)
TAPF	100.0	423.40	327.2	0.70	21.62
ARP-APF[23]	99.4	337.35	384.3	0.80	37.82
IAPF[24]	95.2		456.4	0.63	68.40

3 种算法的航迹图如图 20 所示。可以明显看出，无论是从竖直维度还是从水平维度来看，TAPF 方法的机动幅度明显更小，路径具有更好的平滑性。

4.3.3 三角区斥力势场的测试实验

为测试三角区势场对于减少 APF 法多余路径的效果，设计了测试实验 3。测试环境 3 中随机生成 3～6 个半径相同的障碍物，分别采用本文 TAPF 方法和 IAPF 方法在同一环境中进行测试实验，统计各实验指标结果，如表 4 所示。可以看出，本文 TAPF 方法通过改进的三角区斥力势场规划出的路径长度较优化的 APF 法更短，且平均水平机动角更小。本文 TAPF 方法规划出的航迹无论在航迹

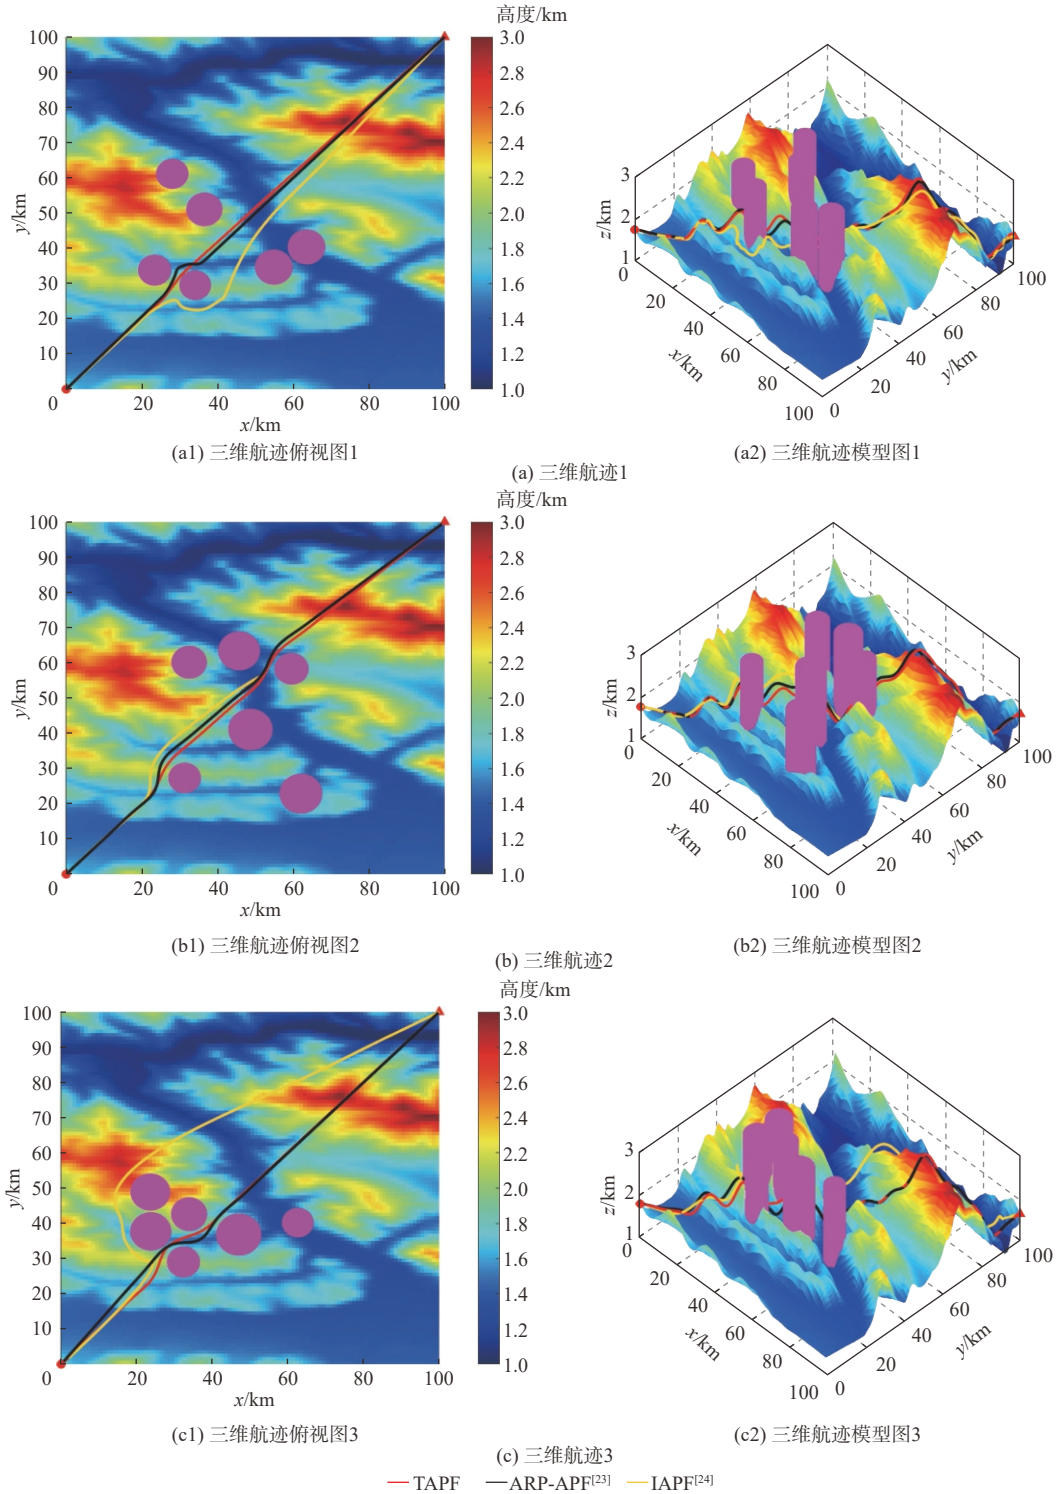


图 20　测试环境 2 中三维航迹图

Fig. 20　Three-dimensional trajectory map in test environment 2

表 4　测试环境 3 中指标对比

Table 4　Comparison of metrics in test environment 3

方法	M_s/%	M_l/km	M_t/s	M_{turn}/(°)
TAPF	100.0	294.5	0.74	31.10
IAPF[24]	97.4	337.1	0.62	67.03

长度还是平滑性方面都更好。

2 种方法对比的俯视图如图 21 所示。可以明显看出, 当进入到障碍物斥力势场的影响范围内时, 传统的斥力场将会一直对无人机产生斥力作用, 即使当无人机已经绕开障碍物, 前进方向已经没有威胁, 仍然会受到斥力影响, 导致产生多余的航迹。而对于改进的三角区势场当无人机绕开障碍物后, 前进方向没有障碍物时, 无人机即使处于斥力影响范围内, 但不受斥力影响, 保持直接飞向目标点的状态。因此, 从水平维度来看, 本文 TAPF

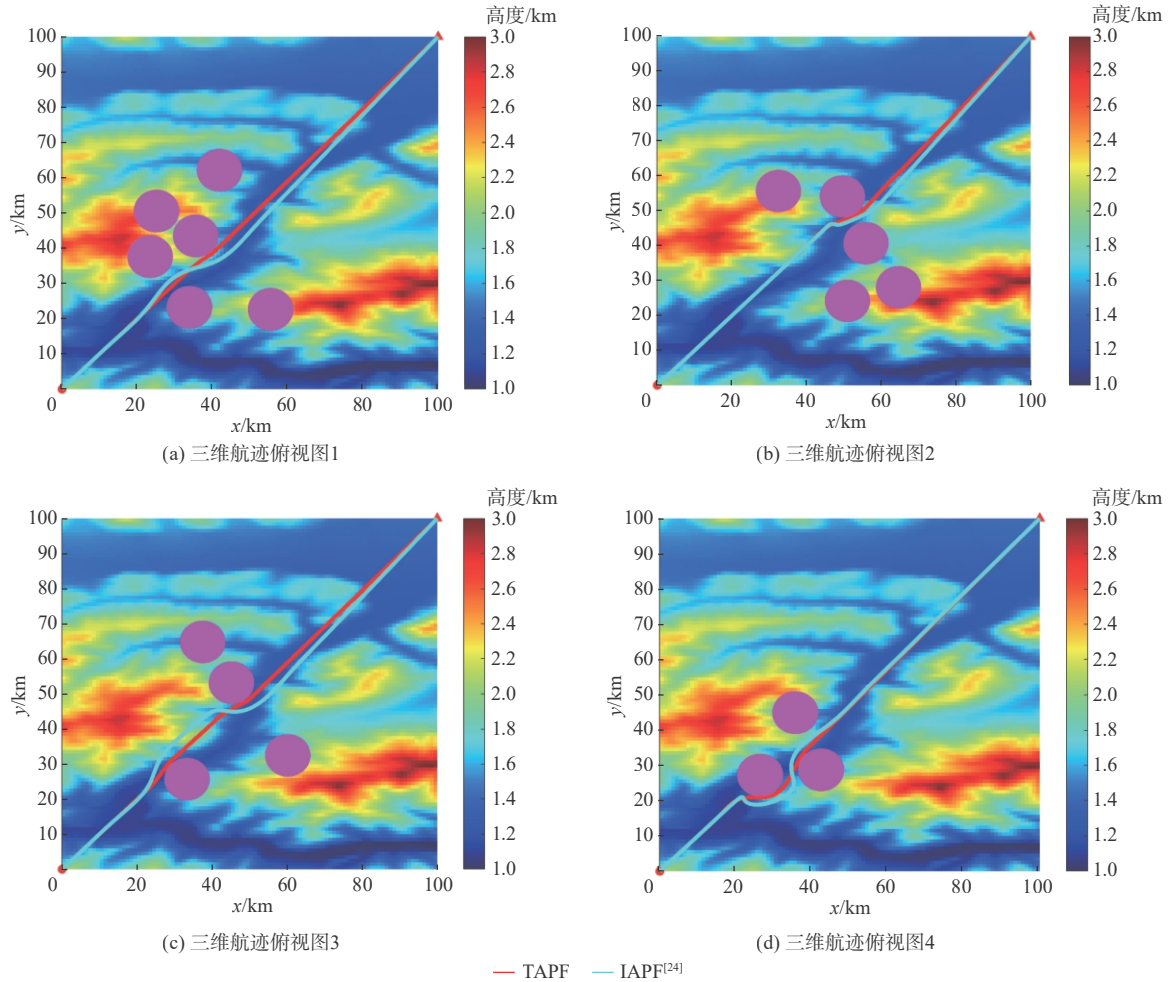


图 21 测试环境 3 中三维航迹俯视图

Fig. 21 Top view of 3D trajectory in test environment 3

方法中采用的三角区斥力势场机动幅度明显更小，路径具有更好的平滑性。

5 结 论

1）本文方法针对 APF 法势场函数设计困难的问题，利用强化学习学习斥力势场，消除了靠经验设计势场函数的不确定性；针对 APF 法适应性差的问题，通过强化学习得到适应性更广的斥力势场，提高了方法的适应性和优化性能；针对当前斥力势场使无人机绕飞过远，提出了三角区斥力势场，解决了无人机在已经绕开障碍物后无效避障增加航迹长度的问题。

2）仿真结果表明，本文方法提高了无人机在复杂环境中规划航迹的能力，在保证飞行成功率的前提下，同时缩短了航迹路程。在忽略自然干扰因素影响条件下，本文方法相较 ARP-APF 方法和 IAPF 法，在无人机航迹规划领域更具可行性。

参考文献（References）

[1] 杨孝鹏, 李伟春, 孙锐. 基于国家安全情报的海岸警卫队态势感知研究[J]. 飞航导弹, 2020(6): 87-91.
Yang X P, Li W C, Sun R. Research on situation awareness of coast guard based on national security intelligence[J]. Aerodynamic Missile Journal, 2020(6): 87-91(in Chinese).

[2] 白文超, 班明飞, 宋梦, 等. 电动汽车-无人机联合救援系统协调调度模型[J]. 上海交通大学学报, 2024, 58(9): 1443-1453.
Bai W C, Ban M F, Song M, et al. Coordinate scheduling model of electric vehicle-unmanned aerial vehicle joint rescue system[J]. Journal of Shanghai Jiao Tong University, 2024, 58(9): 1443-1453(in Chinese).

[3] 王飞, 杨清平. 面向多无人机物流配送的双层任务规划方法[J]. 北京航空航天大学学报, 2026, 52(1): 94-103.
Wang F, Yang Q P. Two-layer task planning method for multi-UAV logistics distribution[J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(1): 94-103(in Chinese).

[4] 武锦龙, 吴虹麒, 李浩, 等. 基于改进 DeepLabV^{3+}的荞麦苗期无人机遥感图像分割识别方法研究[J]. 农业机械学报, 2024, 55(5): 186-195.
Wu J L, Wu H Q, Li H, et al. Segmentation of buckwheat by UAV based on improved lightweight DeepLabV^{3+} at seedling stage[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(5): 186-195(in Chinese).

[5] 王超, 王银花. 一种改进 Dijkstra 算法的 UAV 路径规划[J]. 信息技术与信息化, 2021(10): 217-219.

Wang C, Wang Y H. An improved Dijkstra algorithm for UAV path planning[J]. Information Technology and Informatization, 2021(10): 217-219(in Chinese).

[6] 赵烈海, 李大鹏. 高密度场景下基于改进 A*算法的无人机路径规划[J]. 无线电通信技术, 2024, 50(4): 713-719.
Zhao L H, Li D P. Unmanned aerial vehicle path planning based on improved A* algorithm in high-density scenarios[J]. Radio Communications Technology, 2024, 50(4): 713-719(in Chinese).

[7] 杨玉, 金敏, 鲁华祥. 融合简化稀疏 A*算法与模拟退火算法的无人机航迹规划[J]. 计算机系统应用, 2019, 28(4): 25-31.
Yang Y, Jin M, Lu H X. UAV path planning based on fusion of simplified sparse A* algorithm and simulated annealing algorithm[J]. Computer Systems & Applications, 2019, 28(4): 25-31(in Chinese).

[8] Chen Y B, Luo G C, Mei Y S, et al. UAV path planning using artificial potential field method updated by optimal control theory[J]. International Journal of Systems Science, 2016, 47(6): 1407-1420.

[9] 程泽新, 李东生, 高杨. 一种改进遗传算法的无人机航迹规划[J]. 计算机仿真, 2019, 36(12): 31-35.
Cheng Z X, Li D S, Gao Y. GASA drone path planning to improve mutation strategy[J]. Computer Simulation, 2019, 36(12): 31-35(in Chinese).

[10] Meng X L, Zhu X J, Zhao J. Obstacle avoidance path planning using the elite ant colony algorithm for parameter optimization of unmanned aerial vehicles[J]. Arabian Journal for Science and Engineering, 2023, 48(2): 2261-2275.

[11] Yu Z H, Si Z J, Li X B, et al. A novel hybrid particle swarm optimization algorithm for path planning of UAVs[J]. IEEE Internet of Things Journal, 2022, 9(22): 22547-22558.

[12] 王庆海, 刘广瑞, 郭珂甫. 基于改进人工蜂群算法的无人机航迹规划研究[J]. 机床与液压, 2017, 45(21): 68-72.
Wang Q H, Liu G R, Guo K F. Research on path planning of UAV based on improved ABC algorithm[J]. Machine Tool & Hydraulics, 2017, 45(21): 68-72(in Chinese).

[13] 姬鹏, 郭明皓. 基于 Frenet 坐标下改进人工势场法的无人车局部路径规划[J]. 兵工学报, 2024, 45(7): 2097-2109.
Ji P, Guo M H. Local path planning for unmanned ground vehicles based on improved artificial potential field method in frenet coordinate system[J]. Acta Armamentarii, 2024, 45(7): 2097-2109(in Chinese).

[14] 张铮, 薛波, 柯子鹏, 等. 改进人工势场算法的路径规划[J]. 西安理工大学学报, 2024, 40(1): 27-35.
Zhang Z, Xue B, Ke Z P, et al. Path planning based on improved artificial potential field algorithm[J]. Journal of Xi'an University of Technology, 2024, 40(1): 27-35(in Chinese).

[15] 张菁, 何友, 彭应宁, 等. 基于神经网络和人工势场的协同博弈路径规划[J]. 航空学报, 2019, 40(3): 322493.
Zhang J, He Y, Peng Y N, et al. Neural network and artificial potential field based cooperative and adversarial path planning[J]. Acta Aeronautica et Astronautica Sinica, 2019, 40(3): 322493(in Chinese).

[16] 苗田恬, 方厚招, 安康, 等. 基于人工势场引力因子的机械臂避障规划算法[J]. 计算机工程与设计, 2024, 45(2): 578-586.
Miao T T, Fang H Z, An K, et al. Obstacle avoidance planning algorithm of robot arm based on attraction factor of artificial potential field[J]. Computer Engineering and Design, 2024, 45(2): 578-586(in Chinese).

[17] 刘光才, 马寅松, 齐福强, 等. 基于改进 A*-人工势场法的城市物流无人机路径规划[J]. 飞行力学, 2022, 40(6): 16-23.
Liu G C, Ma Y S, Qi F Q, et al. Flight path planning for urban logistics UAV based on improved A*-APF algorithm[J]. Flight Dynamics, 2022, 40(6): 16-23(in Chinese).

[18] 董炫良, 赵桂清. 人工势场引导蚁群算法的机器人导航路径规划[J]. 机械设计与制造, 2021(6): 169-173.
Dong X L, Zhao G Q. Robot navigation path planning based on ant colony algorithm guided by artificial potential field[J]. Machinery Design & Manufacture, 2021(6): 169-173(in Chinese).

[19] Guan W, Cui Z W, Zhang X K. Intelligent smart marine autonomous surface ship decision system based on improved PPO algorithm[J]. Sensors, 2022, 22(15): 5732.

[20] Zhou Y X, Shu J S, Hao H, et al. UAV 3D online track planning based on improved SAC algorithm[J]. Journal of the Brazilian Society of Mechanical Sciences and Engineering, 2023, 46(1): 12.

[21] 曹馨文, 时宏伟. 自适应斥力系数的无人机路径规划[J]. 计算机系统应用, 2023, 32(5): 36-44.
Cao X W, Shi H W. Path planning of UAV based on adaptive repulsion coefficient[J]. Computer Systems & Applications, 2023, 32(5): 36-44(in Chinese).

[22] 陈康雄, 刘磊. 基于扰动流体与 TD3 的无人机路径规划算法[J]. 电光与控制, 2024, 31(1): 57-62.
Chen K X, Liu L. A UAV path planning method based on interfered fluid and TD3 algorithm[J]. Electronics Optics & Control, 2024, 31(1): 57-62(in Chinese).

[23] Hao G Q, Lv Q, Huang Z, et al. UAV path planning based on improved artificial potential field method[J]. Aerospace, 2023, 10(6): 562.

[24] 王庆禄, 吴冯国, 郑成辰, 等. 基于优化人工势场法的无人机航迹规划[J]. 系统工程与电子技术, 2023, 45(5): 1461-1468.
Wang Q L, Wu F G, Zheng C C, et al. UAV path planning based on optimized artificial potential field method[J]. Systems Engineering and Electronics, 2023, 45(5): 1461-1468(in Chinese).

Adaptive repulsive potential field for UAV trajectory planning

GUO Jing[1], XIAN Yong[1,*], REN Leliang[1], LI Shaopeng[1,2]

(1. School of Missile Engineering, Rocket Force Engineering University, Xi'an 710025, China;
2. School of Automation, Tsinghua University, Beijing 100083, China)

Abstract: Aiming at the difficulty of potential field function design and the poor scene adaptability of the traditional artificial potential field (APF) method in multi-obstacle complex scenes, a three-dimensional self-adaptive repulsive potential field trajectory planning (TAPF) method based on the deep deterministic policy gradient (DDPG) algorithm is proposed. The adaptive repulsive potential field is used for trajectory planning. Firstly, a reinforcement learning-based repulsive potential field learning intelligence is established, which achieves "end-to-end" repulsive force output and improves the adaptability of the repulsive field. Secondly, dynamic triangles are designed to describe the range of the repulsive field, which effectively solves the problem of redundant paths in the traditional circular repulsive field guidance. Lastly, according to the characteristics of UAV trajectory planning, the state space, action space, and action space are designed for the TAPF method, and the proposed algorithm is based on the characteristics of unmanned aerial vehicle (UAV) trajectory planning. The algorithm's state space, action space, and reward function are created. According to simulation results, the proposed method has superior robustness to complicated scene adaptation and plans shorter courses with a better planning effect.

Keywords: unmanned aerial vehicle; trajectory planning; reinforcement learning; artificial potential field; neural network; obstacle avoidance

Received: 2024-07-25; **Accepted**: 2024-11-15; **Published Online**: 2024-12-06 10:59

URL: link.cnki.net/urlid/11.2625.V.20241205.1253.002

Foundation items: National Natural Science Foundation of China (62103432); Shaanxi University Science and Technology Association Young Talent Support Program (20210108)

* **Corresponding author**. E-mail: xy603xy@163.com

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0670

基于分布式电推进概念的飞机横侧向控制

王斌，杨佑绪*，付军泉，段屹蔚，沈骏辉，吴逸飞
(南昌航空大学 飞行器工程学院，南昌 330063)

摘 要：通过分布在机体上的多个电机-螺旋桨系统为飞机提供推力，分布式电推进(DEP)构型为飞机的横侧向控制提供了一种新的策略。建立DEP构型飞机的飞行动力学模型，考虑分布式滑流对气动特性的影响。采用传统比例-积分-微分(PID)控制算法，调节DEP系统的动力输出，控制飞机的横侧向运动，提高飞行稳定性和操控性。结果表明：在偏航运动过程中，飞机采用动力差动控制有效跟踪偏航角度指令，实现了飞机偏航30°，达到良好的控制效果；在滚转运动过程中，飞机利用不同推力推进器的滑流增升效应实现了滚转30°，并保持了稳定的飞行状态。

关 键 词：分布式电推进；动力差动；PID控制；机体/推进系统一体化效应；飞行控制
中图分类号：V249.122+.2
文献标志码：A **文章编号**：1001-5965(2026)11-4009-10

随着航空产业迅速发展，世界各国政府和科研机构越来越关注民用航空器的油耗、噪声和污染物排放[1-2]。民用航空器的传统布局在增大载运量，提高升阻比，降低油耗、噪声和污染物排放等方面已经显现出局限性，因而人们开始寻求新的气动布局设计方案，以满足未来航空市场对民用航空器高经济、低能耗、低噪声和低污染的“绿色航空”要求。分布式电推进(distributed electric propulsion, DEP)技术通过多个电机驱动的螺旋桨或涵道风扇提供动力，动力布局具有明显的分散性。DEP技术能够提高飞机的气动效率，降低能耗和噪声[3]，增加设计的灵活性和飞行安全性。

电动推进器的主要优势包括紧凑的结构设计、尺寸大小无关的特性、电动推进器具有相对较低的控制输入滞后，因此，其可用于主动控制[4]。Winborn等[5]和Ko等[6]介绍了使用分布式推进实现飞行控制的好处，包括减少飞机结构质量、提高燃油效率，降低噪声。Kim等[7-8]指出分布式推进提供飞机动力学的控制能力，可消除更多传统的控制面。Kim[9]在翼身融合飞机设计概念中采用推力矢量，以取代升降舵和副翼，使机翼结构质量降低。Lu等[10]构建了受损飞机模型，提出利用差动推力作为控制输入，充当“虚拟”舵面，帮助受损飞机稳定。Weng等[11]提出了一种用于DEP飞机的多推进电机推力协同控制策略。因此，DEP技术以其结构紧凑、尺寸灵活和低滞后控制特性为飞机带来了诸多优势，增强了飞行动力学控制能力，可替代传统控制面，实现更高的飞行稳定性。

DEP飞机的布局通常与传统的燃油推进飞机不同，电动螺旋桨分布在机翼或机身的多个位置。这种布局呈现典型的推进力-气动力耦合效应，最终影响飞机的气动性能和稳定性。Freeman等[4]建立了线性时不变状态空间模型和推进器的二阶状态空间模型，实现利用差动推力完成类似方向舵偏转的控制效果，但未考虑机体/推进系统一体化(propulsion airframe interaction, PAI)效应的影响，并指出在DEP飞机的闭环控制系统设计中考虑PAI效应是有必要的。Kou等[12]提出了分层模型预测

收稿日期：2024-09-10；录用日期：2024-11-15；网络出版时间：2024-11-19 16:12
网络出版地址：link.cnki.net/urlid/11.2625.V.20241119.1356.004
基金项目：基础加强项目基金(2022-JCJQ-JJ-1135)；江西省“双千计划”人才项目(CK202006470)
*通信作者. E-mail：zgdy_1@163.com

引用格式：王斌，杨佑绪，付军泉，等. 基于分布式电推进概念的飞机横侧向控制[J]. 北京航空航天大学学报，2026，52(11)：4009-4018.
Wang B，Yang Y X，Fu J Q，et al. Lateral directional control of aircraft based on distributed electric propulsion concept[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：4009-4018 (in Chinese).

控制(model predictive control, MPC)方案,用于DEP飞机的动力偏航控制。通过将电动推进器动力学纳入DEP飞机飞行动力学模型,实现了动态最优的动力偏航控制的目标,也未考虑PAI效应。尤顺等[13]针对DEP飞机的推力差动调节飞行姿态,提出一种基于非线性动态逆的动力偏航控制策略,实现90°动力偏航,同样只考虑了推进器的推力而未考虑滑流效应。因此,PAI效应具有强非线性与交叉耦合特性,且难以精确建模,导致控制器设计难度大,控制性能难以保证[14]。Pfeifle等[15]以零侧滑为控制目标,在e-Genius无人机和载人电动icaré2飞机上设计了控制律,并作为飞行试验平台。在2架飞机上,控制器使用差动推力实现了协调飞行和荷兰滚运动,证明了滚转力矩的作用。因此,DEP飞机可用于滚转和偏航控制。

在设计控制策略时,本文针对推进系统与飞机动力学之间的相互作用,即PAI效应考虑不足的问题,建立DEP飞机的模型,旨在实现全机配平和动力学稳定性分析功能,并利用滑流效应产生的升力进行滚转控制。以DEP飞机为控制对象,通过传统比例-积分-微分(proportional-integral-derivative, PID)控制来验证差动偏航控制及滑流滚转控制的可能性。

1 DEP飞机建模

NASA X-57飞机采用DEP的设计理念,机翼上分布有14台电动推进器和螺旋桨,其中,12台电推进器为高升力推进器安装在机翼前缘,安装于翼梢的2台电推进器为巡航推进器,如图1所示。由于螺旋桨产生的滑流效应产生更多的升力,机翼面积相对于P2006T飞机减少42%[16],提供了更好的控制性能和降低噪声水平的潜力。



图1 NASA X-57飞机

Fig. 1 NASA X-57 aircraft

1.1 飞机动力学系统建模

根据小扰动假设,在稳定水平飞行条件下对非线性飞机动力学方程线性化[17]。假设飞机在铅垂平面内对称定常直线飞行,风速均匀。该飞机的状态方程表示为

$$\dot{\boldsymbol{x}}_{\mathrm{f}} = \boldsymbol{A}_{\mathrm{f}}\boldsymbol{x}_{\mathrm{f}} + \boldsymbol{B}_{\mathrm{f}}\boldsymbol{u}_{\mathrm{f}} \tag{1}$$

式中:$\boldsymbol{x}_{\mathrm{f}}$和$\boldsymbol{u}_{\mathrm{f}}$分别为飞机状态向量和控制向量;$\boldsymbol{A}_{\mathrm{f}}$和$\boldsymbol{B}_{\mathrm{f}}$分别为飞机动力学状态矩阵和控制矩阵。

状态向量$\boldsymbol{x}_{\mathrm{f}}$为

$$\boldsymbol{x}_{\mathrm{f}} = [\Delta\beta, \Delta p, \Delta r, \Delta\phi]^{\mathrm{T}} \tag{2}$$

式中:β为侧滑角;p为滚转角速率;r为偏航角速率;ϕ为滚转角。

控制向量$\boldsymbol{u}_{\mathrm{f}}$为

$$\boldsymbol{u}_{\mathrm{f}} = [\Delta\delta_{\mathrm{a}}, \Delta\delta_{\mathrm{r}}]^{\mathrm{T}} \tag{3}$$

式中:δ_{a}为副翼偏转角;δ_{r}为方向舵偏转角。

飞机动力学状态矩阵$\boldsymbol{A}_{\mathrm{f}}$为

$$\boldsymbol{A}_{\mathrm{f}} = \begin{bmatrix} Y_\beta & Y_p & Y_r & \dfrac{g\cos\theta_0}{V_0} \\ L_\beta & L_p & L_r & 0 \\ N_\beta & N_p & N_r & 0 \\ 0 & 1 & \tan\theta_0 & 0 \end{bmatrix} \tag{4}$$

式中:V_0为飞机初始速度;θ_0为初始俯仰角。

控制矩阵$\boldsymbol{B}_{\mathrm{f}}$为

$$\boldsymbol{B}_{\mathrm{f}} = \begin{bmatrix} 0 & \dfrac{Y_{\delta_{\mathrm{r}}}}{mV_0} \\ L_{\delta_{\mathrm{a}}} & L_{\delta_{\mathrm{r}}} \\ N_{\delta_{\mathrm{a}}} & N_{\delta_{\mathrm{r}}} \\ 0 & 0 \end{bmatrix} \tag{5}$$

式中:m为飞机质量。

其中,各类力和力矩导数根据空气动力学稳定性和控制导数计算得到,其定义为

$$Y_i = \frac{1}{2}\rho V_0^2 S C_{Y_i} \qquad i = \beta, \delta_{\mathrm{r}} \tag{6}$$

$$Y_j = \frac{1}{4}\rho V_0 S b C_{Y_j} \qquad j = p, r \tag{7}$$

$$L_i = \frac{1}{2}\rho V_0^2 S b C_{L_i} \qquad i = \beta, \delta_{\mathrm{a}}, \delta_{\mathrm{r}} \tag{8}$$

$$L_j = \frac{1}{4}\rho V_0 S b^2 C_{L_j} \qquad j = p, r \tag{9}$$

$$N_i = \frac{1}{2}\rho V_0^2 S b C_{N_i} \qquad i = \beta, \delta_{\mathrm{a}}, \delta_{\mathrm{r}} \tag{10}$$

$$N_j = \frac{1}{4}\rho V_0 S b^2 C_{N_j} \qquad j = p, r \tag{11}$$

式中:b为飞机机翼展长;ρ为空气密度;S为机翼面积;各类气动导数系数C_{Y_i}、C_{Y_j}、C_{L_i}、C_{L_j}、C_{N_i}、C_{N_j}均可从OpenVSP软件计算得到。

1.2 推进器对飞机的影响

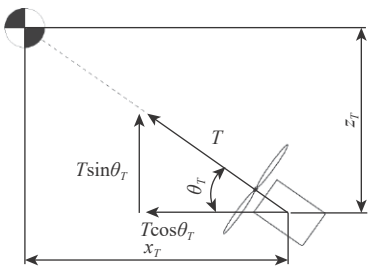
NASA X-57飞机有12个高升力推进器和2个翼尖巡航推进器,且都为电动推进器。其中,高升力推进器采用五叶定距螺旋桨,直径为0.58 m。巡航推进器采用三叶定距螺旋桨,直径为1.52 m[18]。对于高升力推进器和巡航推进器,螺旋桨产生的推力T和功率P分别为

$$T = C_T \rho D^4 n^2 \tag{12}$$

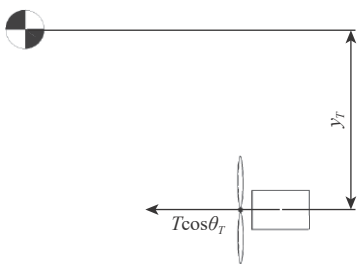
$$P = C_P \rho D^5 n^3 \tag{13}$$

式中: C_T 为推力系数; C_P 为功率系数; D 为螺旋桨直径; n 为螺旋桨转速。

推进器推力不仅产生前向推力, 还因其安装位置在机体坐标系内生成推力分量, 同时引起偏航力矩和滚转力矩, 如图 2 所示。



(a) xz平面内推进器推力矢量



(b) xy平面内推进器推力矢量

图 2　单个推进器推力相对于飞机重心的受力分析

Fig. 2　Force analysis of a single propeller thrust relative to aircraft's center of gravity

电动推进器产生的滚转力矩 $\overline{L}_i$ 和偏航力矩 $\overline{N}_i$ 为

$$\begin{cases} \overline{L}_i = y_{T,i}\left(\dfrac{1}{2}\rho V^2 S b C_{L,i} + \sin\theta_{T,i} T_i\right) \\ \overline{N}_i = y_{T,i}\cos\theta_{T,i} T_i \end{cases} \tag{14}$$

式中: $\theta_{T,i}$ 为第 i 个电动推进器的安装角; T_i 为第 i 个电动推进器的推力; $y_{T,i}$ 为第 i 个电动推进器与飞机重心的展向距离。

将式(14)线性化得控制矩阵 $\boldsymbol{B}_T$ 为

$$\boldsymbol{B}_T = \begin{bmatrix} 0 & \cdots & 0 \\ \dfrac{\overline{L}_{T,1} + (I_{xz}/I_x)\overline{N}_{T,1}}{I_x - I_{xz}^2/I_z} & \cdots & \dfrac{\overline{L}_{T,14} + (I_{xz}/I_x)\overline{N}_{T,14}}{I_x - I_{xz}^2/I_z} \\ \dfrac{\overline{N}_{T,1} + (I_{xz}/I_x)\overline{L}_{T,1}}{I_z - I_{xz}^2/I_x} & \cdots & \dfrac{\overline{N}_{T,14} + (I_{xz}/I_x)\overline{L}_{T,14}}{I_z - I_{xz}^2/I_x} \\ 0 & \cdots & 0 \end{bmatrix} \tag{15}$$

式中: I_x 和 I_z 分别为飞机对 Ox 轴和 Oz 轴的惯性矩; I_{xz} 为对 Ox 与 Oz 轴的惯性积。

1.3　PAI 效应建模

为对 PAI 效应进行建模, 采用文献 [19] 的方法。螺旋桨滑流与升力面之间的气动相互作用可以用来提高升力系数。这种效应也有增加阻力系数的缺点。为简单起见, 舍弃了切向速度分量, 只考虑轴向速度的增加。在该方法的基础上, 进行部分修改, 该模型只体现单个螺旋桨的滑流效应, 如图 3 所示。

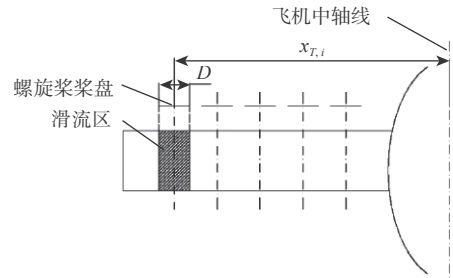


图 3　用于 PAI 效应分析的机翼和螺旋桨参数

Fig. 3　Wing and propeller parameters for PAI effect analysis

根据文献 [20], PAI 效应建模依赖于 8 条假设条件, 其中之一为: 如果螺旋桨桨盘之间间距远远小于桨盘直径, 则每个螺旋桨在机翼上产生的滑流效应的影响是一致的。在文献 [20] 中, 单侧机翼上的各推进器推力相同, 因此, 该假设成立。但本文使用动力差动控制方式, 使机翼上各推进器的推力不相等, 从而导致各推进器的滑流效应不同。该假设对于本文研究的问题并不准确, 因此, 为确保 PAI 效应建模的合理性和准确性, 采用以下假设条件: ①螺旋桨盘处的速度增加是在假设均匀轴向流入的情况下计算的; ②忽略了切向速度引起的升力变化; ③机翼上的气流是附着的; ④机翼是对称的, 因此, 在迎角 α=0 时产生零升力; ⑤忽略每个螺旋桨对相邻螺旋桨的影响; ⑥螺旋桨对机翼的影响仅限于圆盘所占据的翼展间隔; 机翼应完全浸没在滑流中, 即一半的滑流在机翼下方流动, 一半在机翼上方流动。

对于每个螺旋桨推力 T, 使用螺旋桨盘理论计算螺旋桨盘处的轴向诱导因子 a_p:

$$a_\mathrm{p} = \frac{V_\mathrm{p} - V_\infty}{V_\infty} = \frac{1}{2}\left(\sqrt{1 + \frac{8T}{\pi\rho V_\infty^2 D^2}} - 1\right) \tag{16}$$

式中: V_p 为螺旋桨盘处的滑流速度; V_∞ 为真实空速。

因滑流收缩, 机翼上的滑流速度高于螺旋桨盘的滑流。该收缩率为

$$\frac{R_\mathrm{w}}{R_\mathrm{p}} = \sqrt{\frac{1 + a_\mathrm{p}}{1 + a_\mathrm{p}\left[1 + \left(x_\mathrm{p}/R_\mathrm{p}\right) / \sqrt{\left(x_\mathrm{p}/R_\mathrm{p}\right)^2 + 1}\right]}} \tag{17}$$

式中: $x_\mathrm{p}/R_\mathrm{p}$ 给出螺旋桨相对于 x 方向上的前缘的布置除以螺旋桨的半径的比率。根据该比率, 遵循不可压缩流的质量守恒 a_w 为

$$a_{\mathrm{w}}=\frac{a_{\mathrm{p}}+1}{\left(R_{\mathrm{w}}/R_{\mathrm{p}}\right)^2}-1 \tag{18}$$

使用 a_{w}, 截面机翼升力系数 C_l 的增加为

$$\Delta C_l=\left[2\pi\left(\sin\alpha-a_{\mathrm{w}}\beta_{\mathrm{corr}}\sin\left(\alpha_{\mathrm{p}}-\alpha\right)\right)\right]\cdot \sqrt{\left(a_{\mathrm{w}}\beta_{\mathrm{corr}}\right)^2+2a_{\mathrm{w}}\beta_{\mathrm{corr}}\cos\alpha_{\mathrm{p}}+1}-2\pi\sin\alpha \tag{19}$$

式中: α_{p} 为螺旋桨迎角; β_{corr} 为滑流修正系数, 运用文献 [19] 的模型进行计算得到。

局部机翼升力系数 C_L 增量为

$$\Delta C_{L,i}=\Delta C_l\,\Delta y_i \tag{20}$$

式中: Δy_i 为第 i 个螺旋桨相对翼展所占的展向间隔, 即 $\Delta y_i=D/(b/2)$。

1.4 状态空间表达式

DEP 飞机控制中存在 2 种效应: 差动推力和 PAI 效应。因此, 还需要考虑电动推进器的模型和推进器对飞机的影响。

由式(1)、式(5)和式(15)整理得到新的飞机系统状态方程为

$$\dot{\boldsymbol{x}}_{\mathrm{f}}=\boldsymbol{A}_{\mathrm{f}}\boldsymbol{x}_{\mathrm{f}}+\left[\boldsymbol{B}_{\mathrm{f}}\quad\boldsymbol{B}_T\right]\begin{bmatrix}\boldsymbol{u}_{\mathrm{f}}\\ \boldsymbol{u}_T\end{bmatrix} \tag{21}$$

式中: $\boldsymbol{u}_T=[\Delta T_1,\Delta T_2,\cdots,\Delta T_{14}]^{\mathrm{T}}$。推力受到约束条件限制为 $T_{\min}\leqslant T\leqslant T_{\max}$。高升力螺旋桨推进器推力 $T_{\min}$ 为 0 N, $T_{\max}$ 为 700 N, 巡航螺旋桨推进器推力 $T_{\min}$ 为 0 N, $T_{\max}$ 为 963 N。

2 横侧向控制策略

偏航/滚转控制通过控制 DEP 飞机的各个螺旋桨推进器推力实现飞行轨迹偏航。该控制系统使用传统的 PID 控制, PID 控制器是一种经典的反馈控制器, 广泛应用于工业控制和自动化系统中。其基于当前误差、过去误差及误差变化率的反馈信息, 通过调节比例项、积分项和微分项来实现系统的稳定性和动态响应。

PID 控制器传递函数[21] 为

$$G(s)=K_{\mathrm{p}}+\frac{K_{\mathrm{i}}}{s}+K_{\mathrm{d}}s=\frac{K_{\mathrm{d}}s^2+K_{\mathrm{p}}s+K_{\mathrm{i}}}{s} \tag{22}$$

式中: K_{p}、K_{i}、K_{d} 分别为比例、积分和微分系数。为统一参数设置, 每个 PID 控制器的 K_{p}、K_{i}、K_{d} 都与推进器在机翼上的展向位置有关。

PID 控制器参数定义为

$$\begin{cases}K_{\mathrm{p},i}=K_{\mathrm{p}}x_{T,i}\\ K_{\mathrm{i},i}=K_{\mathrm{i}}x_{T,i}\\ K_{\mathrm{d},i}=K_{\mathrm{d}}x_{T,i}\end{cases} \tag{23}$$

2.1 偏航控制回路

偏航角控制回路通过给定期望的偏航角, 与反馈的实际偏航角求差得到偏航角误差, 采用 DEP 系统调节各个推进器的推力差异, 减小偏航角误差。控制回路结构如图 4 所示。

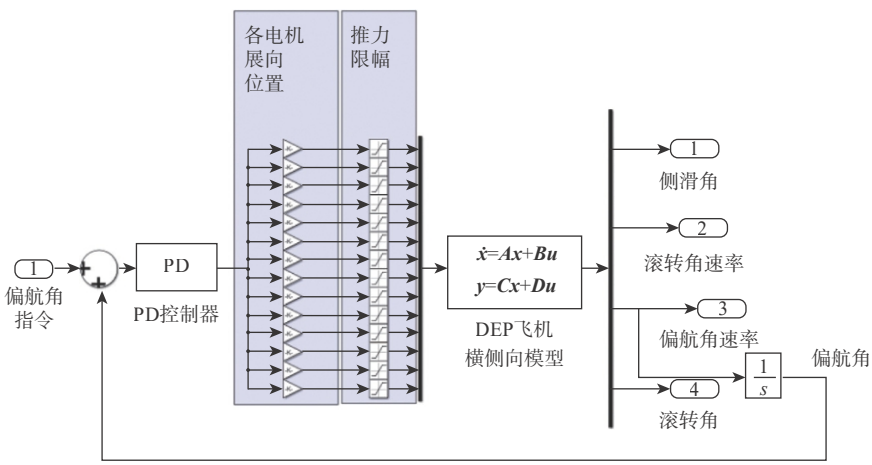


图 4 偏航控制回路结构

Fig. 4 Yaw control loop structure

偏航控制回路开环的幅值响应曲线与相位响应曲线如图 5 所示。幅值裕度为−22.9 dB, 相角裕度为 86.3°, 相角裕度较大, 说明系统在相位方面具有显著的稳定性余量, 这在一定程度上补偿了幅值裕度不足的问题。

在幅值响应曲线中, 低频段的幅值接近 50 dB, 显示出系统在低频段对信号具有较强的放大效果, 适合对低频偏航角命令的响应。随着频率的增加, 幅值逐渐下降, 并在频率约为 10^0 rad/s 附近接近 0 dB, 说明系统增益在此频段开始减弱, 对高频扰动有一定的抑制效果。在更高频段, 幅值继续降低, 表明系统在高频段抑制能力较强, 有助于稳定性。

在相位响应曲线中, 相位在低频段接近−90°, 随后在 10^{-1} rad/s 附近出现一个峰值, 达到 0°以上, 表示该频率附近的相位滞后相对较小, 增强了系统

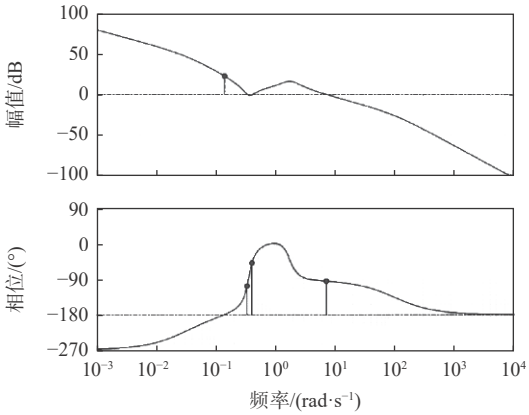


图 5　偏航控制回路开环伯德图

Fig. 5　Open-loop Bode plot of yaw control loop

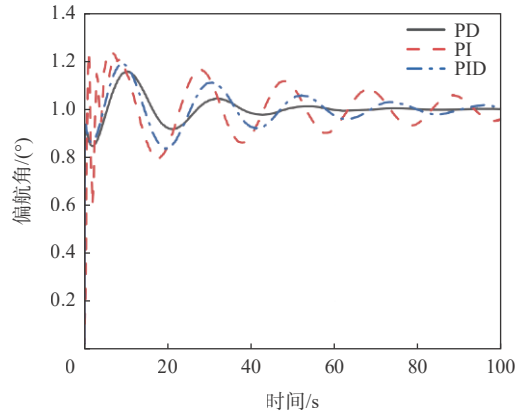


图 6　偏航控制阶跃响应

Fig. 6　Yaw control step response

的动态响应能力。相位逐渐下降, 在高频段接近−180°, 表明系统在高频下可能接近稳定性边界, 但未超出危险区间。

从图 6 和表 1 得出, 比例-微分(proportional-derivative, PD)控制系统的上升时间、调节时间和超调量都优于比例-积分(proportional-integral, PI)控制。PD 控制相较于 PID 控制系统超调量与调节时间都较小。这表明, PD 系统响应速度快, 达到良好的控制效果。

表 1　偏航控制回路不同 PID 控制对比

Table 1　Comparison of different PID controls for yaw control loop

控制方式	上升时间/s	超调量/%	调节时间/s	稳态误差
PD	0.148	15.9	44.6	0
PI	0.467	25.4	149.0	0
PID	0.148	19.0	85.6	0

2.2　滚转控制回路

滚转角控制回路的作用是将飞机的滚转角稳定至期望值。在 DEP 飞机中, 通过调节不同推进器的推力差异来控制滚转角, 并作为反馈以增加回路阻尼特性, 虽然会因此降低系统的开环增益, 但能够实现更平稳的姿态控制和良好的稳态精度。控制回路结构如图 7 所示。

滚转控制回路开环的幅值响应曲线与相位响应曲线如图 8 所示。系统是稳定的, 幅值裕度为 −31.3 dB, 相角裕度为 60.8°, 相角裕度较大, 意味着在相角方面系统有较强的稳定性余量。

在幅值响应曲线中, 低频区域的幅值较高, 说明系统在低频段对滚转信号具有较强的增益作用, 能够有效放大低频的输入信号。这反映了系统在低频扰动下的响应敏感性和对低频信号的控制能力。随着频率的升高, 幅值逐渐下降, 在 10^0 rad/s 左右出现了 0 dB 交点, 标志着系统增益从正增益转为衰减, 对高频扰动的放大能力减弱。

在相位响应曲线中, 低频区域的相位接近−180°, 显示出系统在低频下的显著滞后效应, 说明响应速度较慢。随着频率增加, 相位逐渐上升并达到峰值, 这一变化显示出系统在中频段存在相位补偿的能力, 使相角裕度达到 60.8°。较大的相角裕度意味着系统在相位方面具有较强的稳定性余量, 这提供

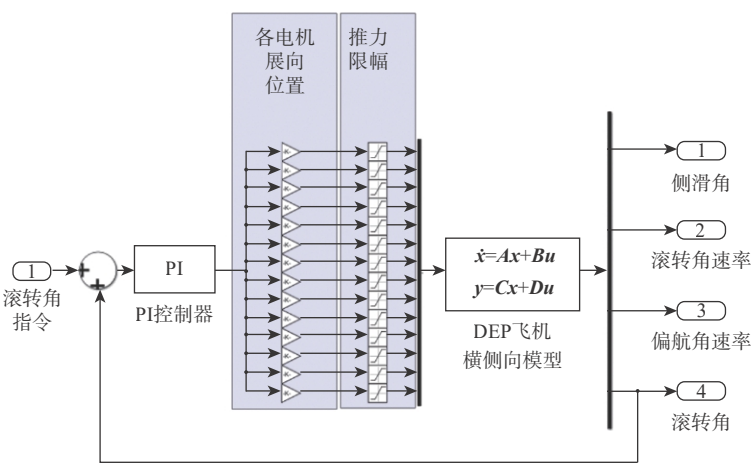


图 7　滚转控制回路结构

Fig. 7　Roll control loop structure

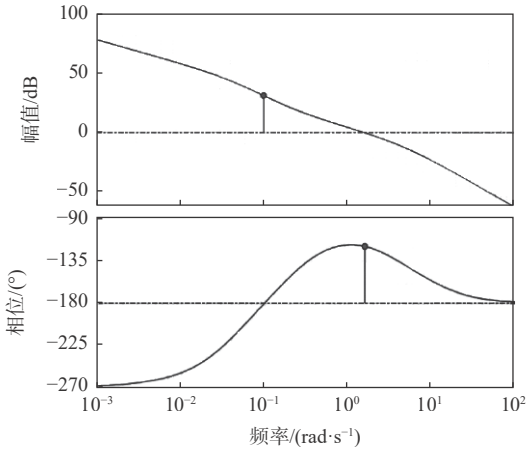


图 8 滚转控制回路开环伯德图

Fig. 8 Open loop Bode plot of the roll control loop

了额外的相位容错能力，在一定程度上缓解增益不稳定带来的影响。

从图 9 和表 2 得出，PI 控制系统的上升时间及调节时间都优于 PD 控制与 PID 控制，虽然 PI 控制超调量比 PD 控制和 PID 控制稍大，但 PD 控制有稳态误差，PID 控制效果与 PD 控制基本一致，因此，滚转控制采用 PI 控制。

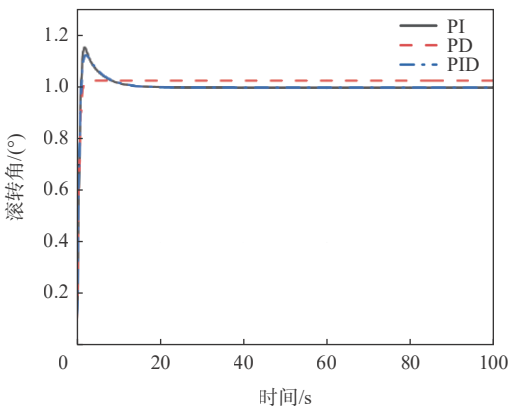


图 9 滚转控制阶跃响应

Fig. 9 Roll control step response

表 2 滚转控制回路不同 PID 控制对比

Table 2 Comparison of different PID controls for the roll control loop

控制方式	上升时间/s	超调量/%	调节时间/s	稳态误差
PI	0.771	15.6	9.67	0
PD	1.000	0	1.72	0.03
PID	0.784	12.7	9.75	0

在偏航控制系统采用 PD 控制、滚转控制系统采用 PI 控制时，偏航与滚转运动具有最优控制效果。PID 控制参数的选取根据不同 K_p、K_i 和 K_d 值阶跃响应，由图 10 可知，滚转控制回路中 K_p 为 4.53 的响应超调量均小于 K_p 为 2 和 K_p 为 6.5 的超调量，且上升时间和调节时间都优于 K_p 为 2 的响应，与 K_p 为 6.5 时的上升时间和调节时间相差极小。故选择 K_p 为 4.53。同理，其他参数均运用该方法选取。PID 控制器参数如表 3 所示。

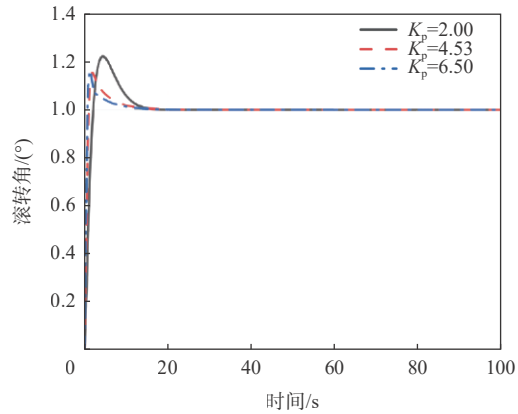


图 10 不同 K_p 值的滚转控制系统阶跃响应

Fig. 10 Step response diagram of roll control system with different K_p values

表 3 PID 控制器参数

Table 3 PID controller parameters

控制回路	K_p	K_i	K_d
偏航	5.00	0	2
滚转	4.53	0.21	0

3 仿真结果及分析

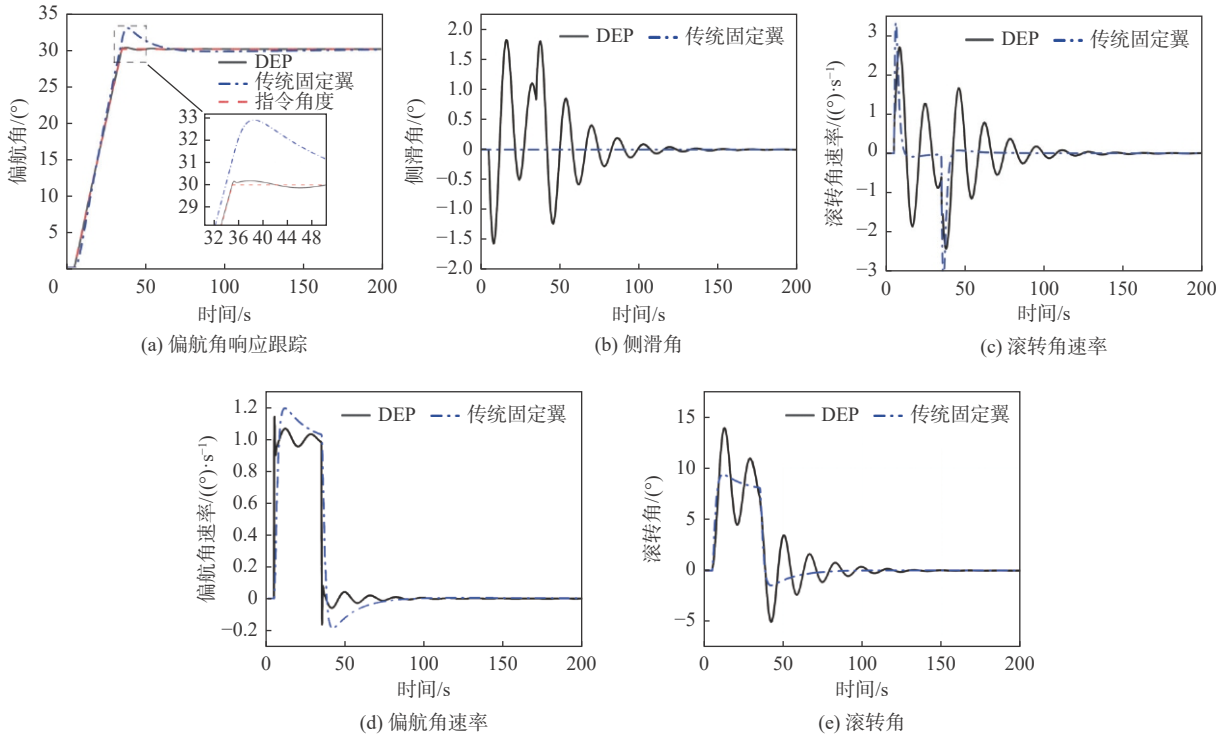
采用 MATLAB/Simulink 软件进行仿真验证，针对差动控制进行了仿真实验，旨在验证其对飞机横侧向姿态的影响及控制效果。

3.1 差动偏航控制仿真

在仿真实验中，模拟飞机在接收偏航角度指令时，DEP 飞机只利用动力差动控制飞机偏航运动，不使用方向舵和副翼进行姿态控制。传统固定翼飞机使用方向舵和副翼进行姿态控制。

飞机仿真飞行条件为：飞机处于巡航平飞状态，飞行速度为 77 m/s，高升力推进器推力为 221 N，巡航推进器推力为 511 N。仿真结果如图 11 和图 12 所示。

当飞机在巡航状态下，5 s 后发出偏航指令，指令为斜率为 1、0°～30°的斜坡信号，DEP 和传统固定翼飞机的实际偏航角能快速跟踪给定信号，偏航角的稳态误差都为 0，但传统固定翼飞机相比 DEP 飞机有较大超调量。DEP 飞机在偏航过程中只有多个推进器共同协调控制，而推进器的 PAI 响应使飞机产生滚转力矩，因此，DEP 的侧滑角、滚转角速率、偏航角速率、滚转角在姿态变化过程中均有所波动。传统固定翼飞机通过方向舵与副翼的协调操纵来平衡滚转力矩和偏航力矩，因此，侧滑角、滚转角速率、偏航角速率及滚转角变化较为平缓，偏航操作结束后各状态量均能恢复到巡航状态值。

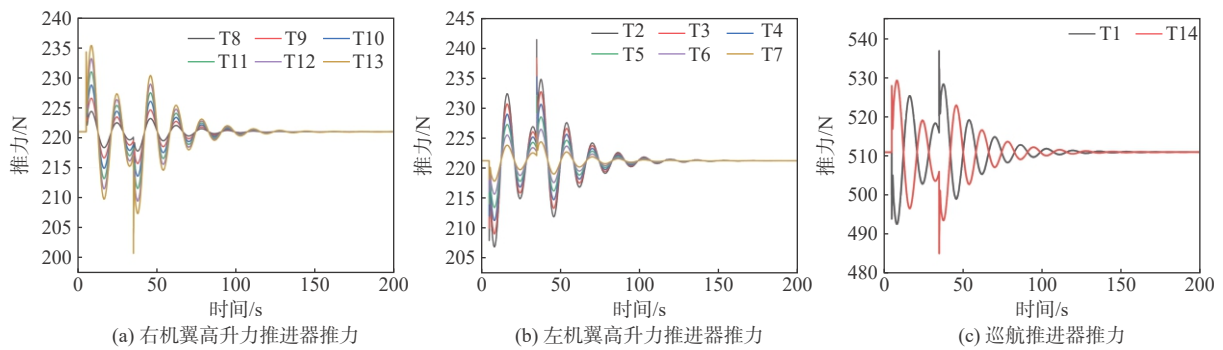


(a) 偏航角响应跟踪　(b) 侧滑角　(c) 滚转角速率

(d) 偏航角速率　(e) 滚转角

图 11　偏航运动中状态变化

Fig. 11　State changes during yaw motion



(a) 右机翼高升力推进器推力　(b) 左机翼高升力推进器推力　(c) 巡航推进器推力

图 12　偏航时控制器输出推力指令

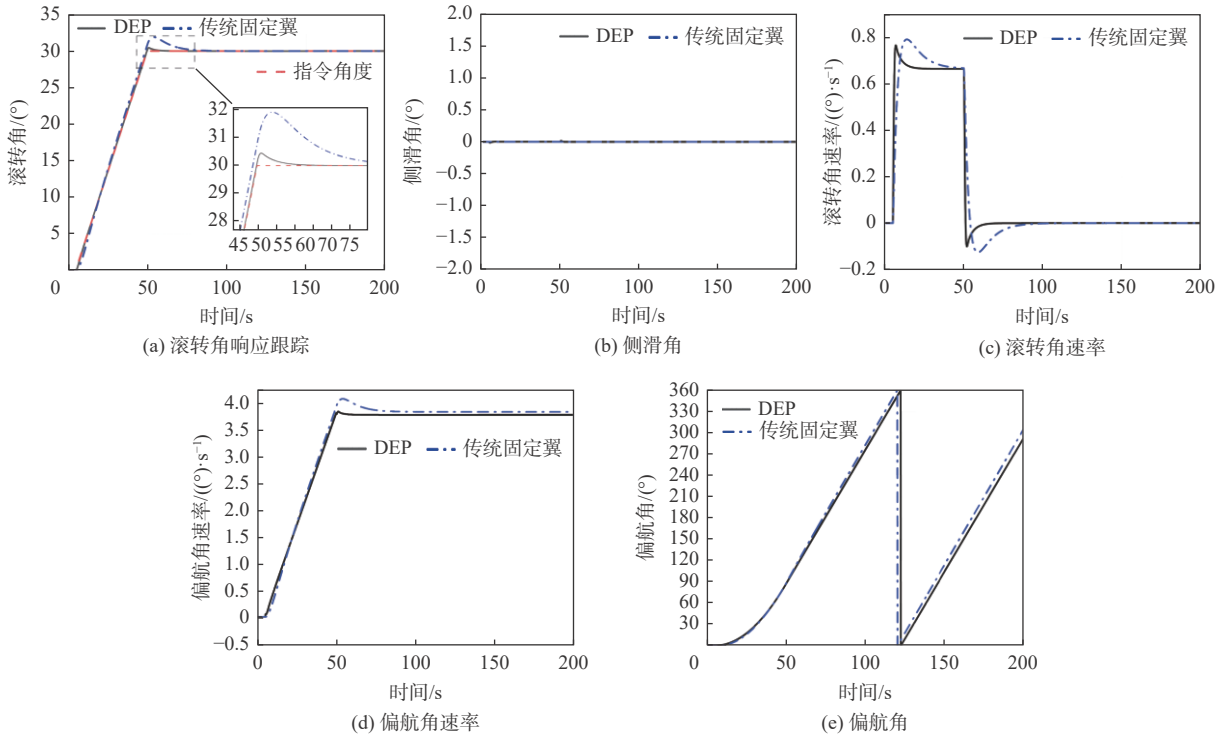
Fig. 12　Controller outputs thrust command during yaw

DEP 飞机推进器编号从左到右依次为 T1、T2、…、T14。由图 12 可知, 飞机在偏航过程中, 单侧机翼的各个推进器推力变化与推进器在机翼的展向位置相关。距离飞机重心越远, 推力输出的变化量越大, 左右两侧的推力变化量一致, 但推力变化方向相反。在偏航完成后, 各个推进器推力回归于初始推力。

3.2　差动滚转控制仿真

DEP 飞机滚转仿真中, 不同推进器产生的非对称滑流升力被用于飞机滚转运动。仿真飞行条件与偏航控制工况保持一致。由于 DEP 采用动力差动实现滚转操纵, 在生成滚转力矩的同时, 不可避免地产生附加偏航力矩, 表现出明显的耦合特性。因此, 使用方向舵偏转抵消动力差动所引起的偏航力矩, 副翼不做任何响应。传统固定翼飞机使用方向舵和副翼进行滚转控制。仿真结果如图 13 和图 14 所示。

飞机在定直平飞状态下, 5 s 时给予滚转 30°的斜坡信号, 由图 13 可知, DEP 飞机实际滚转角有更好的跟踪性能。滚转角随时间增加而逐渐接近指令角度并最终稳定在指令角度值。在时间 50 s 左右, 滚转角达到与指令角度相同的 30°, 并保持稳定。而传统固定翼飞机超调量较大, 稳定时间也较长。这表明, DEP 飞行控制系统能够准确地执行给定的指令, 且侧滑角几乎毫无变化, 而达到目标角度后保持稳定, 滚转角速率也有所波动, 并在滚转完成后回归于初始状态, 说明了系统的高跟踪精度和良好的控制性能。滚转运动完成后, 偏航角速率保持恒定不变, 偏航角线性增大, 飞机进入定向盘旋状态。

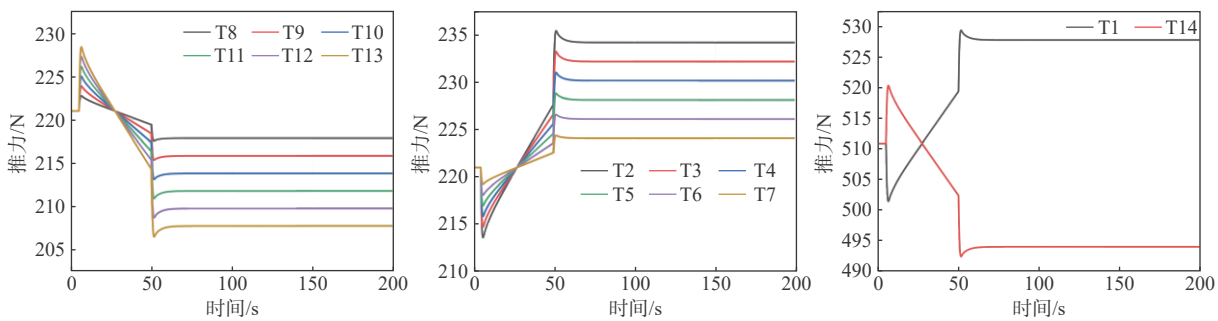


(a) 滚转角响应跟踪　(b) 侧滑角　(c) 滚转角速率

(d) 偏航角速率　(e) 偏航角

图 13　滚转过程中状态变化

Fig. 13　Status changes during rolling



(a) 右机翼高升力推进器推力　(b) 左机翼高升力推进器推力　(c) 巡航推进器推力

图 14　滚转时控制器输出推力指令

Fig. 14　Controller outputs thrust command during roll manoeuvres

由图 14 可知，高升力推进器 T2～T7 初始状态下具有相同的推力值，然后开始减少，T2 推进器的推力减小至停止工作。而高升力推进器 T8～T13 开始增加，巡航推进器 T1 与 T14 在滚转机动中提供主要差动滚转力矩，作用显著。协调一致调整飞机电力推进系统的推力，以控制飞机的滚转角。

4　结　论

考虑滑流效应建立了一种 DEP 飞机模型，以 X-57 飞机为受控对象，设计 PID 控制器，使飞机进行偏航和滚转运动，结果表明：

1）在偏航运动过程中，采用差动控制飞机能够有效跟踪偏航角度指令，并实现了几乎无超调和稳态误差的控制效果，而采用舵面控制飞机的超调量较大。由于受螺旋桨滑流影响且无舵面控制，DEP 飞机相较于传统固定翼飞机滚转角波动较大，但完成偏航指令后，滚转角回归定直平飞状态。

2）在滚转运动过程中，DEP 飞机利用不同推力的推进器产生的滑流效应实现了滚转运动的控制，并保持了稳定的飞行状态。通过协调调整飞机电力推进系统的推力，成功控制飞机滚转运动。相较于传统固定翼飞机，DEP 的滚转控制响应更优；但在滚转过程中，动力差动在产生滚转力矩的同时，会耦合出偏航力矩，仍需依靠方向舵偏转进行配平与抵消。

3）通过建立考虑 PAI 效应的 DEP 飞机模型，只通过动力控制实现了 DEP 飞机偏航与滚转，其控制效果优于传统固定翼飞机舵面控制，提高了飞机的稳定性和操控性。仿真结果表明，基于 DEP 系统的横侧向控制策略，利用多个推进器的协调作用实

现了对飞机姿态的精确控制。进一步的, 通过完善 PAI 效应模型, 使 DEP 飞机模型更精确。

参考文献（References）

[1] Hardin L, Tillman G, Sharma O, et al. Aircraft system study of boundary layer ingesting propulsion[C]//Proceedings of the 48th AIAA/ASME/SAE/ASEE Joint Propulsion Conference & Exhibit. Reston: AIAA, 2012.

[2] Ko A, Leifsson L, Schetz J, et al. MDO of a blended-wing-body transport aircraft with distributed propulsion[C]//Proceedings of the AIAA's 3rd Annual Aviation Technology, Integration, and Operations Forum. Reston: AIAA, 2003.

[3] 孔祥浩, 张卓然, 陆嘉伟, 等. 分布式电推进飞机电力系统研究综述[J]. 航空学报, 2018, 39(1): 46-62.
Kong X H, Zhang Z R, Lu J W, et al. Review of electric power system of distributed electric propulsion aircraft[J]. Acta Aeronautica et Astronautica Sinica, 2018, 39(1): 46-62(in Chinese).

[4] Freeman J L, Klunk G T. Dynamic flight simulation of spanwise distributed electric propulsion for directional control authority[C]//Proceedings of the 2018 AIAA/IEEE Electric Aircraft Technologies Symposium. Piscataway: IEEE Press, 2018: 1-15.

[5] Winborn Jr B R. ADAM III V/STOL concept[J]. Journal of Aircraft, 1970, 7(2): 175-181.

[6] Ko A, Schetz J A, Mason W H. Assessment of the potential advantages of distributed-propulsion for aircraft[C]//Proceedings of the 16th International Symposium on Air Breathing Engines. Cape Verde Islands: ISABE, 2003.

[7] Kim H D, Saunders J D. Embedded wing propulsion conceptual study: NASA/TM-2003-212696[R]. Washington, D. C. : NASA, 2003.

[8] Kim H D, Felder J L, Tong M T, et al. Revolutionary aeropropulsion concept for sustainable aviation: turboelectric distributed propulsion[C]//Proceedings of the 21st International Symposium on Air Breathing Engines. Busan: ISABE, 2013.

[9] Kim H D. Distributed propulsion vehicles[C]//Proceedings of the 27th Congress of the International Council of the Aeronautical Sciences. Nice: Optimage Ltd. , 2010.

[10] Lu L K, Turkoglu K. H_∞ loop-shaping robust differential thrust control methodology for lateral/directional stability of an aircraft with a damaged vertical stabilizer[C]//Proceedings of the AIAA Guidance, Navigation, and Control Conference. Reston: AIAA, 2016.

[11] Weng L H, Zhang X, Yao T K, et al. A thrust cooperative control strategy of multiple propulsion motors for distributed electric propulsion aircraft[J]. World Electric Vehicle Journal, 2021, 12(4): 199.

[12] Kou P, Wang J, Liang D L. Powered yaw control for distributed electric propulsion aircraft: a model predictive control approach[J]. IEEE Transactions on Transportation Electrification, 2021, 7(4): 3006-3020.

[13] 尤顺, 寇鹏, 姚轩宇, 等. 分布式电推进飞机动力偏航非线性动态逆控制[J]. 航空动力学报, 2024, 39(2): 20220222.
You S, Kou P, Yao X Y, et al. Nonlinear dynamic inversion for the powered yaw control of distributed electric propulsion aircraft[J]. Journal of Aerospace Power, 2024, 39(2): 20220222(in Chinese).

[14] Perry A T, Ansell P J, Kerho M F. Aero-propulsive and propulsor cross-coupling effects on a distributed propulsion system[J]. Journal of Aircraft, 2018, 55(6): 2414-2426.

[15] Pfeifle O, Frangenberg M, Notter S, et al. Distributed electric propulsion for yaw control: testbeds, control approach, and flight testing[C]//Proceedings of the AIAA AVIATION 2021 FORUM. Reston: AIAA, 2021: 3192.

[16] Deere K A, Viken J K, Viken S A, et al. Computational analysis of the X-57 maxwell airplane at unpowered conditions (preliminary fuselage)[M]. Washington, D. C.: NASA Technical Memorandum, 2022.

[17] Etkin B, Reid L D. Dynamics of flight: stability and control[M]. 3rd ed. New York: Wiley, 1996.

[18] Deere K A, Viken S, Carter M B, et al. Computational component build-up for the X-57 Maxwell distributed electric propulsion aircraft[C]//Proceedings of the 2018 AIAA Aerospace Sciences Meeting. Reston: AIAA, 2018.

[19] Patterson M D. Conceptual design of high-lift propeller systems for small electric aircraft[D]. Atlanta: Georgia Institute of Technology, 2016.

[20] De Vries R, Brown M T, Vos R. A preliminary sizing method for hybrid-electric aircraft including aero-propulsive interaction effects[C]//Proceedings of the Aviation Technology, Integration, and Operations Conference. Reston: AIAA, 2018.

[21] 胡寿松. 自动控制原理[M]. 7 版. 北京: 科学出版社, 2019.
Hu S S. Principle of automatic control[M]. 7th ed. Beijing: Science Press, 2019(in Chinese).

Lateral directional control of aircraft based on distributed electric propulsion concept

WANG Bin，YANG Youxu*，FU Junquan，DUAN Yiwei，SHEN Junhui，WU Yifei

(School of Flight Vehicle and Engineering，Nanchang Hangkong University，Nanchang 330063，China)

Abstract：Distributed electric propulsion (DEP) aircraft used multiple motor-propeller system distributed on the body to provide thrust and this configuration offers a new strategy for lateral control of the aircraft. The aerodynamic effects of distributed slipstream were taken into account when developing the flight dynamics model for DEP aircraft. The traditional proportional-integral-derivative (PID) control algorithm was used to adjust the power output of the DEP system, controlling the aircraft's lateral movement to improve flight stability and controllability. The results show that during yaw motion, the aircraft uses differential thrust control effectively tracking yaw angle commands, achieving a 30° yaw and reaching excellent con-trol performance. The airplane maintains a stable flight state during roll motion by using the slipstream lift effect of various thrust propellers to achieve a 30° roll.

Keywords：distributed electric propulsion；differential thrust；PID control；propulsion airframe interaction effects；flight control

Received：2024-09-10；**Accepted**：2024-11-15；**Published Online**：2024-11-19 16：12

URL：link.cnki.net/urlid/11.2625.V.20241119.1356.004

Foundation items：Fundamental Reinforcement Project Fund (2022-JCJQ-JJ-1135)； Jiangxi Province "Double Thousand Plan" Talent Project (CK202006470)

* **Corresponding author**. E-mail：zgdy_1@163.com

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0656

基于改进 Transformer 的视觉语言模型

金泽辉[1]，陈凯[1,*]，唐敦兵[1]，方国宇[1]，温菲霞[2]

(1. 南京航空航天大学 机电学院，南京 210016；2. 中国电子科技集团公司第二十八研究所，南京 210007)

摘 要：图像字幕是一项结合计算机视觉和自然语言处理的跨模态任务，模型需要为图像生成恰当的描述。为了应对这一挑战，提出一种带有残差注意力模块和门控线性单元的增强Transformer——残差门控 Transformer (RGFormer)。基于 CLIP 和 RGFormer，提出一种生成图像字幕的模型——CRM。CRM 利用 CLIP 的图像编码器提取特征作为图像字幕的前缀，该前缀通过映射网络 RGFormer 被投影到文本空间，然后被输入 GPT-2 语言模型中生成图像字幕。CLIP 是在一个大型的图像-文本对数据集上进行训练的，包含丰富的视觉和语义信息，非常适合完成视觉-语言跨模态任务。CRM 的核心理念是使用 RGFormer 映射网络来缩小视觉与文本表示之间的差距，从而完成图像字幕任务。CRM 可以在短时间内为大规模的数据集生成有意义的描述，且无需额外监督。定量评估实验表明，CRM 在 COCO Caption 数据集上的表现可与一些先进模型相媲美，且效率更高。

关 键 词：图像字幕；CLIP；Transformer；门控线性单元；残差多头注意力

中图分类号：V221$^+$.3; TB553

文献标志码：A **文章编号**：1001-5965(2026)11-4019-10

图像字幕是一项利用自然语言描述视觉图像的任务。该任务不仅涉及检测和识别图像中的主要对象，还需要用自然语言表达其之间的关系，最终生成贴合图像内容的完整描述。图像字幕生成是一个跨学科、多模态的交叉研究方向，可以应用于许多场景，如自动驾驶、多模态检索、智能监控等，在信息时代具有广阔的应用前景。

目前已有许多成熟的图像字幕生成方法[1-7]，其主要遵循图像编码和文本解码的泛式。具体来说，这些方法通常使用图像编码器提取视觉特征，然后使用文本解码器生成相应的字幕。

然而，由于视觉特征和语义特征之间的差异，这些模型的训练通常需要大量的计算资源。其需要更大规模的数据集、更复杂的网络结构和更多的可训练参数。有时，为了获得更好的性能，还需要目标边界框和对象类别等额外监督标签。这些缺点限制了其在实际场景中的应用。因此，研究轻量级模型以解决图像字幕生成任务具有重要意义。

为了解决这个问题，本文采用强大的预训练模型构建了更轻量级的网络。具体而言，利用在大规模图像文本对数据集上预训练的 CLIP 编码器[8]，从输入图像中提取富含视觉和语义信息的特征，随后设计了残差门控 Transformer(residual gated Transformer, RGFormer)映射网络将其投影至语言空间，作为前缀引导语言模型生成图像字幕。该方法无需大量训练数据或额外监督标签，利用视觉和语义信息之间的强相关性，降低了模型的训练成本和数据需求。

本文在 COCO Caption[9-10] 数据集上进行实验，整个训练过程在一张 Nvidia GTX 3090Ti GPU 上耗时 4 h。实验结果表明，CRM(CLIP-RGFormer model)具备良好的泛化能力。定量评估结果显示，CRM

收稿日期：2024-09-05；**录用日期**：2025-02-14；**网络出版时间**：2025-03-19 11:16

网络出版地址：link.cnki.net/urlid/11.2625.V.20250318.1741.006

基金项目：国家自然科学基金 (52202417)；中国博士后科学基金 (2022TQ0155,2022M721605)；虚拟现实技术与系统全国重点实验室 (北京航空航天大学) 开放课题基金 (VRLAB2023A02)；中国科协青年科技人才托举工程 (2023QNRC001)；中央高校基本科研业务费专项资金 (NS2024030)；江苏省科协青年科技人才托举工程 (JSTJ-2023-XH032)

* **通信作者**. E-mail：chen_kai@nuaa.edu.cn

引用格式：金泽辉，陈凯，唐敦兵，等. 基于改进 Transformer 的视觉语言模型 [J]. 北京航空航天大学学报，2026，52（11）：4019-4028.
Jin Z H，Chen K，Tang D B，et al. Visual language model based on improved Transformer [J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：4019-4028 （in Chinese）.

在较短的训练时间内达到了与一些先进方法相媲美的性能指标。综上所述,本文的创新点如下:

1)提出一种基于CLIP和RGFormer的轻量级图像字幕生成模型CRM。该模型能够在较短的训练时间内为图像生成贴合内容的字幕。

2)提出一种基于残差多头注意力机制和门控线性单元的改进Transformer——RGFormer,在图像字幕生成任务中表现出优于原生Transformer的性能。

1 相关工作

1.1 图像编码器

图像字幕生成模型需要将输入图像编码为特征向量序列,再输入文本解码器生成单词序列。早期研究使用来自分类任务的预训练卷积神经网络(convolutional neural network, CNN)(如VGG16[11]和ResNet101[12])作为编码器来获得网格级图像特征。然而,Anderson等[1]指出,该方法未能有效确定图像中的关键区域。为了生成更符合人类视觉习惯的字幕,他们使用Faster R-CNN[13]检测图像中的突出部分并提取区域级特征,进而提出了自下而上和自上而下注意力(bottom-up and top-down attention, BUTD)图像字幕生成模型,在公开数据集上取得了更优异的性能。后续的许多研究沿用了BUTD的思想。例如,Zhou等[14]提出的视觉-语言预训练(vision-language pre-training, VLP)模型同样利用预训练的目标检测器检测关键物体并提取图像区域级特征。

然而,这种依赖目标检测网络的方法需要边界框和物体类别等额外的标签进行训练,且特征提取过程非常耗时,导致模型训练和推理时间变长,限制了其在实际应用中的效率和可扩展性。

本文使用CLIP作为图像编码器,取代了传统的目标检测网络。CLIP是一种基于文本和图像的多模态模型,在大规模图像文本对数据集上进行了无监督对比学习,旨在将图像和文本映射到同一特征空间。其核心原理是通过对比学习,最大化图像和文本的相似性,同时最小化不相关的配对。引入CLIP编码器后,无需依赖复杂的目标检测网络即可直接从图像中提取富含视觉和语义信息的特征。已有大量研究表明,CLIP在多种视觉任务中表现优异,包括图像分类[15-17]和目标检测[18-20]等。相比传统方法,CLIP通过广泛的预训练,在缺乏标注数据时仍能提供良好的性能,并且具有一定的零样本推理能力。

1.2 文本解码器

根据文本解码器的类型,现有的图像字幕生成模型可分为两类:基于卷积神经网络-长短期记忆(convolutional neural network-long short-term memory, CNN-LSTM)的模型[1,6-7,21-22]和基于CNN-Transformer的模型[3,5,23-24]。前者使用LSTM[25]作为解码器,能够有效捕捉长期依赖关系,并缓解网络反向传播过程中的梯度消失和爆炸问题。例如,BUTD将底层提取的图像特征输入LSTM解码,实现对图像内容的准确描述。后者使用Transformer[26]作为解码器,凭借其强大的全局表征能力,模型能够更有效地结合上下文信息,从而生成更合理的字幕。近年来,应用Transformer最有影响力的工作之一是BERT[27],其为后续研究大语言模型引入了基本框架:在大规模数据集上进行预训练,然后在较小的数据集上针对下游任务进行微调。Vilbert[28]使用基于BERT的预训练语言模型,结合交叉注意力机制,有效地融合并处理图像和文本2种模态的数据。VLP[14]通过将视觉特征转化为语义前缀,进一步引导BERT生成语义连贯的图像字幕。

然而,前述2种方法均存在一定的局限性。LSTM在训练效率和表达能力方面存在瓶颈。首先,LSTM依赖时间步计算,无法充分利用现代GPU的并行计算能力,导致训练速度较慢。其次,LSTM主要依赖局部信息进行预测,难以整合全局上下文信息,导致生成的描述在连贯性和整体性上有所欠缺。相比之下,Transformer通过自注意力机制实现了全局信息的有效整合,并且其高度并行化的计算方式显著提升了训练效率。然而,基于Transformer的BERT语言模型的微调过程需要耗费大量算力,且对样本规模和质量有较高的要求,难以保证微调后的模型性能。

本文使用GPT-2[29]作为文本解码器,以增强模型全局表达能力。GPT-2是一种基于Transformer架构的大规模预训练语言模型,核心原理是通过自注意力机制捕捉文本中的长距离依赖关系,并利用无监督学习从海量文本数据中学习语言表示。为解决语言模型微调的难题,本文提出以训练轻量级映射网络来替代传统的微调过程。建立视觉和文本共享空间[14,28,30]的研究与本文工作密切相关。VLP对整个模型进行预训练,以获取视觉和语言联合表征。而本文使用CLIP能够自然地获取这种联合表征,且仅需训练轻量级映射网络即可在下游任务中实现良好性能。

2 图像字幕生成方法介绍

给定一个图像文本对数据集$\{x^i,y^i\}_{i=1}^N$,N表示样本数量。图像字幕生成是为每张图像x^i生成最贴合

内容的字幕 y^i。每个字幕 y^i 都可以用一个 token 序列 $\boldsymbol{y}_1^i,\boldsymbol{y}_2^i,\cdots,\boldsymbol{y}_l^i$ 来表示，其中，l 是数据集中真实 token 序列的最大长度。训练过程中每个 token 序列都被填充到长度 l，训练目标如下：

$$\max_{\theta}\sum_{i=1}^{N}\ln p_\theta(\boldsymbol{y}_1^i,\boldsymbol{y}_2^i,\cdots,\boldsymbol{y}_l^i|x^i) \tag{1}$$

式中：θ 为训练参数，p 为生成真实 token 序列 $\boldsymbol{y}_1^i,\boldsymbol{y}_2^i,\cdots,\boldsymbol{y}_l^i$ 的概率。

本文将 CLIP 编码得到的嵌入转化为语义前缀，使用自回归语言模型逐个生成单词。具体来说，在已知输入 x^i 和前 $j-1$ 个 token 的情况下，最大化 $\boldsymbol{y}_j^i$ 的概率：

$$\max_{\theta}\sum_{i=1}^{N}\sum_{j=1}^{l}\ln p_\theta(\boldsymbol{y}_j^i|x^i,\boldsymbol{y}_1^i,\cdots,\boldsymbol{y}_{j-1}^i) \tag{2}$$

2.1　总体框架

受 Li 等[31]的启发，本文采用一种使用前缀引导语言模型生成图像字幕的方法，总体框架如图 1 所示。首先，将图像输入 CLIP 编码器，即 Vision Transformer[32] 网络中，获得一组嵌入。然后，将其与一组可学习常量嵌入拼接起来，并通过映射网络投影到语言空间生成字幕前缀。本文使用 Transformer 作为映射网络，并在此基础上提出了一种增强架构——RGFormer。每个 RGFormer 模块主要由一个残差多头注意力模块（residual multi-head attention，RMHA）和一个带有门控线性单元（gated linear unit，GLU）的前馈层组成。最后，将生成的字幕前缀与真实 token 嵌入进行拼接，并输入 GPT-2 中生成图像字幕。在训练期间，保持编码器和解码器冻结，只对映射网络进行训练，从而实现模型轻量化。

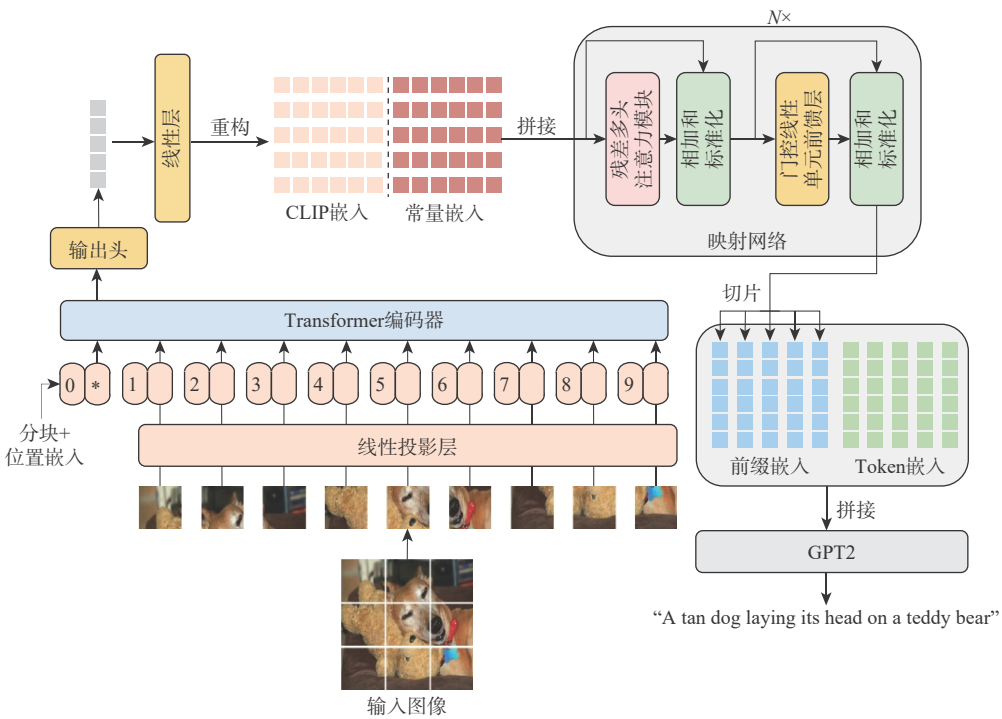


图 1　CRM 网络总体框架

Fig. 1　Overall structure of CRM

本文使用 CLIP 编码器从图像 x^i 中提取特征，得到一组嵌入向量 $\boldsymbol{e}_1^i,\boldsymbol{e}_2^i,\cdots,\boldsymbol{e}_k^i$。随后，将这组嵌入与一组可学习常量嵌入 $\boldsymbol{c}_1,\boldsymbol{c}_2,\cdots,\boldsymbol{c}_k$ 进行拼接，并传递给轻量级映射网络 F，以获得前缀嵌入 $\boldsymbol{p}_1^i,\boldsymbol{p}_2^i,\cdots,\boldsymbol{p}_k^i$：

$$\boldsymbol{p}_1^i,\boldsymbol{p}_2^i,\cdots,\boldsymbol{p}_k^i=F(\mathrm{Concat}(\boldsymbol{e}_1^i,\boldsymbol{e}_2^i,\cdots,\boldsymbol{e}_k^i,\boldsymbol{c}_1,\boldsymbol{c}_2,\cdots,\boldsymbol{c}_k)) \tag{3}$$

式中：k 表示前缀长度。本文使用 GPT-2 分词器对真实文本标签进行分词，获得一组 token 序列 $\boldsymbol{y}_1^i,\boldsymbol{y}_2^i,\cdots,\boldsymbol{y}_l^i$，随后将这些 token 编码为词嵌入向量：

$$\boldsymbol{t}_1^i,\boldsymbol{t}_2^i,\cdots,\boldsymbol{t}_l^i=\mathrm{TextEncoder}(\boldsymbol{y}_1^i,\boldsymbol{y}_2^i,\cdots,\boldsymbol{y}_l^i) \tag{4}$$

式中：TextEncoder 表示 GPT 文本编码器。每个 token 嵌入 $\boldsymbol{t}_x^i(x\in[1,l])$ 的维度与前缀嵌入 $\boldsymbol{p}_x^i(x\in[1,k])$ 相同，本文将其排列在一起，并输入 GPT-2 中。给定前缀，训练目标是使用自回归方法预测下一个 token。本文保持 CLIP 和 GPT-2 冻结，并使用简单有效的交叉熵损失来训练映射网络 F：

$$\mathcal{L}_x=-\sum_{i=1}^{N}\sum_{j=1}^{l}\ln p_\theta(\boldsymbol{t}_j^i|\boldsymbol{p}_1^i,\boldsymbol{p}_2^i,\cdots,\boldsymbol{p}_k^i,\boldsymbol{t}_1^i,\boldsymbol{t}_2^i,\cdots,\boldsymbol{t}_{j-1}^i) \tag{5}$$

2.2　图像编码器结构

CRM 编码器主要包括 3 个模块，如图 2(a)所示。首先，线性投影层将输入图像分割成一组块，并

将每个块展平为向量。在每个向量上添加位置编码后，将其输入 Transformer 编码器中。Transformer 编码器由多个堆叠的基础模块组成，如图 2(b)所示。每个模块主要包含一个多头注意力层和一个前馈层，其中，Lx 表示有 2 个模块堆叠。多头注意力机制使模型能够评估不同输入部分的重要性，前馈网络应用线性组合和非线性激活来增强模型的表达能力。最后，本文将输出头的结果通过线性变换重构为一组一维向量，每个向量的维度与 GPT-2 的词嵌入向量维度相匹配，以满足输入要求。

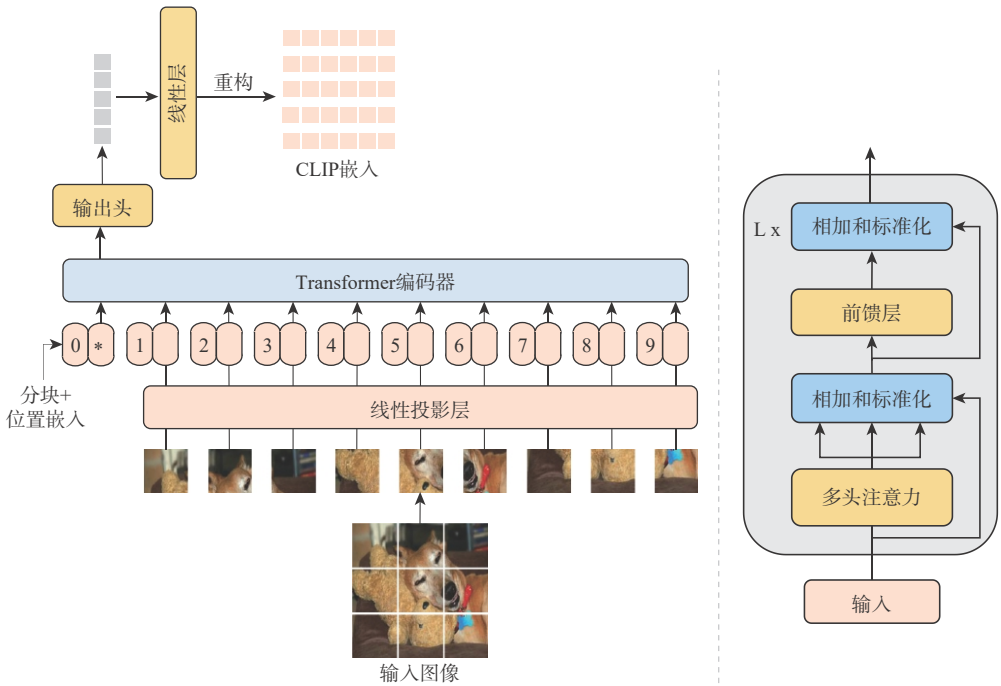


图 2 CRM 编码器和 Transformer 编码器

Fig. 2 Image encoder and Transformer encoder

CRM 编码器的前向传播过程如式(6)～式(10)所示。x_p^n表示图像块，$\boldsymbol{E}$表示线性投影层的权重矩阵，$\boldsymbol{E}_{\text{pos}}$表示位置编码，$\boldsymbol{z}_l$表示 Transformer 编码器的输出，$l$表示堆叠深度，$\boldsymbol{y}$表示输出头结果。MHA表示多头注意力，MLP表示前馈层，LN表示线性变换，Reshape表示张量重塑。编码器的最终输出结果是一组嵌入向量$\boldsymbol{cp}_1^i, \boldsymbol{cp}_2^i, \cdots, \boldsymbol{cp}_k^i$。

$$\boldsymbol{z}_0 = [x_{\text{prefix}}; x_p^1\boldsymbol{E}; x_p^2\boldsymbol{E}; \cdots; x_p^N\boldsymbol{E}] + \boldsymbol{E}_{\text{pos}} \tag{6}$$

$$\boldsymbol{z}'_l = \text{MHA}(\boldsymbol{z}'_{l-1}) + \boldsymbol{z}'_{l-1} \tag{7}$$

$$\boldsymbol{z}_l = \text{MLP}(\boldsymbol{z}'_l) + \boldsymbol{z}'_l \tag{8}$$

$$\boldsymbol{y} = \text{LN}(\boldsymbol{z}_l) \tag{9}$$

$$\boldsymbol{cp}_1^i, \boldsymbol{cp}_2^i, \cdots, \boldsymbol{cp}_k^i = \text{Reshape}(\text{LN}(\boldsymbol{y})) \tag{10}$$

2.3 映射网络结构

映射网络是本研究的重点，是实现模型跨模态能力的关键组件。该网络构建了视觉-语言共享空间，将提取的图像特征投影并转化为语义前缀，实现了模态间的转换。为了实现模型轻量化，同时避免微调语言模型，本文保持 CLIP 和 GPT-2 参数冻结，并采用 Transformer 作为映射网络。

Transformer 在文本序列任务上表现出色，但仍存在一定的局限性。Transformer 依靠注意力机制关注上下文信息，但堆叠的各个基础模块之间的关系相对独立。具体而言，每个模块计算得到的注意力分数仅受前一模块输出的影响，而更早期的原始注意力分数未得到有效保留。这种设计限制了模块之间的信息流动，可能导致重要信息的丢失。此外，由多个基础模块堆叠而成的深度神经网络可能存在梯度消失和爆炸问题，导致训练不稳定和收敛困难。

2.3.1 RGFormer 整体结构

为了解决上述问题，本文首先提出了 RMHA，用于替代 Transformer 原始注意力模块。RMHA 维护了一条注意力分数传播路径，以保留更多的原始信息。此外，将前馈层中的第 1 个线性层替换为 GLU，利用门控机制缓解梯度消失问题。基于这 2 个模块，本文提出了一种改进的 Transformer 架构——RGFormer，如图 3 所示。

2.3.2 残差多头注意力

多头注意力机制将注意力分散到各个子空间中，使模型可以学习多维特征信息。最后，将各子

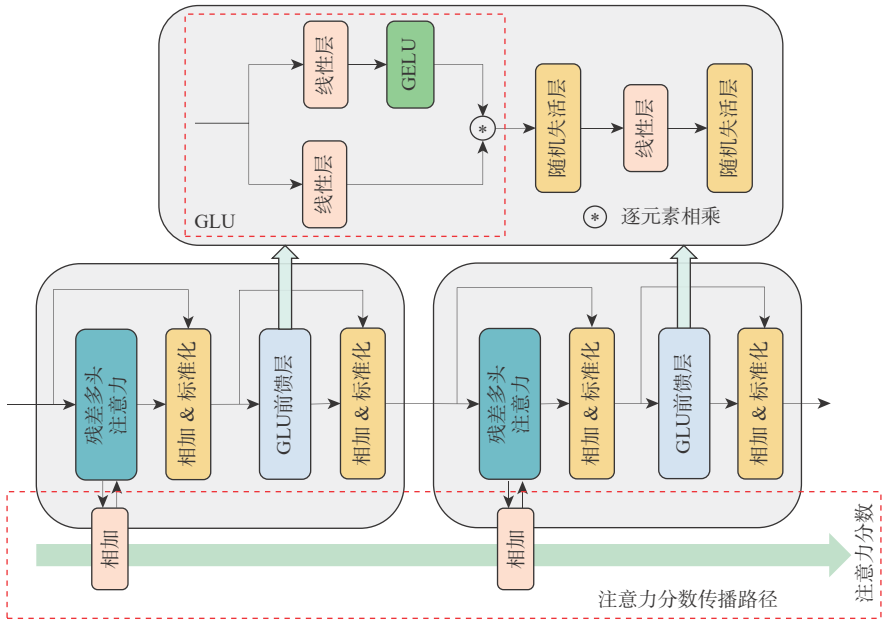


图 3　RGFormer 模块结构

Fig. 3　Structure of RGFormer module

空间的输出进行合并，具体计算过程如下：

$$\begin{cases} \boldsymbol{Q}_i = \boldsymbol{Q}\boldsymbol{W}_i^{\boldsymbol{Q}}, \boldsymbol{K}_i = \boldsymbol{K}\boldsymbol{W}_i^{\boldsymbol{K}}, \boldsymbol{V}_i = \boldsymbol{V}\boldsymbol{W}_i^{\boldsymbol{V}} \\ h_i = \text{Attention}(\boldsymbol{Q}_i, \boldsymbol{K}_i, \boldsymbol{V}_i) \\ \text{MultiHead}(\boldsymbol{Q}, \boldsymbol{K}, \boldsymbol{V}) = \text{Concat}(h_1, h_2, \cdots, h_n)\boldsymbol{W}^{\text{O}} \end{cases} \tag{11}$$

式中：$\boldsymbol{Q}$ 和 $\boldsymbol{K}$ 为维度为 d_k 的矩阵；$\boldsymbol{V}$ 为维度为 d_v 的矩阵；i表示子空间的索引；$\boldsymbol{W}_i^{\boldsymbol{Q}}$、$\boldsymbol{W}_i^{\boldsymbol{K}}$、$\boldsymbol{W}_i^{\boldsymbol{V}}$分别为将 $\boldsymbol{Q}$、$\boldsymbol{K}$、$\boldsymbol{V}$ 投影到子空间的矩阵；$\boldsymbol{W}^{\text{O}}$为对注意力头输出进行合并的权重矩阵。注意力函数采用使用缩放点积来实现，如下所示：

$$\text{Attention}(\boldsymbol{Q}, \boldsymbol{K}, \boldsymbol{V}) = \text{Softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\text{T}}}{\sqrt{d_k}}\right)\boldsymbol{V} \tag{12}$$

本文提出了一种改进的注意力模块 RMHA，旨在保留更多的原始特征和缓解梯度消失问题。RMHA 的核心思想是创建一条“直接”路径来传播注意力分数。具体来说，每个 RMHA 模块将传播注意力分数作为残差项添加到当前层的注意力分数矩阵中，并计算得到最终的注意力权重，如图 4 所示，其中，Block$N$ 表示堆叠的第 N 个模块。RMHA 具体计算过程如下所示：

$$\begin{cases} \text{RMHA}(\boldsymbol{Q}, \boldsymbol{K}, \boldsymbol{V}, \text{Prev}) = \text{Softmax}\left(\frac{\boldsymbol{Q}\boldsymbol{K}^{\text{T}}}{\sqrt{d_k}} + s\right)\boldsymbol{V} \\ s = s + \frac{\boldsymbol{Q}\boldsymbol{K}^{\text{T}}}{\sqrt{d_k}} \end{cases} \tag{13}$$

式中：s表示传播注意力分数。s通过迭代更新，使每个 RMHA 模块能够利用全局所有注意力分数。此外，RMHA 的残差结构能够有效缓解梯度消失问题，从而提升模型训练的稳定性。

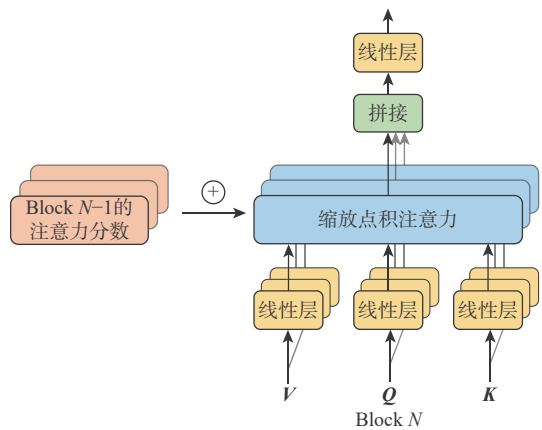


图 4　RMHA 模块结构

Fig. 4　Structure of RMHA module

2.3.3　门控线性单元前馈层

原始 Transformer 前馈层包含一个隐藏线性层，本文使用 GLU 进行替代。GLU 的核心思想是引入门控机制来增强网络的表达能力，其前向传播过程如下：

$$\text{GLU}(x, W_1, W_2, b_1, b_2) = \sigma(xW_1 + b_1) \otimes (xW_2 + b_2) \tag{14}$$

式中：σ表示激活函数；$\otimes$表示逐元素乘法；W和b表示权重和偏置。

本文使用 GELU 函数，相比于常用的 ReLU 等激活函数，GELU 更为连续和平滑，有助于梯度的稳定传播。GLU 由 2 个线性层“并联”组成，其中仅一个线性层包含激活函数。在前向传播过程中，输入向量进入 2 个分支，得到线性和非线性结果，随后逐元素相乘。GLU 通过门控机制选择性地激活输入特征，这使模型能够更有效地捕捉输入数据

中的关键信息，同时忽略不相关的部分。此外，GLU 同时保留了线性和非线性路径，在梯度的反向传播过程中有利于保持梯度的稳定，从而缓解梯度消失问题。

2.4 CRM 推理过程

GPT-2 使用Softmax来确定当前时间步生成词汇表中每个单词的概率。基于此，本文使用集束搜索算法，根据概率在每个时间步中选择若干候选词，并维持一个固定大小的候选集。具体而言，设定集束宽度为k，在每个时间步，算法根据当前候选序列的累积概率扩展新的候选词，并筛选出概率最高的k个序列继续迭代。最终，选择具有最高累积概率的词序列作为生成的图像字幕。图 5 展示了集束宽度为 2 的字幕生成过程，蓝色标注表示当前时间步累积概率最高的候选字符。集束搜索算法不仅提升了字幕的连贯性和语义一致性，还能够有效避免生成过程中的局部最优问题。

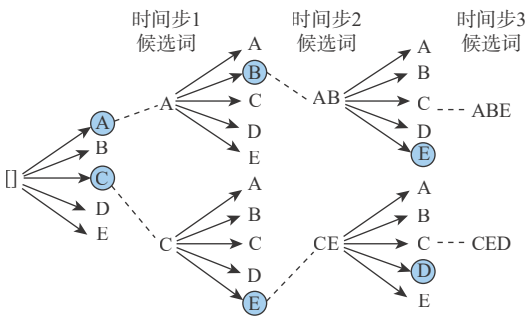


图 5 集束搜索算法

Fig. 5 Beam search algorithm

3 实验结果

3.1 数据集和对比模型

本文在 COCO Caption 数据集上进行实验，并按照 Karpathy 等[33] 的方法对数据集进行划分。训练集包含 120 000 幅图像，每幅图像对应 5 个标题。验证集和测试集各由 5 000 幅图像组成。

本文将CRM 与BUTD、VLP、VL-T5[34]、VLKD[35] 和 Oscar[3] 等方法进行比较。其中，BUTD、VLP 和 Oscar 均使用目标检测器提取图像区域级特征，并输入解码器以生成文本序列。BUTD 结合顶层注意力机制聚焦于检测到的物体，以生成细节丰富的字幕。VLP 的训练方法类似于 BERT，在数百万个图像文本对上进行了预训练以获取视觉-语言联合表征。Oscar 在预训练过程中利用检测到的对象标签作为锚点，将视觉特征与文本中的相应语义对齐，促进多模态信息的融合。VL-T5 使用基于 Transformer 的 T5[36] 模型，提出了一种多任务学习框架。通过预训练的联合编码器理解图片和文本之间的复杂关系，然后在下游任务上进行微调。VLKD 将 CLIP 文本编码器替换为预训练的 BART[37]，并通过知识蒸馏的方式让 BART 学习 CLIP 的跨模态知识，将文本特征映射到共享空间中。

3.2 评估指标和实验结果

3.2.1 评估指标

本文使用图像字幕生成任务中的常见指标，包括 SPICE[21]、BLEU@4[38]、METEOR[39] 和 CIDEr[40]，其中，SPICE 为语义命题型图像字幕评价指标，BLEU@4 为 4 元 BLEU，METEOR 为显序翻译评估指标，CIDEr 为基于共识的图像描述评价指标。在 COCO Caption 数据集上验证 CRM 的性能。此外，本文研究的目标是设计一种轻量化的图像字幕生成方法。因此，本文对比了 CRM 和基线模型的可学习参数规模和训练时间，以验证其轻量化效果。

3.2.2 定量评估

表 1 提供了 CRM 与各对比模型在 COCO Caption 数据集上的定量评估结果，表中加粗项表示对应列指标的最优结果。实验结果表明，CRM 在 SIPCE 指标上仅次于 VL-T5 和 Oscar，这是因为 SPICE 指标侧重于评估生成字幕在语义层次上的相似性。CRM 使用预训练的 CLIP 编码器提取图像特征，并结合增强的 RGFormer 映射网络实现跨模态信息转化，强调图像和文本之间的语义对齐，生成的描述具有较强的语义一致性和全局关联性。相比之下，BUTD 和 VLP 等模型可能更注重局部细节，容易忽略全局语义表达。在 BLEU@4、METEOR 和 CIDEr 指标上，CRM 略低于部分模型。一方面是因为其他模型具有更多的可学习参数，对复杂特征的表达能力更强；另一方面上述指

表 1 COCO Caption 数据集定量评估结果

Table 1 Quantitative evaluation on COCO caption dataset

模型	BLEU@4	METEOR	CIDEr	SPICE	参数规模	训练时间/h	设备型号
BUTD[1]	36.2	27.0	113.5	20.3	5.20×10^7	960	M40
VLP[14]	36.5	28.4	117.7	21.3	1.15×10^8	48	V100
VL-T5[34]	34.5	28.7	116.5	21.9	2.70×10^8		
VLKD[35]	34.1	27.5	114.3	21.0			
Oscar[3]	**36.58**	**30.4**	**124.12**	**23.17**	1.35×10^8	74	V100
CRM	33.61	27.85	114.60	21.67	$\mathbf{4.60\times10^7}$	**4**	3090 Ti

标更注重词汇匹配及语法结构的准确性。而CRM更强调轻量化和在不同场景中的泛化能力，生成的字幕通常具有更高的自由度和灵活性，可能不完全符合某些特定的语法结构。总的来说，CRM以更小的参数规模和更短的训练时间，达到了媲美主流方法的性能，在保证模型性能的前提下实现了轻量化。

3.2.3　定性评估

图6展示了CRM为从COCO Caption测试集中随机选择的图像生成的未经筛选的字幕。从结果来看，这些字幕都较准确地描述了图像的内容，值得注意的是，CRM能够识别一些不常见的物体。例如，CRM识别出了第4张图片的“double decker bus”，Ground Truth中并没有相应的描述，这归因于CLIP图像编码器在多样化大规模数据集上进行了预训练，具备一定的零样本推理能力。此外，CRM展现出一定的联想能力。在第1张图片中，通过识别“toilet”关联到“in a bathroom”，使字幕内容更为丰富。然而，结果表明模型也存在一定的不足，偶尔无法识别图像中的某些次要物体，如第1张图中的“glasses”或“hat”。相比之下，VLP在这方面的表现更优秀，因为VLP使用了Faster R-CNN对象检测器，并结合对象标签，从图像中提取区域级特征，更擅长捕捉图中的对象。



原图					
Ground Truth	Man in glasses and a cap sitting on the toilet.	A big cat laying down in a chair on a porch.	A small dog is curled up on top of the shoes.	Two red busses are traversing next to a tall brick building.	Three cows walking along the street in a town.
BUTD	A smiling man sitting on a toilet.	A cat siting in a blue chair.	A dog sleeping with some shoes.	Red buses driving down a street.	Two cows walking along the street.
VLP	A man in a hat sitting on a toilet.	A cat sitting on top of a chair.	A dog sleeping in the shoes.	Two red busses are driving on a street.	A few cows walking down the street in a town.
CRM	A man sitting on a toilet in a bathroom.	A cat is siting outside on a chair.	A dog laying on top of the shoes.	A red double decker bus driving down a street.	Black and white photograph of cows walking down a street.

图6　COCO Caption测试集中随机选择图像的未筛选结果

Fig. 6　Unfiltered results of randomly selected images from COCO Caption test set

为了更直观地展示RMHA模块的效果，本文选择图6中的第2和第3张图片进行注意力可视化，如图7所示，其中，蓝色到红色的渐变表示权重逐渐升高。实验结果表明，RMHA能够准确地聚焦于图像中的关键区域，如主体“cat”和“dog”，从而有效促进信息流动并增强模型的表达能力。

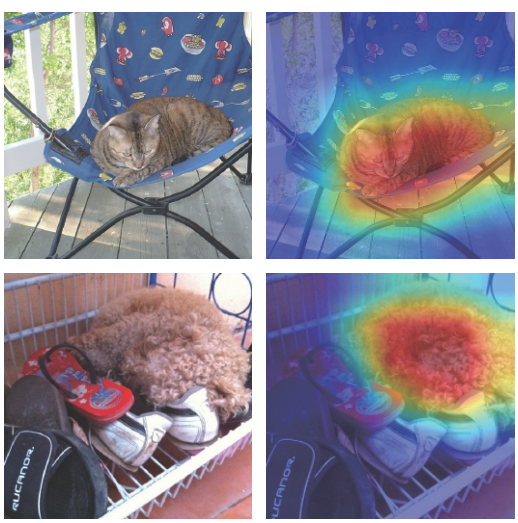


图7　注意力可视化结果

Fig. 7　Attention visualization results

定性实验结果表明，CRM在COCO Caption测试集上表现出了良好的性能。为了进一步评估模型的泛化能力，本文从网络上随机收集了一些图像并用CRM生成字幕，如图8所示。可以观察到，面对COCO Caption数据集之外的任意网络图片，CRM仍能够生成准确且有意义的字幕，表现出了优秀的泛化能力。

3.2.4　前缀长度实验

Li等[31]指出，增加前缀长度可以提升模型在下游任务中的表现。在前缀长度达到特定值后，模型性能将趋于稳定，达到的饱和值因下游任务而异。对于图像字幕生成任务，本文研究了不同前缀长度对模型性能的影响，在COCO Caption数据集上对具有不同前缀长度的CRM分别进行了4轮训练，并使用BLEU@4和CIDEr分数在训练集和测试集上进行了定量评估。

如图9所示，当前缀长度过小时，模型无法有效表达完整信息，性能较差。当前缀长度增加到约40时，模型在训练集和测试集上的表现趋于稳定，



BUTD: A group of people are riding skateboards
VLP: A group of kids riding skateboards on a wooden ramp
CRM: A group of young skateboarders pose for a picture



BUTD: There are some penguins and a man in a hat
VLP: A group of penguins are standing in the snow
CRM: A man standing in the snow with penguins around



BUTD: A street with many stores and a bicycle
VLP: A person walking down a street at night
CRM: A person walking down a narrow alley at night



BUTD: A man in a black hat swinging a bat
VLP: A baseball player swinging a bat at a ball
CRM: A baseball player swinging a bat during a game

图 8 CRM 为网络图片生成的字幕

Fig. 8 Captions for online pictures generated by CRM

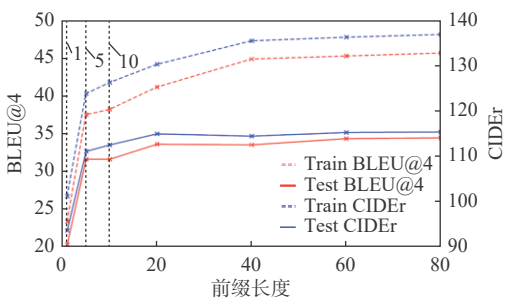


图 9 CRM 在不同前缀长度下的性能

Fig. 9 Performance of CRM under different prefix lengths

并且进一步增加前缀长度无法显著提升性能，反而会造成计算资源的浪费。考虑到 Transformer 在计算注意力权重时会产生较大的内存开销，本文在实验中将最大前缀长度设置为 80。

3.2.5 消融实验

本文进行了消融实验来验证 RGFormer 模块的有效性，结果如表 2 所示，表中，加粗项表示对应指标的最优结果。以原始 Transformer 作为映射网络的模型称为 CTM（CLIP transformer model）。实验结果表明，RMHA 模块和 GLU 模块均有助于提升 CTM 的性能，且 RMHA 模块的提升效果更明显。这是因为注意力机制是 Transformer 架构最核心的部分，直接决定了模型对输入数据的理解和处理能力。RMHA 能够有效地保留并传递重要的注意力信息。相比之下，前馈层更多作用在特征转换和非线性表示上。引入 GLU 能够提升非线性表达能力，但对模型整体性能的影响相对有限。当将 RMHA 和 GLU 组合成 RGFormer 作为映射网络时，模型表现出优于单独使用任一模块的性能指标。

表 2 RGFormer 消融实验结果

Table 2 Results of ablation experiment of RGFormer

模型	BLEU@4	METEOR	CIDEr	SPICE
CTM	33.53	27.45	113.08	21.05
CTM+RMHA	33.59	27.73	114.27	21.56
CTM+GLU	33.50	27.62	113.49	21.23
CTM+RGFormer(CRM)	**33.61**	**27.85**	**114.60**	**21.67**

4 结 论

1）CRM 在图像字幕生成任务中以更轻量化的结构取得了良好的性能，在 COCO Caption 测试集上的 BLEU@4、METEOR、CIDEr、SPICE 指标分数分别为 33.61、27.85、114.60、21.67，可与 BUTD 和 VLP 等先进方法相媲美，且参数和训练时间大大减少；

2）RGFormer 相较于原生 Transformer 提升了性能，其中，RMHA 模块通过残差结构连接前后注意力模块，保留了更多的原始注意力信息，GLU 前馈层通过门控机制选择性激活输入特征，增强了模型的表达能力。

3）脱离了使用目标检测器提取图像区域级特征的传统形式。CRM 无需额外的监督标签或进行耗时的目标检测过程，实现了轻量化。

4）CRM 使用 RGFormer 为映射网络，有效地将 CLIP 提取的图像特征映射到文本空间中，解决了图像字幕生成任务跨模态的难点。

5）CRM 聚焦于更轻量化的结构，以更低的训练成本实现了良好的性能。但由于舍弃了目标检测器，在一些图像中可能无法识别到次要物体，存在一定局限性。

参考文献（References）

[1] Anderson P, He X D, Buehler C, et al. Bottom-up and top-down at-

tention for image captioning and visual question answering [C]//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway Palo Alto: IEEE Press, 2018: 6077-6086.

[2] Chen X L, Zitnick C L. Learning a recurrent visual representation for image caption generation[EB/OL]. (2014-11-20)[2024-12-18]. https://doi.org/10.48550/arXiv.1411.5654.

[3] Li X J, Yin X, Li C Y, et al. Oscar: object-semantics aligned pre-training for vision-language tasks[C]//Computer Vision-ECCV 2020. Cham: Springer International Publishing, 2020: 121-137.

[4] Stefanini M, Cornia M, Baraldi L, et al. From show to tell: a survey on deep learning-based image captioning[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(1): 539-559.

[5] Tan H, Bansal M. LXMERT: learning cross-modality encoder representations from transformers[EB/OL]. (2019-12-03)[2024-12-20]. https://doi.org/10.48550/arXiv.1908.07490.

[6] Xu K, Ba J L, Kiros R, et al. Show, attend and tell: neural image caption generation with visual attention[C]//International Conference on Machine Learning. New York: ACM, 2015: 2048-2057.

[7] Yao T, Pan Y W, Li Y H, et al. Exploring visual relationship for image captioning[C]//Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 711-727.

[8] Radford A, Kim J W, Hallacy C, et al. Learning transferable visual models from natural language supervision[C]//International Conference on Machine Learning. Virtual Event: PMLR, 2021: 8748-8763.

[9] Chen X L, Fang H, Lin T Y, et al. Microsoft COCO captions: data collection and evaluation server[EB/OL]. (2015-04-03)[2024-12-20]. https://doi.org/10.48550/arXiv.1504.00325.

[10] Lin T Y, Maire M, Belongie S, et al. Microsoft COCO: common objects in context[C]//Computer Vision-ECCV 2014. Cham: Springer International Publishing, 2014: 740-755.

[11] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2015-04-10)[2024-12-20]. https://arxiv.org/abs/1409.1556.

[12] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 770-778.

[13] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.

[14] Zhou L, Palangi H, Zhang L, et al. Unified vision-language pre-training for image captioning and VQA[C]//Proceedings of the 34th AAAI Conference on Artificial Intelligence Palo Alto: AAAI Press, 2020: 13041-13049.

[15] Conde M V, Turgutlu K. CLIP-art: contrastive pre-training for fine-grained art classification[C]//Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Piscataway: IEEE Press, 2021: 3951-3955.

[16] Zhang R R, Zhang W, Fang R Y, et al. Tip-adapter: training-free adaption of CLIP for few-shot classification[C]//Computer Vision-ECCV 2022. Cham: Springer Nature Switzerland, 2022: 493-510.

[17] Liu H D, Xu S Y, Fu J M, et al. CMA-CLIP: cross-modality attention CLIP for image-text classification[EB/OL]. (2021-12-09)[2024-12-21]. https://arxiv.org/abs/2112.03562.

[18] Vidit V, Engilberge M, Salzmann M. CLIP the gap: a single domain generalization approach for object detection[C]//Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2023: 3219-3229.

[19] Teng Z, Duan Y N, Liu Y, et al. Global to local: clip-LSTM-based object detection from remote sensing images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5603113.

[20] Gu X Y, Lin T Y, Kuo W C, et al. Open-vocabulary object detection via vision and language knowledge distillation[EB/OL]. (2022-05-12)[2024-12-21]. https://doi.org/10.48550/arXiv.2104.13921.

[21] Anderson P, Fernando B, Johnson M, et al. SPICE: semantic propositional image caption evaluation[C]//Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 382-398.

[22] Yong C, Fei H, Lian Z, et al. A hierarchical multimodal attention-based neural network for image captioning[J]. ACM SIGIR Forum, 2017, 51(CD): 889-892.

[23] Ji J Y, Luo Y P, Sun X S, et al. Improving image captioning by leveraging intra-and inter-layer global representation in transformer network[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2021, 35(2): 1655-1663.

[24] Luo Y P, Ji J Y, Sun X S, et al. Dual-level collaborative transformer for image captioning[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2021, 35(3): 2270-2277.

[25] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.

[26] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//Advances in Neural Information Processing Systems. Long Beach: Curran Associates, Inc. , 2017, 30: 5998-6008.

[27] Devlin J, Chang M W, Lee K, et al. BERT: pre-training of deep bidirectional transformers for language understanding[EB/OL]. (2019-05-24)[2024-12-24]. https://doi.org/10.48550/arXiv.1810.04805.

[28] Lu J, Batra D, Parikh D, et al. Vilbert: pretraining task-agnostic visiolinguistic representations for vision-and-language tasks[J]. Advances in neural information processing systems, 2019, 32.

[29] Radford A, Wu J, Child R, et al. Language models are unsupervised multitask learners[J]. OpenAI Blog, 2019, 1(8): 9.

[30] Zhang P C, Li X J, Hu X W, et al. VinVL: revisiting visual representations in vision-language models[C]//Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2021: 5575-5584.

[31] Li X L, Liang P. Prefix-tuning: optimizing continuous prompts for generation[EB/OL]. (2021-01-01)[2024-12-25]. https://doi.org/10.48550/arXiv.2101.00190.

[32] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16x16 words: transformers for image recognition at scale[EB/OL]. V2. (2021-06-03)[2024-12-25]. https://doi.org/10.48550/arXiv.2010.11929.

[33] Karpathy A, Li F F. Deep visual-semantic alignments for generating image descriptions[C]//Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2015: 3128-3137.

[34] Cho J, Lei J, Tan H, et al. Unifying vision-and-language tasks via text generation[C]//International Conference on Machine Learning. Virtual Event: PMLR, 2021: 1931-1942.

[35] Sun L, Li Y W, Dong Y M. Learning from expert: vision-language knowledge distillation for unsupervised cross-modal hashing retrieval[C]//Proceedings of the 2023 ACM International Conference on Multimedia Retrieval. New York: ACM, 2023: 499-507.

[36] Raffel C, Shazeer N, Roberts A, et al. Exploring the limits of transfer learning with a unified text-to-text transformer[J]. Journal of Machine Learning Research, 2020, 21(140): 1-67.

[37] Lewis M, Liu Y H, Goyal N, et al. BART: denoising sequence-to-sequence pre-training for natural language generation, translation, and comprehension[EB/OL]. (2019-10-29)[2024-12-25]. https://doi.org/10.48550/arXiv.1910.13461.

[38] Papineni K, Roukos S, Ward T, et al. Bleu: a method for automatic evaluation of machine translation[C]//Proceedings of the 40th Annual Meeting of the Association for Computational Linguistics. Philadelphia: Association for Computational Linguistics, 2002: 311-318.

[39] Denkowski M, Lavie A. Meteor universal: language specific translation evaluation for any target language[C]//Proceedings of the Ninth Workshop on Statistical Machine Translation. Philadelphia: Association for Computational Linguistics, 2014: 376-380.

[40] Vedantam R, Zitnick C L, Parikh D. CIDEr: consensus-based image description evaluation[C]//Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2015: 4566-4575.

Visual language model based on improved Transformer

JIN Zehui[1], CHEN Kai[1,*], TANG Dunbing[1], FANG Guoyu[1], WEN Feixia[2]

(1. College of Mechanical and Electrical Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;
2. Nanjing Research Institute of Electronic Engineering, Nanjing 210007, China)

Abstract: Natural language processing and computer vision are combined in the cross-modal job of image captioning. The model is required to generate an appropriate caption for the given image. To address this challenge, we proposed residual gated Transformer (RGFormer) as an enhancement of the Transformer architecture. The model, based on CLIP and RGFormer, CRM, is then proposed for image captioning. CRM utilizes the encoder of CLIP to extract image features as a prefix to the caption. RGFormer, a lightweight mapping network, projects the prefix into language space before feeding it into GPT-2 to produce captions. CLIP was trained on an extensive dataset comprising image-text pairs, which contains rich visual and semantic information and is exceptionally well-suited for vision-language tasks. The core idea of CRM is to reduce the disparity between visual and textual representations by using RGFormer to accomplish the cross-modal task. CRM could generate meaningful captions for large-scale datasets in a short training time without additional annotations or pre-training. Quantitative evaluation experiments show that CRM achieves results comparable to some advanced models on the COCO Caption dataset more efficiently.

Keywords: image caption; CLIP; Transformer; gated linear unit; residual multi-head attention

Received: 2024-09-05; **Accepted**: 2025-02-14; **Published Online**: 2025-03-19 11:16

URL: link.cnki.net/urlid/11.2625.V.20250318.1741.006

Foundation items: National Natural Science Foundation of China (52202417); China Postdoctoral Science Foundation (2022TQ0155,2022M721605); Open Project Program of State Key Laboratory of Virtual Reality Technology and Systems, Beihang University (VRLAB2023A02), Young Elite Scientists Sponsorship Program by CAST (2023QNRC001); The Fundamental Research Funds for the Central Universities (NS2024030); Young Elite Scientists Sponsorship Program by JSTJ (JSTJ-2023-XH032)

* **Corresponding author**. E-mail: chen_kai@nuaa.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0546

基于熵权-TOPSIS的多机悬吊系统工作空间稳定性评价

李威，赵志刚*，赵祥堂，李子轩，江政
(兰州交通大学 机电工程学院，兰州 730070)

摘 要：针对多机悬吊系统工作空间稳定性难以评价的问题，提出一种基于熵权-优劣解距离法(TOPSIS)的稳定性评价方法，建立多维度工作空间来表征工作空间稳定性分布。通过分析系统的运动学和动力学特性，提出位置性能指标、姿态性能指标及拉力均匀性性能指标等影响多机悬吊系统稳定性的指标。采用熵权法(EWM)与层次分析法(AHP)计算各性能指标的复合权重确定各指标的相对重要性，运用TOPSIS对工作空间内各位置点的稳定性能进行计算。以定末端的多机悬吊系统为例仿真计算，评价工作空间位置点的稳定性，并绘制不同稳定性能区间内的多维度工作空间。仿真结果表明：随稳定性能增加，多维度工作空间向中心和上部收缩，表明多机悬吊系统工作空间中间区域和上部区域的稳定性较优。多维度工作空间为多机悬吊系统的构型优化提供了理论基础。

关 键 词：多机器人系统；悬吊系统；稳定性；多维度工作空间；优劣解距离法；熵权法
中图分类号：TP242.2
文献标志码：A **文章编号**：1001-5965(2026)11-4029-11

多机悬吊系统是一种典型的刚柔耦合的并联机器人，通过控制柔索的收放来实现被吊运物的运动[1-2]。相较于传统的绳牵引并联机器人和单机器人吊运系统，不仅具备高度灵活性和简洁的结构，还具有较低的惯性和更大的工作空间[3]。但柔性绳索本身的刚度较低，且柔索只能对被吊运物体施加单向的拉力，导致系统在面对外部干扰时的抗扰动能力较弱。在系统工作空间中，不同区域的稳定性不同，准确评价多机悬吊系统工作空间中各位置点的稳定性高低对完成吊运任务具有重要意义，而提升多机悬吊系统工作空间稳定性是当前研究中的一大挑战。

从20世纪80年代开始，国内外学者从不同的角度对绳牵引并联机器人的稳定性进行了研究。文献[4]将重力视为绳索，将柔索视为直线弹簧，利用系统总刚度矩阵来评估绳牵引并联机器人稳定性。文献[5]使用了Hessian矩阵分析了悬吊系统的静平衡稳定性，并探讨了多机悬吊系统的构型问题，但未考虑柔索拉力对稳定性的影响。文献[6]研究了欠约束柔索并联机器人的基于斜率的稳定性评价方法，也没有考虑柔索拉力对被吊运物运动稳定性的影响。文献[7]对一类绳牵引并联机构的结构进行了分析，使用动平台的位姿运动敏感性作为评价指标对绳牵引并联机构的稳定性进行评价。文献[8]对一类三自由度柔索并联机器人的布置方式进行设计，优化了机构的稳定性。文献[9]利用加权方法对影响柔索驱动并联机器人动平台运动稳定性的位置与拉力指标进行加权分析，并分析了各因素对动平台运动稳定性的重要程度。文献[10]针对4-1型柔索驱动并联机器人，提出一种融合机器人末端执行器位置和约束力影响因子的稳定性评价方法及其指标。文献[11]将柔索驱动

收稿日期：2024-07-18；**录用日期**：2024-09-23；**网络出版时间**：2024-09-27 10:28
网络出版地址：link.cnki.net/urlid/11.2625.V.20240926.1735.002
基金项目：国家自然科学基金(51965032)；甘肃省自然科学基金(22JR5RA319)
*通信作者. E-mail：zhaozhg@mail.lzjtu.cn

引用格式：李威，赵志刚，赵祥堂，等. 基于熵权-TOPSIS的多机悬吊系统工作空间稳定性评价[J]. 北京航空航天大学学报，2026，52(11)：4029-4039. Li W，Zhao Z G，Zhao X T，et al. Workspace stability evaluation of multi-engine suspension system based on EWM-TOPSIS[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：4029-4039 (in Chinese).

并联机器人的稳定性从0或1推广到区间[0,1],通过稳定性值的大小来评估动平台在该位置点的稳定性能。文献[12]提出了一种基于索张力测定的稳定性指标,根据稳定性指标设计了机构的稳定工作空间,但没有讨论拉力均匀性对机构稳定性的影响。文献[13]以多机悬吊系统的运动学和动力学为基础,提出了综合多性能指标的位置稳定性评价方法,但没有分析几种性能指标对系统性能影响的权重。除此之外,许多学者也对机器人工作空间的性能分布进行了研究。文献[14]求解了6轴工业机器人的最大工作空间,分析了位姿准确度和位姿重复性等性能指标在工作空间内部的分布。文献[15]提出了一种多量纲变量统一表达的并联机构多维度工作空间表示法,表达了刚性并联机构的全域工作空间和性能空间,但是没有对绳牵引并联机构的工作空间性能分布进行研究。文献[16]分析了不同构型刚柔复合驱动并联喷涂机器人的可行姿态角在工作空间内的分布,综合工作空间体积等性能指标,优选了最佳构型。

现有文献对多机悬吊系统这类绳牵引并联机构的稳定性研究较为有限,缺乏综合分析各性能指标对稳定性的影响研究,也少有关于工作空间性能表征的探讨。不同性能指标对悬吊系统运动的影响程度不同,因此,各指标的权重也应不同。然而,现有的稳定性评价研究常将各性能指标的权重视为相等,这限制了各指标对系统稳定性真实影响的准确反映。

建立多机悬吊系统稳定性评价模型,分析工作空间不同区域的稳定程度,对系统的构型优化至关重要。本文创新点如下:

1)基于多机悬吊系统的运动学、动力学模型,定义了拉力均匀性、位置、姿态等性能指标,以便更准确地评估多机悬吊系统的稳定性。

2)使用层次分析法-熵权法(analytic hierarchy processentropy-entropy weight method, AHP-EWM)计算3种性能指标的权重。定义稳定性能对多机悬吊系统工作空间不同位置点的稳定性进行量化。采用逼近理想解排序法(technique for order preference by similarity to ideal solution, TOPSIS)法对系统工作空间内各个位置点的稳定性能进行计算。

3)依据稳定性能,建立多维度工作空间。多维度工作空间可以表征多机悬吊系统的工作空间不同区域的稳定性能分布。

4)对多维度工作空间进行仿真实验,仿真结果表明,多维度工作空间可以准确地表征稳定性能分布,工作空间高性能的位置点主要分布在工作空间中心及上部区域。

1 多机悬吊系统运动学和动力学模型

1.1 系统构型及分类

多机悬吊系统是由3自由度串联机器人组成、使用柔性绳索吊运同一物体的系统。m台吊机固定在地面上,通过一根可调节长度的柔索与被吊运物相连,对被吊运物的n个自由度进行精确控制,从而实现被吊运物位姿的调整,并顺利完成吊运作业。系统的构型详见图1。

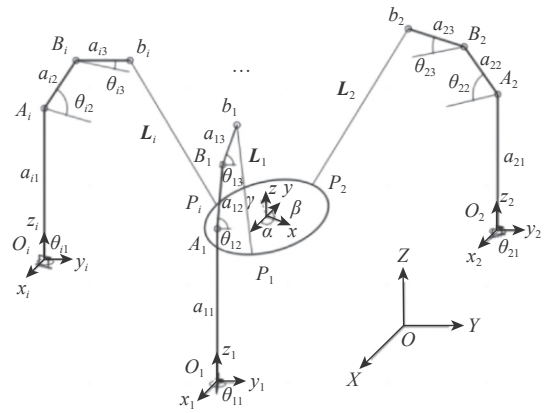


图1 悬吊系统空间构型

Fig. 1 Spatial configuration of the suspension system

图1中,O-XYZ为全局坐标系,O'-xyz为物体坐标系;在吊机靠近地面第1个关节的中心建立局部坐标系O_i-$x_iy_iz_i$,各坐标轴方向与O-XYZ一致。吊机为3关节机器人,O_i、A_i、B_i为第i台吊机的转动关节,初始位置均处于水平平面。a_{ij}为第i台吊机的第j根机械臂的长度(j=1,2,3),θ_{ij}为第i台吊机第j个关节处相对初始位置的转动量,$\boldsymbol{L}_i$为柔索的空间位置矢量,b_i为第i根柔索与第i台吊机末端连接点,P_i为吊点。多机悬吊系统在静力学平衡的研究中,输入量为θ_{ij}和柔索长度l_i,输出量为被吊运物的广义坐标(x, y, z, α, β, γ),其中,x、y、z分别为吊运物质心在X、Y、Z轴方向的位移量,α、β、γ分别为被吊运物绕X、Y、Z轴方向的转动量。通过系统输入量的改变控制输出量来满足不同的吊运任务需求。

根据驱动方式可以将多机悬吊系统分为定柔索长度、定末端、柔索长度和机器人末端位置同时变化3种构型。本文研究对象为定末端系统构型,对多机悬吊系统稳定性进行研究,该构型柔索的数目m=3,被吊运物自由度n=6。当$m\geqslant 3$时,所用研究方法及所得结论仍可成立。

1.2 系统运动学和动力学建模

由图1所示几何关系可知,多机悬吊系统的柔

索长度 l_i 为

$$l_i=\sqrt{(x_{P_i}-x_{b_i})^2+(y_{P_i}-y_{b_i})^2+(z_{P_i}-z_{b_i})^2}\quad i=1,2,3 \tag{1}$$

式中: $(x_{P_i},y_{P_i},z_{P_i})$为机器人末端在 *O-XYZ*中位置点 P_i 的坐标, $(x_{b_i},y_{b_i},z_{b_i})$为柔索与被吊运物的连接点在 *O-XYZ*中吊点 b_i 的坐标, 柔索与被吊运物的连接点由局部坐标向全局坐标通过齐次变换关系转换所得的坐标为

$$\begin{bmatrix}x_{P_i}\\y_{P_i}\\z_{P_i}\end{bmatrix}=\begin{bmatrix}x\\y\\z\end{bmatrix}+{}^{O}\boldsymbol{R}_{P}\begin{bmatrix}{}^{P}x_{P_i}\\{}^{P}y_{P_i}\\{}^{P}z_{P_i}\end{bmatrix}\qquad i=1,2,3 \tag{2}$$

式中: $[{}^{P}x_{P_i},{}^{P}y_{P_i},{}^{P}z_{P_i}]^{\mathrm{T}}$为 P_i 在 *O′-xyz*中的位置坐标, ${}^{O}\boldsymbol{R}_{P}$为旋转矩阵。

$$\begin{aligned}{}^{O}\boldsymbol{R}_{P}&=\boldsymbol{R}_z(\gamma)\boldsymbol{R}_y(\beta)\boldsymbol{R}_x(\alpha)=\\&\begin{bmatrix}\cos\gamma&-\sin\gamma&0\\\sin\gamma&\cos\gamma&0\\0&0&1\end{bmatrix}\begin{bmatrix}\cos\beta&0&\sin\beta\\0&1&0\\-\sin\beta&0&\sin\beta\end{bmatrix}\cdot\\&\begin{bmatrix}1&0&0\\0&\cos\alpha&-\sin\alpha\\0&\sin\alpha&\cos\alpha\end{bmatrix}\end{aligned} \tag{3}$$

式中: $\boldsymbol{R}_x(\alpha)$ 为绕 x 轴的基本旋转矩, α 为绕物体坐标系 z 轴转角; $\boldsymbol{R}_y(\beta)$ 绕 y 轴的基本旋转矩阵, β 为绕物体坐标系 y 轴转角; $\boldsymbol{R}_z(\gamma)$ 绕 z 轴的基本旋转矩阵, γ 为绕物体 z 轴转角。

被吊运物的运动速度为$(\boldsymbol{v},\boldsymbol{\omega})$, $\boldsymbol{v}$ 为被吊运物的平移速度, $\boldsymbol{\omega}$ 为被吊运物的角速度, 且有

$$\boldsymbol{v}=\left(\frac{\mathrm{d}x}{\mathrm{d}t},\frac{\mathrm{d}y}{\mathrm{d}t},\frac{\mathrm{d}z}{\mathrm{d}t}\right) \tag{4}$$

$$\boldsymbol{\omega}=\left(\frac{\mathrm{d}\alpha}{\mathrm{d}t},\frac{\mathrm{d}\beta}{\mathrm{d}t},\frac{\mathrm{d}\gamma}{\mathrm{d}t}\right) \tag{5}$$

多机悬吊系统的运动学方程由式 (1) 给出。机器人的数量等于柔索的数量, 也等于运动学方程的数量。由式 (1)～ 式 (5) 可以得到多机悬吊系统的运动学方程。

由于柔索相对于多机悬吊系统来说质量较轻, 因此, 被吊运物在吊运过程中, 通常可以忽略柔索自身的质量、弹性形变及由柔索自身质量产生的悬链线效应。基于这一假设, 可以将被吊运物的力旋量平衡方程表示为

$$\boldsymbol{J}^{\mathrm{T}}\boldsymbol{T}=\boldsymbol{F} \tag{6}$$

式中: $\boldsymbol{T}$ 为多机悬吊系统的拉力矩阵, $\boldsymbol{T}=[T_1,T_2,T_3]^{\mathrm{T}}$, T_1、T_2、T_3 为各柔索的拉力大小, $T_i\in(t_{\min},t_{\max})$为第 i 根柔索上的拉力介于柔索最小拉力 $t_{\min}$ 及柔索极限拉力 $t_{\max}$ 之间, 其中 i=1,2,3。 $\boldsymbol{F}$为被吊运物受到的外力旋量, 其为由 6 个分量组成的列向量, 表达式为

$$\boldsymbol{F}=\left[\left(M\frac{\mathrm{d}\boldsymbol{v}}{\mathrm{d}t}\right)^{\mathrm{T}},\left([\boldsymbol{J}_x,\boldsymbol{J}_y,\boldsymbol{J}_z]\frac{\mathrm{d}\boldsymbol{\omega}}{\mathrm{d}t}\right)^{\mathrm{T}}\right]^{\mathrm{T}} \tag{7}$$

式中: M 为被吊运物的质量大小; $\boldsymbol{J}_x$、$\boldsymbol{J}_y$、$\boldsymbol{J}_z$分别为被吊运物绕 x、y、z 坐标轴的旋转惯量; t 为时间。

$\boldsymbol{J}^{\mathrm{T}}=[\boldsymbol{J}_1,\boldsymbol{J}_2,\boldsymbol{J}_3]$为悬吊系统的结构矩阵, 且有

$$\boldsymbol{J}_i=\begin{bmatrix}\boldsymbol{e}_i\\({}^{O}\boldsymbol{R}_{P}{}^{P}\boldsymbol{P})\times\boldsymbol{e}_i\end{bmatrix} \tag{8}$$

式中: ${}^{P}\boldsymbol{P}$ 为吊点 P_i 转换到全局坐标系的位置矢量; $\boldsymbol{e}_i$为柔索的单位向量, 即

$$\boldsymbol{e}_i=\frac{\boldsymbol{L}_i}{\|\boldsymbol{L}_i\|}=\frac{{}^{O}\boldsymbol{P}_i-{}^{O}\boldsymbol{b}_i}{\|{}^{O}\boldsymbol{P}_i-{}^{O}\boldsymbol{b}_i\|}\qquad i=1,2,3 \tag{9}$$

由式 (6)～式 (9) 可得到系统的动力学模型。使用最小二乘法联立以上静力学平衡方程求解, 可以得到 3 根柔索拉力的大小。

$$\boldsymbol{J}^{\mathrm{T}}(\boldsymbol{J}\boldsymbol{T}+\boldsymbol{F})=0\Rightarrow\boldsymbol{T}=(\boldsymbol{J}^{\mathrm{T}}\boldsymbol{J})^{-1}[\boldsymbol{J}^{\mathrm{T}}(-\boldsymbol{F})] \tag{10}$$

2　多机悬吊系统稳定性分析

2.1　稳定性描述

多机悬吊系统通过柔索驱动精确控制被吊运物体, 外界干扰可能导致被吊物体的运动状态变化, 进而影响整个系统的动态平衡。因此, 多机悬吊系统的运动稳定性可定义为: 系统在面对外部干扰时, 维持被吊运物预定运动轨迹和姿态, 顺利完成吊运任务的能力。

本文评估多机悬吊系统的稳定性是对被吊运物在工作空间内任意位置点的稳定程度进行评估。为量化不同位置点被吊运物的稳定性, 引入稳定性能的概念衡量各位置点的稳定水平。

多机悬吊系统的稳定性受柔索拉力分布、被吊运物的姿态和空间位置等因素影响, 这些因素共同决定不同位置点的稳定性高低。为此, 定义了 3 种性能指标, 包括被吊运物的位置、姿态和柔索拉力, 综合评价系统的稳定性。采用 TOPSIS 对这些指标进行多维度综合评估。

2.2　位置性能指标

在多机悬吊系统中, 使用位置性能指标σ表示被吊运物的位置, 其表达式为

$$\sigma=\left(\frac{l_1+l_2+l_3}{3l_{\max}}\right)\left(\frac{l_{\min}}{l_{\max}}\right) \tag{11}$$

式中: l_1、l_2、l_3为被吊运物处于工作空间该位置点时的各柔索长度; $l_{\max}$ 为 3 根柔索中最长一根柔索的长度, $l_{\min}$ 为 3 根柔索中最短一根柔索的长度。

通过多机悬吊系统的运动学方程来定义位置性能指标 σ, 表示被吊运物质心 P 距离多机悬吊系统工作空间的竖直中线 MQ 以及系统工作空间上

表面几何中心 M 点的距离，如图 2 所示。其中 M 和 Q 点均为工作空间上下表面的几何中心。

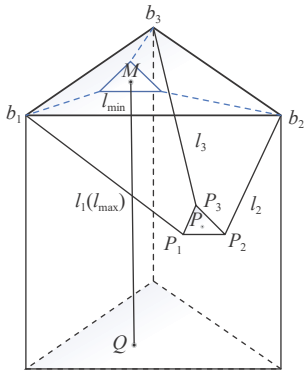


图 2 位置性能指标示意图

Fig. 2 Schematic diagram of location performance indicators

位置性能指标 $\sigma\in(0,1]$，当 σ 增加的时候，表示被吊运物位置向工作空间中心靠上区域移动，此时柔索拉力逐渐增大，系统的刚度逐渐提升。这增强了被吊运物抵抗外部干扰的能力，从而提高多机悬吊系统的稳定性。

2.3 姿态性能指标

分析多机悬吊系统构型可知，在静力学平衡时，绕 Z 轴旋转的 γ 角不影响稳定性。在评估姿态对被吊运物稳定性影响时，主要考虑绕 X 和 Y 轴旋转的 α 和 β 角。当 α 和 β 接近 0°时，被吊运物姿态稳定；当 α 或 β 接近± π/2 rad 时，可能发生柔索虚牵的情况，导致多机悬吊系统不稳定。因此，在实际吊运中应避免这种情况发生。

引入姿态性能指标 ζ 来衡量多机悬吊系统被吊运物的姿态稳定程度：

$$\zeta=\frac{\pi/2-\max(|\alpha|,|\beta|)}{\pi/2} \tag{12}$$

式中：$\zeta\in[0,1]$。被吊运物的姿态角 α 与 β 均为 0°时，ζ=1，此时被吊运物的姿态平稳，被吊运物运动稳定性最高；反之当 α 或 β 为±π/2 rad 时，ζ=0，此时柔索虚牵，拉力失衡，被吊运物处于极不稳定的情况。

2.4 拉力均匀性性能指标

使用 3 根柔索拉力之和与其中拉力最大柔索拉力的比值来定义拉力均匀性性能指标 τ：

$$\tau=\left(\frac{T_1+T_2+T_3}{3T_{\max}}\right) \tag{13}$$

式中：T_1、T_2、T_3 为第 1、2、3 根柔索的拉力；$T_{\max}$ 为 3 根柔索中拉力最大柔索的拉力。

拉力均匀性性能指标 $\tau\in(0,1]$，当 T_1=T_2=T_3 时，τ=1，柔索的拉力分布更加均匀，被吊运物的平稳性更好，反之各柔索之间拉力差别越大，τ 越小，被吊运物越不平稳。

3 基于熵权-TOPSIS 的多机悬吊系统稳定性评价模型

多机悬吊系统在工作空间内不同区域的稳定性各不相同，每个位置点的稳定性能也有所差异。需要一种可视化的方法准确反映稳定性能的分布。此外，不同指标对系统稳定性的影响程度也不同。为正确计算各指标的权重，本文采用 EWM 确定权重，并结合 AHP 进行修正。利用 TOPSIS 对工作空间内各位置点的稳定性能进行计算，并将稳定性能 Ω_S 以颜色映射到工作空间中，建立多维度工作空间。这些研究为多机悬吊系统的构型优化提供了理论基础。

3.1 AHP-EWM 赋权

在评估多机悬吊系统工作空间不同位置点的稳定性时，不同性能指标在评价模型中的权重不同，而现有研究通常将各指标权重视为相等，这与实际情况相悖。本文采用 EWM 确定性能指标的客观权重，这是一种通过信息量确定指标权重的客观方法，特别适用于多指标的权重确定，确保评估结果更为客观。在确定拉力均匀性、位置和姿态 3 个指标的权重时，每个工作空间位置点都被视为评价对象。

汇总位置性能指标、拉力均匀性性能指标及姿态性能指标构成原始矩阵：

$$\boldsymbol{X}=\begin{bmatrix}\tau_{n'1} & \sigma_{n'2} & \zeta_{n'3}\end{bmatrix}^{\mathrm{T}}=(x_{i'j'})_{n'\times 3}=\begin{bmatrix}x_{11} & x_{12} & x_{13}\\ x_{21} & x_{22} & x_{23}\\ \vdots & \vdots & \vdots\\ x_{n'1} & x_{n'2} & x_{n'3}\end{bmatrix} \tag{14}$$

式中：$\boldsymbol{X}$ 为原始数据矩阵；$x_{i'j'}$ 为第 i' 个评价对象的第 j' 个性能评价指标；j'=1,2,3。n' 为评价的对象，等于工作空间位置点的数目。

为使各性能指标转化为正向指标，需要对原始矩阵正向化，对影响多机悬吊系统稳定性的各性能指标进行趋同化处理。令

$$A=\max(x_{1j'},x_{2j'},\cdots,x_{n'j'}) \tag{15}$$

$$B=\min(x_{1j'},x_{2j'},\cdots,x_{n'j'}) \tag{16}$$

$$x'_{i'j'}=\frac{x_{i'j'}-B}{A-B} \tag{17}$$

原始的性能指标经过正向化处理之后，即可得到正向化矩阵 $\boldsymbol{X}'$：

$$\boldsymbol{X}'=(x'_{i'j'})_{n'\times 3}=\begin{bmatrix}x'_{11} & x'_{12} & x'_{13}\\ x'_{21} & x'_{22} & x'_{23}\\ \vdots & \vdots & \vdots\\ x'_{n'1} & x'_{n'2} & x'_{n'3}\end{bmatrix} \tag{18}$$

由于各性能指标之间量纲不同，需要对性能指

标进行归一化处理, 以消除不同量纲的影响, 使原始数据介于区间 [0,1], 得到标准化矩阵 $\boldsymbol{Z}$:

$$\boldsymbol{Z}=\left(z_{i'j'}\right)_{n'\times 3}=\frac{x'_{i'j'}}{\sqrt{\sum_{i'=0}^{n'}x'^{2}_{i'j'}}}=\begin{bmatrix} z_{11} & z_{12} & z_{13} \\ z_{21} & z_{22} & z_{23} \\ \vdots & \vdots & \vdots \\ z_{n'1} & z_{n'2} & z_{n'3} \end{bmatrix} \tag{19}$$

式中: $z_{i'j'}$为第 j'项指标下第 i'个评价对象占该指标的比重, 有 n 行评价对象, 3 列评价指标。

通过概率矩阵可以计算第 j'项指标下第 i'个样本值占该指标的比重:

$$p_{i'j'}=\frac{z_{i'j'}}{\sum_{i'=1}^{n'}z_{i'j'}} \tag{20}$$

由式 (20) 可以得到各性能指标的熵值 $C_{j'}$:

$$C_{j'}=-\frac{\sum_{i'=1}^{n'}p_{i'j'}\ln p_{i'j'}}{\ln n'}\qquad j'=1,2,3 \tag{21}$$

计算第 j'项指标的信息熵冗余度:

$$g_{j'}=1-C_{j'}\qquad j'=1,2,3 \tag{22}$$

由式 (14)～式 (22) 可以得到多机悬吊系统各性能指标的熵权ω_{E}:

$$\omega_{\mathrm{E}}=\frac{g_{j'}}{\sum_{j'=1}^{3}g_{j'}}\qquad j'=1,2,3 \tag{23}$$

由式(14)～式(23)可以求得影响多机悬吊系统稳定性的各性能指标的熵权, EWM 是一种客观的赋权方法, 通过评估指标数据的离散程度来确定权重。然而, 由于数据误差可能对结果产生较大影响, 为更符合实际情况, 本文使用 AHP 对 EWM 进行修正。

由于被吊运物姿态失稳时往往伴随受力不均衡, 物体会通过位置偏移自发回归受力平衡状态, 该过程中被吊运物的拉力与位置同步发生改变。被吊运物姿态由自身位置与拉力状态共同决定, 因此, 在多机悬吊系统稳定性评价中, 姿态性能指标的重要程度最低。结合文献 [17] 的研究结论, 在系统参数保持一致的条件下, 增大位置性能指标权重、减小拉力均匀性性能指标权重时, 被吊运物整体稳定性逐步提升, 这表明位置性能指标对吊运物体运动稳定性的影响更为突出。综合上述分析可得 3 个性能指标的重要性排序: 位置性能指标＞拉力均匀性性能指标＞姿态性能指标。

本文采用 AHP 确定各性能指标的主观权重 ω_{A}, 如表 1 所示。针对位置性能指标σ、拉力均匀性性能指标τ、姿态性能指标ζ, 构建两两比较判断矩阵, 矩阵采用 1–9 标度法完成指标间相对重要性赋值。由矩阵赋值结果可见, 在所研究的多机悬吊评价问题中, 指标σ重要性最高, τ次之, ζ重要性最低。后续基于该判断矩阵求解各指标权重, 并开展一致性检验, 以保证专家主观判断逻辑不存在显著矛盾。

表 1　性能指标行因素相对于列因素的重要程度得分

Table 1　Score of the importance degree of row factors with respect to column factors for performance index

性能指标	重要程度得分		
	τ	σ	ζ
τ	1	1/2	3
σ	2	1	4
ζ	1/3	1/4	1

比较优先判断矩阵, 通过 AHP 计算得到 ω_{A} = [0.319 6, 0.558 4, 0.122 0]。为验证判断矩阵设计的合理性, 进行一致性检验[18]。表达式见式 (24), 随机一致性指标如表 2 所示。

$$C_{\mathrm{R}}=\frac{\lambda_{\max}-n}{(s-1)R_{\mathrm{I}}} \tag{24}$$

式中: R_{I}为随机一致性指标; s 为矩阵维数; $\lambda_{\max}$为矩阵最大特征值; C_{R} 为一致性检验指标。

表 2　随机一致性指标

Table 2　Random consistency indicators

矩阵维数	R_{I}
1	0
2	0
3	0.58
4	0.89
5	1.12
6	1.24

根据矩阵的一致性指标, 当 n=3 时, R_{I}=0.58, 代入数值得 C_{R}=0.015 776<0.1, 表示矩阵符合一致性检验, 各指标权重比例具有科学性。

将 AHP 与 EWM 结合, 通过式 (25) 计算得到复合权重ω_{S}:

$$\omega_{\mathrm{S}}=\frac{\omega_{\mathrm{E}}\omega_{\mathrm{A}}}{\sum_{i=1}^{3}\omega_{\mathrm{E}}\omega_{\mathrm{A}}} \tag{25}$$

通过 AHP-EWM 得到 3 个性能指标的权重之后, 使用 TOPSIS 法对工作空间内各位置点的稳定性能进行计算, 实现对多机悬吊系统工作空间稳定性的综合评价。

3.2　TOPSIS 法综合评价

评估多机悬吊系统工作空间稳定性时, 需要计

算所有位置点的稳定性能。通过获取各位置点的性能数据，可以建立系统中所有性能指标的理想最优解和最劣解。TOPSIS方法通过特定计算确定每个位置点相对于理想最优解和最劣解的综合距离，来评估工作空间各位置点的稳定性。距离理想最优解越近且距离最劣解越远的位置点稳定性越高；反之，稳定性越低。

使用TOPSIS法综合多机悬吊系统各性能指标权重，构建性能评估体系来评估系统稳定性。该方法不仅能够确定工作空间内不同位置点的稳定性能Ω_{S}，还能直观地反映被吊运物在每个位置点的稳定程度，为系统构型优化提供关键参考。

通过式(19)得到的标准化矩阵$\boldsymbol{Z}$定义正理想值D^{+}与负理想值D^{-}：

$$D^{+}=\max|\boldsymbol{Z}_{i1},\boldsymbol{Z}_{i2},\cdots,\boldsymbol{Z}_{in}| \qquad i=1,2,\cdots,n \tag{26}$$

$$D^{-}=\min|\boldsymbol{Z}_{i1},\boldsymbol{Z}_{i2},\cdots,\boldsymbol{Z}_{in}| \qquad i=1,2,\cdots,n \tag{27}$$

计算各性能指标与D^{+}、D^{-}的欧氏距离：

$$D_i^{+}=\sqrt{\sum_{j=1}^{3}\omega_{\mathrm{E}}(Z_j^{+}-z_{ij})^2} \tag{28}$$

$$D_i^{-}=\sqrt{\sum_{j=1}^{3}\omega_{\mathrm{E}}(Z_j^{-}-z_{ij})^2} \tag{29}$$

计算该位置点的稳定性能Ω_{S}：

$$\Omega_{\mathrm{S}}=\frac{D_i^{-}}{D_i^{+}+D_i^{-}} \tag{30}$$

通过TOPSIS法，可得多机悬吊系统的工作空间不同位置点的稳定性能Ω_{S}，$\Omega_{\mathrm{S}}\in[0,1]$，不同位置点的稳定性不同，当$\Omega_{\mathrm{S}}$=0时，说明位置点与理想性能最劣点重合，此时该位置点的稳定性能最低，多机悬吊系统的稳定性最差。随着Ω_{S}的增加，位置点的稳定性能增加，当Ω_{S}=1时，说明位置点与理想性能最优的点重合，此时与理想性能最劣点的距离最远，该位置点的稳定性能最高，多机悬吊系统的稳定性最优，通过TOPSIS法可以对多机悬吊系统工作空间的稳定性能进行计算。

3.3 多维度工作空间

建立多机悬吊系统的稳定性评价模型后，基于TOPSIS法结合拉力均匀性性能指标、位置性能指标、姿态性能指标求解工作空间位置点稳定性能，建立多性能指标融合全域表达的多维度工作空间。多维度工作空间具体定义为：对于3根柔索控制的6自由度的多机悬吊系统，将每一个性能指标作为一个维度，多维度综合对静力学平衡工作空间位置点P的稳定性能进行评价。将稳定性能评分颜色映射到位置点P，评价后的位置点P的集合构成了多机悬吊系统的多维度工作空间。

在求解多维度工作空间时，给定稳定性能Ω_{S}的区间，求解在该区间内的所有位置点，并将Ω_{S}颜色映射到该位置点。多维度工作空间求解步骤如下：

1）定义多机悬吊系统的构型参数，稳定性能Ω_{S}的区间、吊机的姿态变换范围、被吊运物的质心位置的范围及吊机末端的坐标。

2）使用Monte Carlo法循环N次，随机给出被吊运物的位置及姿态。

3）在每次循环内，按式(1)计算出3根柔索的长度，利用式(6)～式(9)计算出结构矩阵$\boldsymbol{J}$，判断$\boldsymbol{J}$是否发生降秩。如果发生降秩，则本循环停止，进行下一循环；如果没有降秩，则根据式(10)计算每根柔索的拉力。

4）判断每次循环中3根柔索的拉力大小T_i，如果$T_i\in[0,T_{\max}]$，则使用式(11)～式(13)计算该位置点的各性能指标τ、ζ、σ。

5）汇总记录计算的性能指标，使用EWM通过式(23)计算指标的客观权重，并使用式(25)得到复合权重。

6）使用TOPSIS法通过式(30)计算位置点的稳定性能Ω_{S}，若Ω_{S}属于给定区间，则将Ω_{S}颜色映射到该位置点上，符合条件的位置点的集合组成了多机悬吊系统的多维度工作空间。

4 实例仿真

以3台吊运机器人协作吊运一个重物为例，如图3所示。

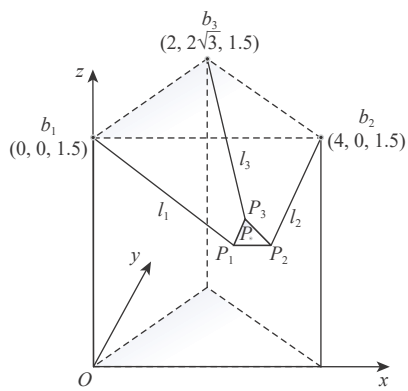


图3 机器人末端位置示意图

Fig. 3 Schematic diagram of the robot end position

多机悬吊系统的相关参数如表3所示。

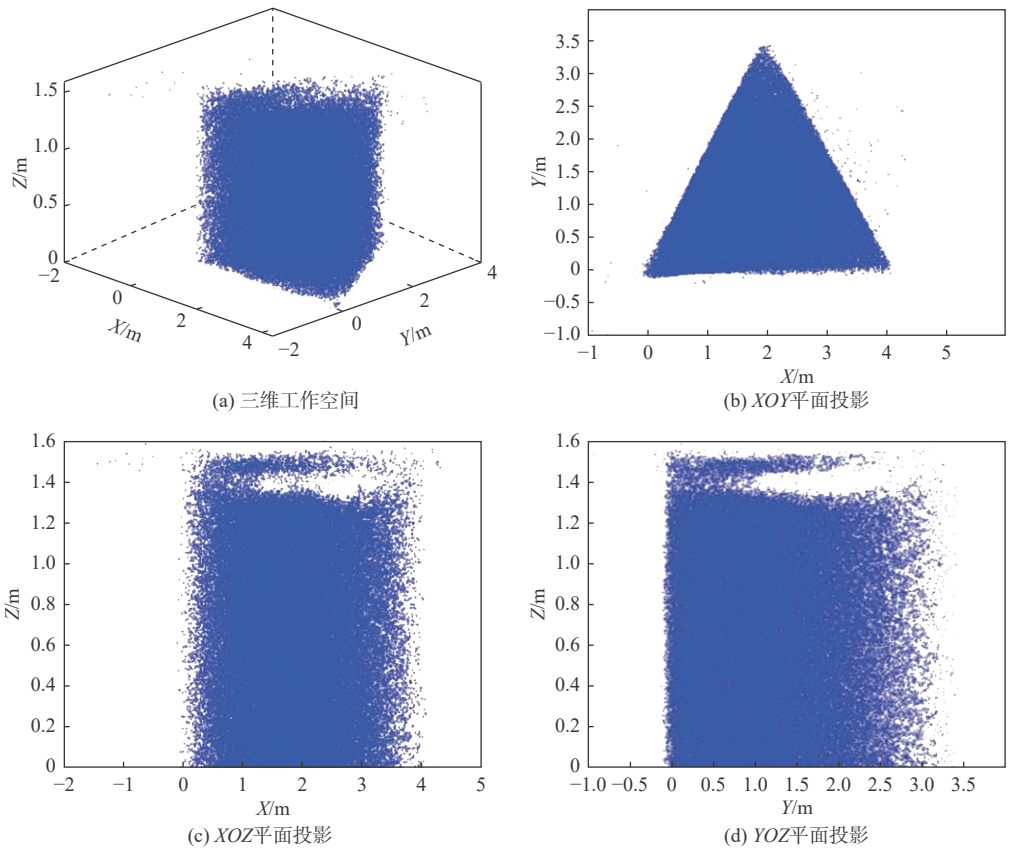
循环10万次，求解多机悬吊系统的静力学平衡工作空间，并求解各性能指标及权重，对工作空间的稳定性能进行计算，得到多机悬吊系统的多维度工作空间。

多机悬吊系统的静力学平衡工作空间如图4所示。经过10万次循环测试，可以观察到多机悬

表 3　悬吊机器人模型参数

Table 3　Model parameters of suspended robot

被吊运物质量M_p/kg	索拉力下限t_{min}/N	索拉力上限t_{max}/N	绕X轴旋转姿态角α/rad	绕Y轴旋转姿态角β/rad	1#末端位置b_1/m	2#末端位置b_2/m	3#末端位置b_3/m
10	0	400	$(-\pi/2, \pi/2)$	$(-\pi/2, \pi/2)$	$(0,0,1.5)^T$	$(4,0,1.5)^T$	$(2,2\sqrt{3},1.5)^T$



(a) 三维工作空间　(b) *XOY*平面投影

(c) *XOZ*平面投影　(d) *YOZ*平面投影

图 4　静力学平衡工作空间仿真结果

Fig. 4　Static balance workspace simulation results

吊系统静力学平衡工作空间空间具有明确的界限。由于循环次数的限制, 边界区域的工作空间点分布较为稀疏。总体, 该工作空间的几何形状大致为直三棱柱, 有 335 个位置点游离在约束范围之外, 这是由于计算时算法的特性所产生的, 实际吊运中这些点是很难抵达的。静力学平衡工作空间总体分布与多机悬吊系统末端位置布局基本一致。

通过式 (23) 计算得到 3 个性能指标的客观权重, 得到熵权 $\omega_E=[\tau,\sigma,\zeta]=[0.247\,4,0.479\,8,0.272\,8]$, 结合$\omega_A$通过式 (25) 得到多机悬吊系统的性能指标的复合权重$\omega_S=[0.207\,9,0.704\,5,0.087\,6]$。

在 EWM 和 AHP 所计算的结果中, 权重系数最大的均为位置性能指标σ, 权重因子占比都接近 0.5。而 EWM 计算的姿态性能指标ζ的权重大于拉力均匀性性能指标τ, 这是由于 EWM 在计算的过程中依赖数据本身的变异程度, 被吊运物的姿态波动影响了 EWM 计算的结果, 在实际吊运过程当中, 被吊运物可以在姿态不平稳时自动调节姿态, 使被吊运物的状态趋于稳定, 因此, 在进行稳定性评价时, 姿态对多机悬吊系统的稳定性贡献较小, 权重最低。这时需要使用 AHP 对 EWM 进行修正, 修正之后得到的复合权重: $\sigma > \tau > \zeta$。较为合理地反映了 3 个性能指标对多机悬吊系统稳定性的影响程度。

得到性能指标的权重后, 使用 TOPSIS 法对多机悬吊系统工作空间位置点的稳定性能进行综合评价, 如图 5 所示。稳定性能Ω_S呈中间高两头低的

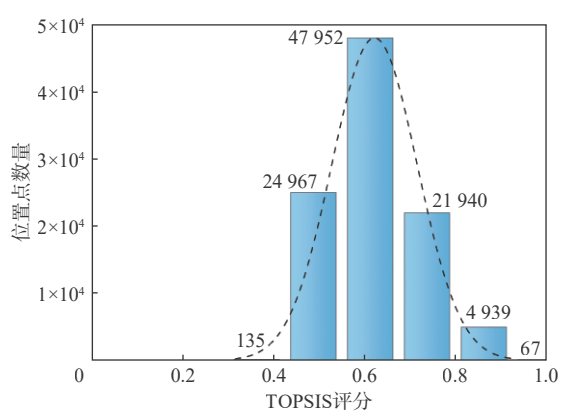
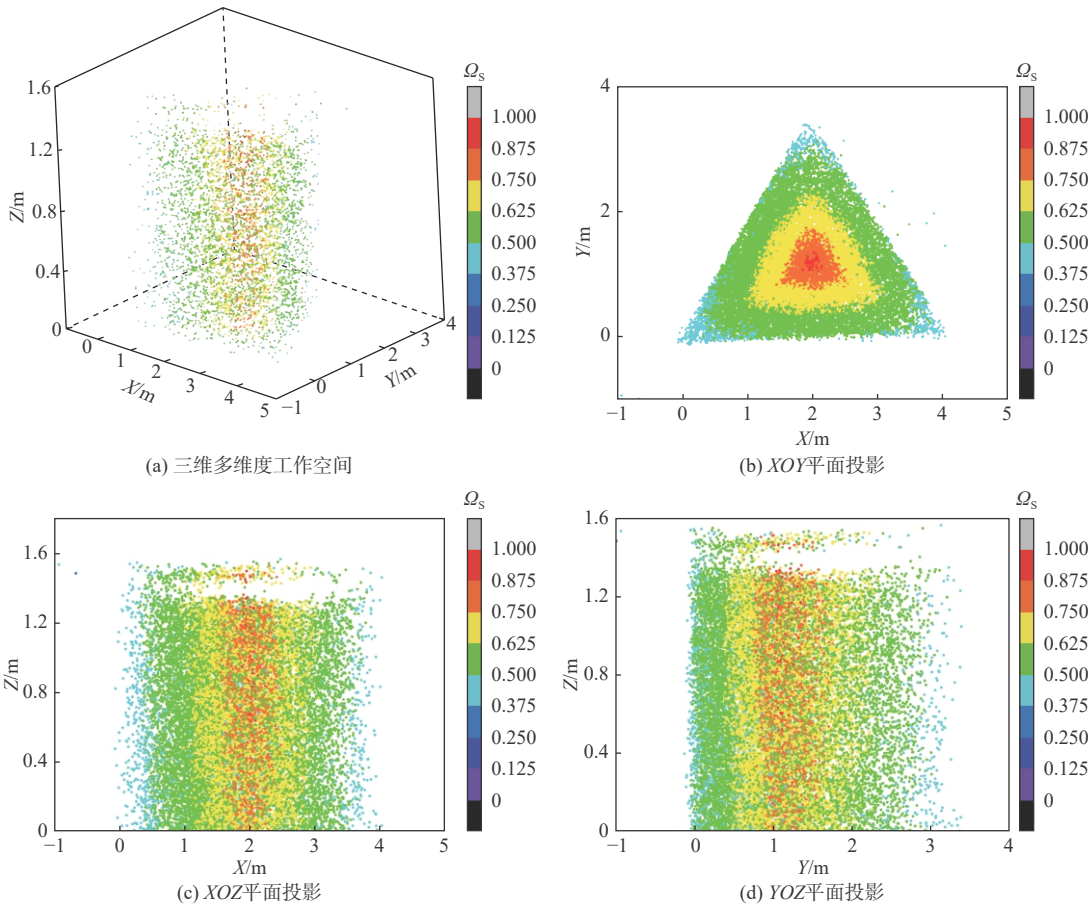


图 5　TOPSIS 评分分布

Fig. 5　TOPSIS score distribution

分布趋势，Ω_S多分布于区间 [0.4,0.8]。

按照第 3 节所述的步骤将 TOPSIS 法得到的稳定性能Ω_S颜色映射到原工作空间中，得到多机悬吊系统的多维度工作空间，综合反映多机悬吊系统工作空间稳定性能的分布，多维度工作空间如图 6 所示。不同的颜色代表不同的稳定性评分，从多维度工作空间 *XOY* 平面投影可以明显看出，多机悬吊系统的Ω_S主要呈现阶梯分布，从外到内Ω_S逐渐增加，机械臂末端位置附近的工作空间位置点的颜色主要为浅蓝色，代表稳定性能$\Omega_S \in [0,0.5]$，该区域的稳定程度较低。内部的Ω_S呈弧三角形向心逐渐增加，其中，工作空间中心位置点的稳定性能最高，Ω_S接近 1。



(a) 三维多维度工作空间　(b) *XOY*平面投影

(c) *XOZ*平面投影　(d) *YOZ*平面投影

图 6　$\Omega_S \in [0,1]$ 时的多维度工作空间

Fig. 6　Multi-dimensional workspace at $\Omega_S \in [0,1]$

使用 Alpha Shape 算法可以对多维度工作空间进行边界拟合，并使用数值积分法求解工作空间体积。得到不同评分区间内的工作空间体积变化，如图 7 所示。可以看出，当$\Omega_S \in [0.7,1]$ 时，相比于$\Omega_S \in [0,1]$，位置点数目减少至 20 479 个，下降 79.18%；工作空间体积从 10.472 m^3 减少至 1.905 6 m^3，下降 81.80%，而当$\Omega_S \in [0.8,1]$ 时，相对于$\Omega_S \in [0.7,1]$，位置点数目减少至 5 006 个，下降 75.87%；工作空间体积从 1.905 6 m^3 减少至 0.463 3 m^3，下降 75.69%。这说明，随着稳定性能的增加，在多机悬吊系统的工作空间中，工作空间的位置点数目逐渐减少，工作空间体积也逐步下降。在实际吊运任务当中，往往对被吊运物的稳定性有一定要求，需要被吊运物在稳定性能较高的区域内运动，这对工作空间的稳定性能提出了要求，需要求解稳定性能更好的工作空间。

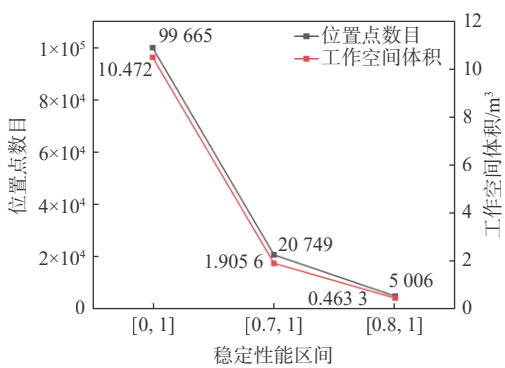
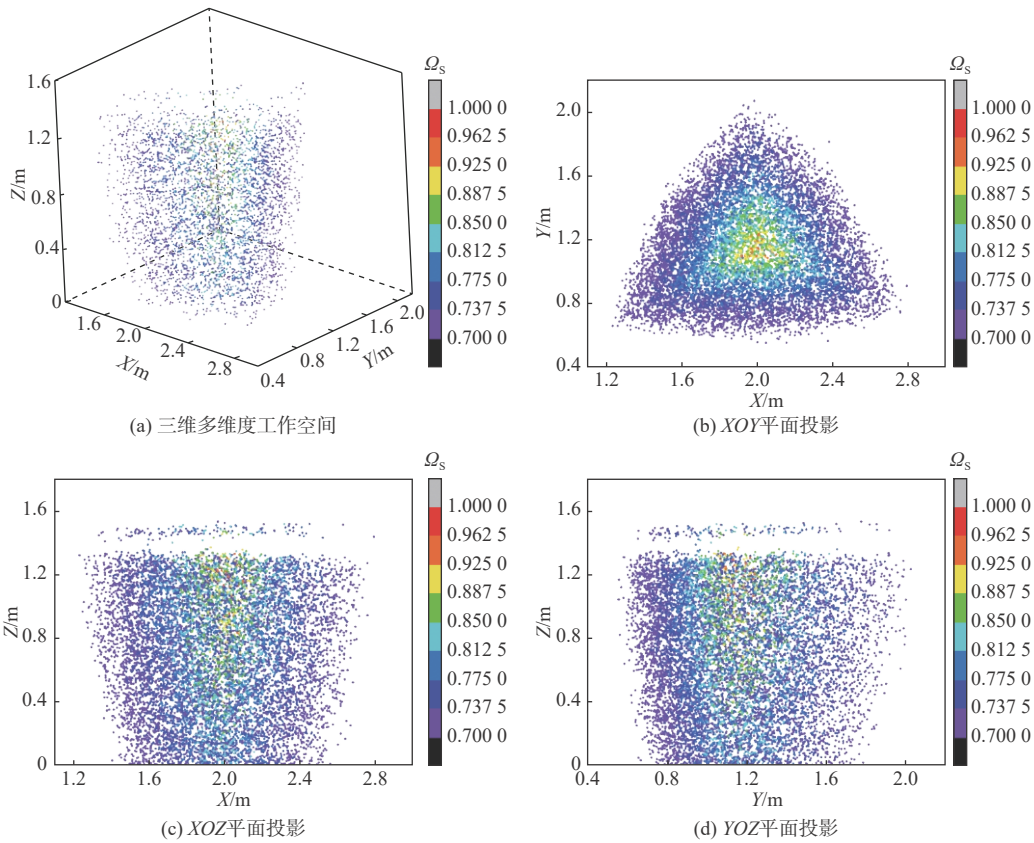


图 7　不同稳定性能区间的多维度工作空间变化

Fig. 7　Multi-dimensional workspace changes in different stability performance intervals

求解$\Omega_S \in [0.7,1]$ 和$\Omega_S \in [0.8,1]$ 的多维度工作空间，如图 8 和图 9 所示。可以看出，当Ω_S增加时，多机悬吊系统的多维度工作空间呈倒三棱台的形状，边界也从直边三角形更接近弧三角形，表明工作空间中心区域的稳定性能优于工作空间边界区域。

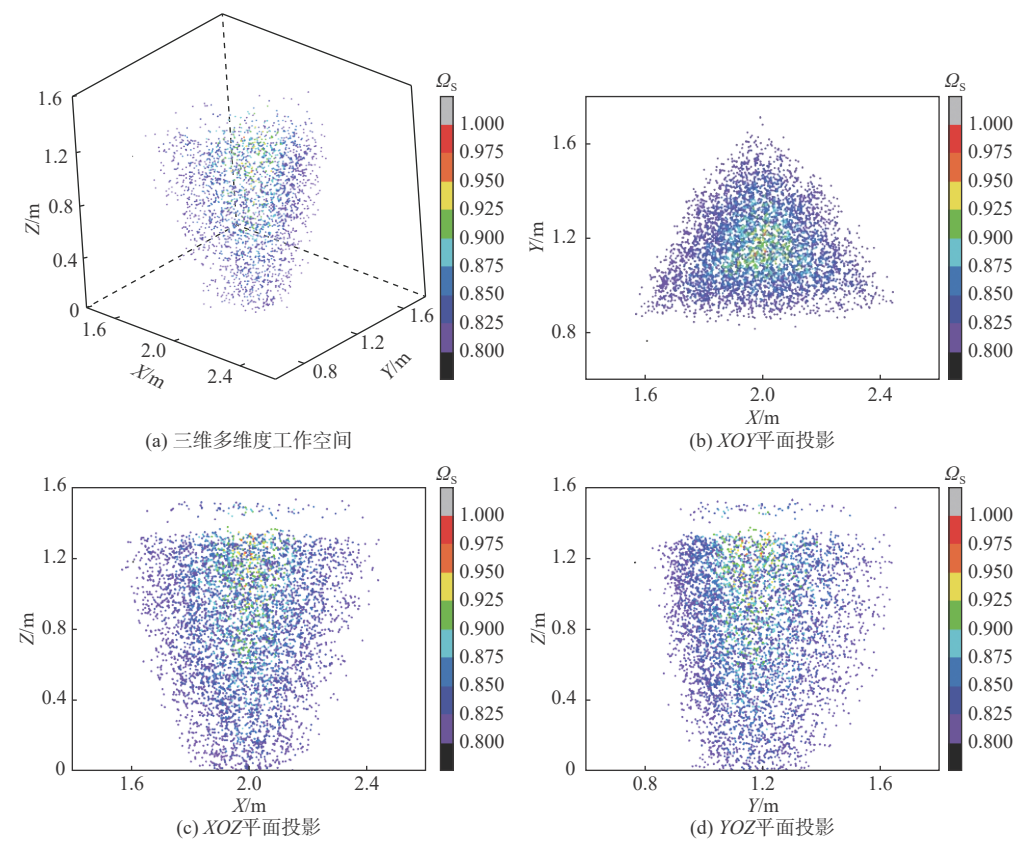


(a) 三维多维度工作空间　(b) *XOY*平面投影

(c) *XOZ*平面投影　(d) *YOZ*平面投影

图 8　$\Omega_S \in [0.7,1]$ 时的多维度工作空间

Fig. 8　Multi-dimensional workspace at $\Omega_S \in [0.7,1]$



(a) 三维多维度工作空间　(b) *XOY*平面投影

(c) *XOZ*平面投影　(d) *YOZ*平面投影

图 9　$\Omega_S \in [0.8,1]$ 时的多维度工作空间

Fig. 9　Multi-dimensional workspace at $\Omega_S \in [0.8,1]$

图8和图9相比图6,多维度工作空间下部体积减小尤为突出,进一步表明工作空间的稳定性能由下而上逐渐增加,工作空间上部运动稳定程度优于工作空间底部。通过对比图8与图9可知,在不同的Q_S区间内,稳定性能评分接近的点在分布上呈现出相似性,彼此可以交叉验证。这为面对不同任务需求的多机悬吊系统的构型优化提供了理论指导,即以多维度工作空间为基础,以提升工作空间的Q_S整体质量及分布为导向,对多机悬吊系统进行构型优化,满足不同的任务需求。

5 结 论

针对多机悬吊系统工作空间稳定性难以量化评价的问题,采用AHP与EWM组合赋权确定拉力均匀性、位置、姿态3项性能指标的复合权重,结合TOPSIS法建立了多机悬吊系统工作空间稳定性评价模型,并构建多维度工作空间表征稳定性能的空间分布。实例仿真结果表明:工作空间稳定性能呈中间高、两头低的分布趋势,中部及上部区域稳定性较优;随稳定性能阈值增大,多维度工作空间呈倒三棱台状收缩。该评价方法与多维度工作空间可为多机悬吊系统的构型优化、吊运作业区域选取与路径规划提供理论依据。

未来将进一步拓展稳定性评价指标体系,计入柔索弹性形变、外界扰动等实际工况因素,提高稳定性评价的精准度;并将该评价方法推广至定柔索长度、柔索长度与机器人末端位置同时变化等其他构型的多机悬吊系统,结合多维度工作空间的稳定性分布开展构型优化设计,使被吊运物尽可能运行于高稳定区域。

参考文献(References)

[1] 赵志刚, 滕富军, 石广田, 等. 多机器人联合吊运系统可行域分析与求解[J]. 上海交通大学学报, 2015, 49(8): 1174-1180.
Zhao Z G, Teng F J, Shi G T, et al. Analysis and calculation of feasible region of multi-robot combined lifting system[J]. Journal of Shanghai Jiao Tong University, 2015, 49(8): 1174-1180(in Chinese).

[2] 苏程, 叶佳楠, 李巍, 等. 欠约束多机协调吊运系统动力学工作空间分析[J]. 上海交通大学学报, 2019, 53(2): 225-231.
Su C, Ye J N, Li W, et al. Analysis of dynamic workspace for under-constrained coordinate suspending system with multi-robots[J]. Journal of Shanghai Jiao Tong University, 2019, 53(2): 225-231(in Chinese).

[3] 刘鹏, 仇原鹰. 绳牵引摄像机器人的力位混合稳定性评价方法[J]. 西安电子科技大学学报 (自然科学版), 2016, 43(1): 87-93.
Liu P, Qiu Y Y. Approach with a hybrid force-position property to assessing the stability for camera robots[J]. Journal of Xidian University, 2016, 43(1): 87-93(in Chinese).

[4] Behzadipour S, Khajepour A. Stiffness of cable-based parallel manipulators with application to stability analysis[J]. Journal of Mechanical Design, 2006, 128(1): 303-310.

[5] Michael N, Fink J, Kumar V. Cooperative manipulation and transportation with aerial robots[J]. Autonomous Robots, 2011, 30(1): 73-86.

[6] Bosscher P, Ebert-uphoff I. A stability measure for undercon-strained cable-driven robots[C]//Proceedings of the IEEE International Conference on Robotics and Automation. Piscataway: IEEE, 2004: 4943-4949.

[7] Vu D S, Alsmadi A. Trajectory planning of a cable-based parallel robot using reinforcement learning and soft actor-critic[J]. WSEAS Transactions on Applied and Theoretical Mechanics, 2020, 15: 165-172.

[8] Vu D S, Barnett E, Zaccarin A M, et al. On the design of a three-DOF cable-suspended parallel robot based on a parallelogram arrangement of the cables[C]//Gosselin C, Cardou P, Bruckmann T, et al. Cable-Driven Parallel Robots. Cham: Springer International Publishing, 2018: 319-330.

[9] 刘鹏, 乔心州. 大跨度完全约束空间3-DOF柔索驱动并联机器人稳定性灵敏度研究[J]. 清华大学学报 (自然科学版), 2022, 62(9): 1548-1558.
Liu P, Qiao X Z. Stability sensitivity of a completely restrained 3-DOF cable-driven parallel robot with four long-span cables[J]. Journal of Tsinghua University(Science and Technology), 2022, 62(9): 1548-1558(in Chinese).

[10] 刘鹏, 曹现刚, 张旭辉, 等. 4-1型柔索驱动并联机器人稳定性度量及其灵敏度分析[J]. 振动与冲击, 2023, 42(14): 180-188.
Liu P, Cao X G, Zhang X H, et al. Stability and sensitivity of a 4-1 type cable-driven parallel robot[J]. Journal of Vibration and Shock, 2023, 42(14): 180-188(in Chinese).

[11] Liu P, Qiu Y Y, Su Y. A new hybrid force-position measure approach on the stability for a camera robot[J]. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 2016, 230(14): 2508-2516.

[12] Liu P, Qiu Y Y, Su Y, et al. On the minimum cable tensions for the cable-based parallel robots[J]. Journal of Applied Mathematics, 2014: 350492.

[13] 苏程, 卫启哲, 赵志刚, 等. 多机协调吊运系统综合多影响因子的位置稳定性评价方法[J]. 哈尔滨工程大学学报, 2023, 44(3): 481-488.
Su C, Wei Q Z, Zhao Z G, et al. Position stability evaluation method for a multi-robot coordinated lifting system based on multi-influence factors[J]. Journal of Harbin Engineering University, 2023, 44(3): 481-488(in Chinese).

[14] 董成举, 刘文威, 李小兵, 等. 六轴工业机器人工作空间分析及区域性能研究[J]. 中国测试, 2020, 46(5): 154-160.
Dong C J, Liu W W, Li X B, et al. Working space analysis and space division performance research on 6-DOF industrial robot[J]. China Measurement & Testing Technology, 2020, 46(5): 154-160(in Chinese).

[15] 李典. 面向任务的并联机构多维度工作空间表示及构型设计研究[D]. 北京: 北京交通大学, 2020.
Li D. Research on multi-dimensional workspace representation and task-oriented structural design for parallel mechanisms[D]. Beijing: Beijing Jiaotong University, 2020(in Chinese).

[16] 赵嘉浩, 訾斌, 王威, 等. 刚柔复合驱动并联喷涂机器人机构设计与工作空间分析[J]. 机械工程学报, 2023, 59(15): 28-39.
Zhao J H, Zi B, Wang W, et al. Mechanical design and workspace analysis of a rigid-flexible hybrid driven parallel spray-painting robot[J]. Journal of Mechanical Engineering, 2023, 59(15): 28-39(in Chinese).

[17] 陈瑞娜. 浮动基多机协调吊运系统的运动稳定性分析[D]. 兰州: 兰州交通大学, 2023.
Chen R N. Kinematic stability analysis of multi-robot coordinated towing system with floating base[D]. Lanzhou: Lanzhou Jiaotong University, 2023(in Chinese).

[18] 夏子立, 景强, 高文博, 等. 基于权重融合法的跨海桥梁部位及部件权重体系分析[J]. 科学技术与工程, 2023, 23(5): 2171-2180.
Xia Z L, Jing Q, Gao W B, et al. Weight system analysis of bridge parts and components based on weight fusion method[J]. Science Technology and Engineering, 2023, 23(5): 2171-2180(in Chinese).

Workspace stability evaluation of multi-engine suspension system based on EWM-TOPSIS

LI Wei，ZHAO Zhigang*，ZHAO Xiangtang，LI Zixuan，GANG Zheng

(School of Mechatronic Engineering，Lanzhou Jiao Tong University，Lanzhou 730070，China)

Abstract：In response to the challenge of assessing the stability of a multi-robot suspension system's workspace, we propose a stability evaluation method based on entropy weight method (EWM) and technique for order preference by similarity to an ideal solution (TOPSIS). Additionally, article establish a multi-dimensional workspace to characterize the distribution of stability within the workspace. Firstly, by analyzing the kinematics and dynamics characteristics of the system, article introduce performance indices for position, attitude, and flexure force uniformity that impact the system's stability. Secondly, the article employs EWM-AHP to calculate composite weights for each performance index in order to determine their relative importance. Subsequently, TOPSIS is utilized to evaluate the stability performance of each position in the workspace. Finally, simulation computations are performed to identify the static balancing workspace of a fixed-end multi-machine suspension system and evaluate the stability of different positions within this space over various stability performance intervals. The simulation findings show that the multi-dimensional working space decreases toward its center and upper half as stability performance increases, indicating improved overall stability in these areas for the working space of the multi-machine suspension system. This analysis provides a theoretical foundation for optimizing configurations in multi-robot suspension systems.

Keywords：multi-robot system; suspension system; stability; multi-dimensional workspace; technique for order preference by similarity to an ideal solution; entropy weight method

Received：2024-07-18；**Accepted**：2024-09-23；**Published Online**：2024-09-27 10：28

URL：link.cnki.net/urlid/11.2625.V.20240926.1735.002

Foundation items：National Natural Science Foundation of China (51965032); National Natural Science Foundation of Gansu Province of China (22JR5RA319)

* **Corresponding author**. E-mail：zhaozhg@mail.lzjtu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0509

轻量级多尺度特征融合增强的空间非合作小目标检测算法

刘振江[1]，张会娟[2,*]，姬淼鑫[1]，卢涛[1]，张弛[1]，余远金[2]
(1. 河南工业大学 电气工程学院，郑州 450001；2. 北京理工大学 自动化学院，北京 100081)

摘 要：针对深空背景下空间非合作小目标特征提取不充分而检测精度低、空间计算资源有限等问题，提出一种轻量级多尺度特征融合增强和上下文感知的空间目标检测算法。设计一种轻量级多特征下采样模块实现空间非合作目标的多尺度特征提取，加强对细粒度特征提取能力；设计快速双空间金字塔池化模块加强对目标全局上下文特征提取，并聚合局部显著特征和全局特征以提高特征泛化能力；设计跨维度三重特征增强模块（CTFEM）对不同维度信息进行全局上下文建模，进一步增强小目标特征信息，抑制易混淆背景信息，从而提高对小目标检测能力。使用VisDrone2019公开的小目标数据集和自建空间态势感知数据集（SSAD）对所提算法进行验证，实验结果表明：所提算法与基准模型YOLOv8n相比，模型参数量减少19.38%，在SSAD数据集上mAP50和mAP50-95分别提高0.2%和1.2%，在VisDrone2019数据集上mAP50和mAP50-95分别提高2.0%和1.4%。

关 键 词：空间非合作目标检测；小目标检测；特征融合；上下文信息；轻量级网络
中图分类号：V44; V52; TP391.41
文献标志码：A **文章编号**：1001-5965(2026)11-4040-11

随着空间目标数量的逐年增加，空间态势感知对保证在轨航天器安全起着重要的作用[1]，而空间目标检测是实现空间态势感知的基础。空间任务包括空间目标监测、回避和清除，需要尽早实时识别和监测空间非合作目标[2-3]，避免潜在碰撞，规划有效轨迹，以确保在轨服务卫星的正常运行[4-5]。因此，快速准确检测和识别远距离非合作航天器和空间碎片等小目标具有重要意义。

基于图像的深度学习目标检测[6-9]为空间态势感知带来诸多优势。Wu等[10]针对空间目标识别和定位效率低的问题，提出了两阶段卷积神经网络(two-stage convolutional neural network, T-SCNN)。Xiang等[11]提出了基于网格学习的快速空间碎片检测方法，将图像划分为14×14个网格，使用基于网格的快速神经网络(fast grid-based neural network, FGBNN)定位网格内的空间碎片。Wang等[12]在YOLOv3网络基础上改进了特征提取结构，融合浅层特征和深层特征，增强网络对不同尺度目标的检测能力。Jia等[13]将改进的Resnet-50骨干网络和特征金字塔网络融合到Faster R-CNN框架[14]，增强了模型的泛化能力。Aldahoul等[15]为提高对空间目标的定位和分类，提出了一种模型决策融合方法，利用EfficientNet-v2和EfficientNet-B4网络训练EfficientDet模型。Mahendrakar等[16]基于形状和

收稿日期：2024-07-03；**录用日期**：2024-09-13；**网络出版时间**：2024-09-20 10:37
网络出版地址：link.cnki.net/urlid/11.2625.V.20240919.1640.008
基金项目：国家资助博士后研究人员计划(GZC20233408)；国家自然科学基金(62222304,62173039,62201199)；河南工业大学创新基金支持计划专项资助(2021ZKCJ07)
* **通信作者**. E-mail：zhanghjqy@bit.edu.cn

引用格式：*刘振江，张会娟，姬淼鑫，等. 轻量级多尺度特征融合增强的空间非合作小目标检测算法[J]. 北京航空航天大学学报，2026，52(11)：4040-4050. Liu Z J，Zhang H J，Ji M X，et al. Lightweight multi-scale feature fusion enhancement algorithm for spatial non-cooperative small target detection[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：4040-4050 (in Chinese).*

纹理的人类启发决策过程, 将形状检测器和纹理检测器与 YOLOv5 相结合, 增强安全决策能力, 提出了 SpaceYOLO 空间目标检测方法。Tang 等[17] 使用 RepPoint 替换 YOLOv7 中 ElAN 骨架的 3×3 卷积, 提高了检测空间目标组件的准确率。Ai 等[18] 采用 3 个一级特征图代替特征金字塔结构和解耦头, 增强对不同尺度空间目标的检测。Massimi 等[5] 将脉冲多普勒雷达系统与 YOLO 相结合, 提高了空间碎片探测能力。这些工作对于特征明显的目标具有较好的分类检测性能。

为了进一步提高对空间小目标的检测精度, Guo 等[19] 提出了基于空间图像特征的通道和空间注意力 U-Net 网络, 实现了单幅光学图像空间弱小目标检测。Jiang 等[20] 提出多通道直方图截断模块和中心差分卷积对特征进行增强, 构建了 SOD-YOLO 实现弱小空间目标检测。上述文献在简单背景和特征单一的小目标检测方面有一定的效果, 但复杂背景下的检测精度有待提高。Tao 等[21] 引入了增强的空间特征模块来增强小目标的空间细节, 构建空间碎片显著性检测算法 SDebrisNet。Yuan 等[22] 提出交叉上下文融合模块, 通过多分支并行学习不同尺度的上下文信息, 增强特征表达能力, 用于检测小型和微弱的空间目标。上述文献对小目标特征提取能力有一定的增强, 但模型复杂度在较高有限资源下应用受限。

上述工作提升了对空间目标检测的性能, 但是对于空间非合作目标检测, 深空图像具有杂散光、低信噪比等特性。现有的空间小目标检测方法在复杂背景中表现不佳, 尤其在特征提取能力和对小目标的优化方面存在不足, 检测精度下降。此外, 由于模型复杂度较高, 在星上资源受限的环境中难以实现实时检测。因此, 本文在 YOLOv8n 网络模型的基础上提出一种轻量级空间非合作小目标检测网络 S-YOLO, 其兼顾检测精度与模型轻量化, 具体创新点如下:

1) 为解决空间目标数据样本难获取的问题, 构建了以小尺度目标为主的空间态势感知数据集(spatial situational awareness detection, SSAD), 包含 22 个空间目标类别、50 563 张图片、68 925 个标签, 可为空间非合作目标探测提供大规模基准数据集;

2) 提出一种轻量级多特征下采样模块(light-weight multi-feature down sampling module, LMFD), 改善跨步标准卷积丢失目标信息问题, 增强对细粒度特征提取能力;

3) 提出快速双空间金字塔池化模块(double spatial pyramid pooling-fast, DSPPF), 加强对目标全局上下文特征提取, 融合目标局部显著特征, 提高特征表达能力, 进一步增强对小目标检测;

4) 提出跨维度三重特征增强模块(cross-dimension triplet feature enhance module, CTFEM), 在颈部跨通道进行全局上下文建模, 增强小目标弱特征表示。同时, 引入动态上采样模块(upsampling by dynamic sampling, DySample), 缓解特征丢失问题, 提高特征的表达能力和精确度, 增强小目标检测性能。

1　空间非合作小目标检测算法

YOLOv8 采用单阶段端到端架构[23–24], 包括骨干网络(Backbone)、颈部(Neck)和头部(Head)。骨干网络主要由 C2f 和 CBS 模块组成, 对输入图像执行四次下采样提取特征。C2f 模块在保证轻量级的同时实现了丰富梯度信息采集。颈部网络采用特征金字塔网络(feature pyramid networks, FPN)和路径聚合网络(path aggregation network, PAN)结构, 通过组合不同尺度特征, 增强网络特征融合能力。YOLOv8 头部采用解耦合结构, 包含 3 个不同尺度检测分支, 利用非极大值抑制得到最优检测框。

为提升空间非合作小目标检测能力, 关键在于增强模型对低信噪比、低光照、小尺度空间目标的特征提取能力, 同时还应考虑网络轻量化, 以满足实时性和稳定检测环境需求。因此, 本文提出基于 YOLOv8n 的空间非合作目标检测模型 S-YOLO。S-YOLO 的整体结构如图 1 所示。

1.1　轻量级多特征下采样模块

空间非合作小目标特征信息不明显, 使用跨步标准卷积实现下采样, 模型提取细节特征能力有限, 随着网络深度增加, 将导致细节信息丢失, 空间信息的丢失使模型难以识别检测小尺度目标。因此, 为了提取更丰富的空间非合作目标特征, 本文提出了 LMFD, 如图 2 所示。

首先, 使用 1×1 卷积将输入特征从通道 C_1 提高到 C_2, 不改变图像分辨率, 在增加非线性特征的同时获得更多通道特征。然后, 进行通道分割, 送入 2 个不同特征提取分支。其中, 上分支先进行 1×1 逐点卷积[25], 减少计算量和内存消耗, 在保持空间分辨率的同时实现不同通道信息融合, 有利于提升模型表达能力。接着采用 3×3, 步距为 2 的深度卷积[25], 在减少参数量的同时提取更多空间特征。最后, 再使用 1×1 逐点卷积进行特征融合。其中, 下分支直接使用 5×5, 步距为 2 的深度卷积。2 个不同尺寸的卷积核可扩展网络感受野, 更好地提取不同尺度空间目标特征, 提高模型对不同尺度目标的检测能力。2 个分支的输出在通道上进行拼接,

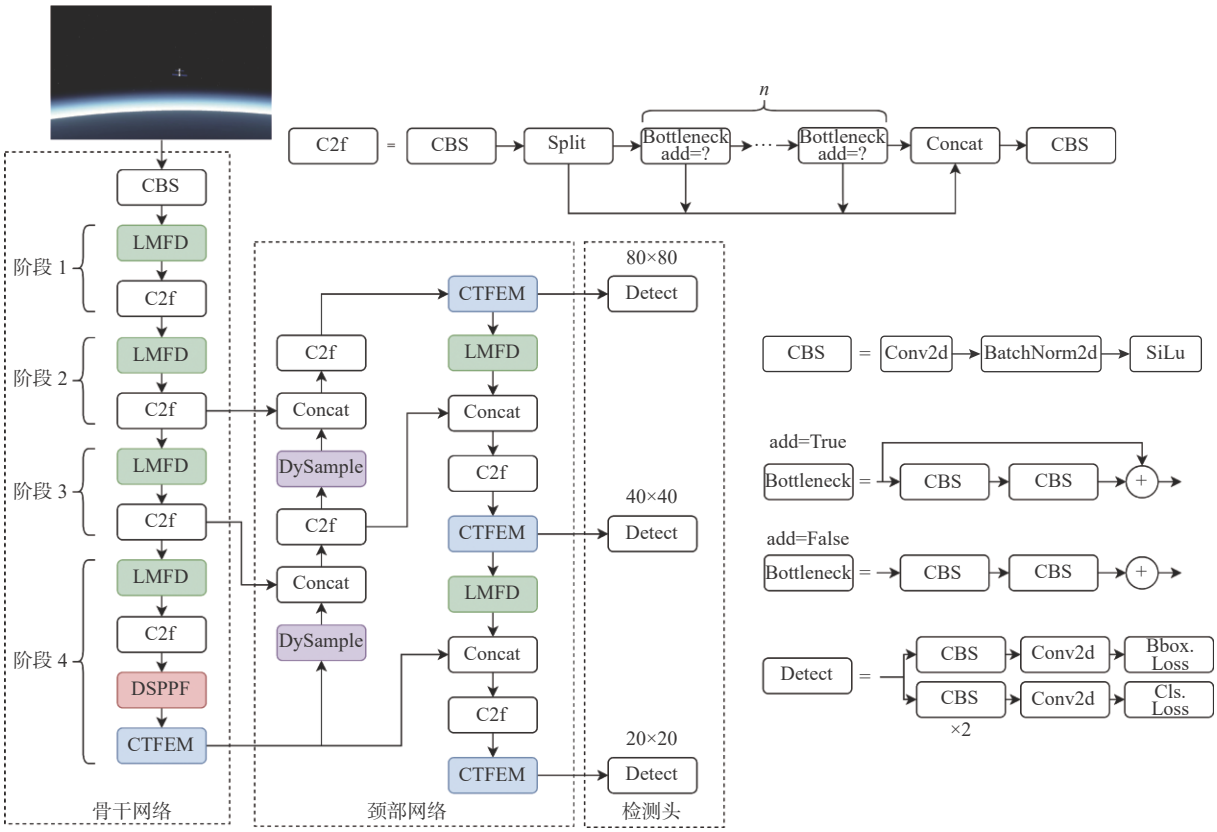


图 1 S-YOLO 网络结构

Fig. 1 Structure of S-YOLO network

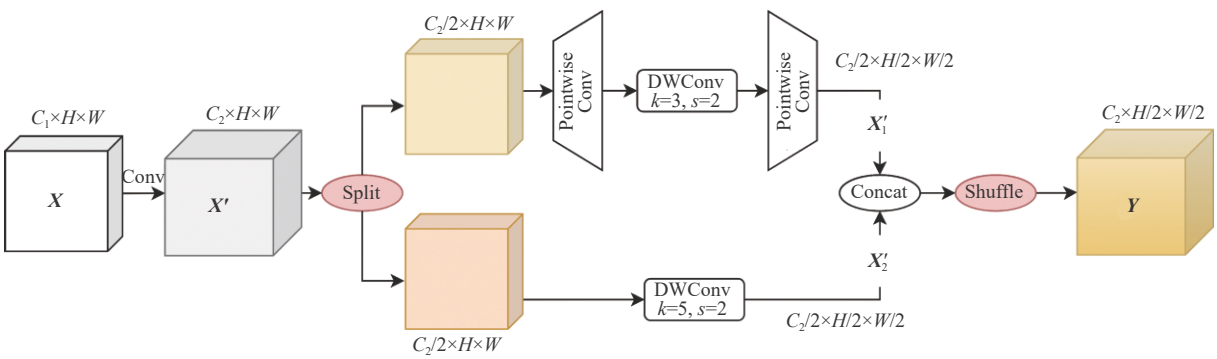


图 2 LMFD 结构

Fig. 2 Structure of LMFD

最终在通道上进行混洗[26], 可促进不同通道信息交流, 更好地融合不同通道信息, 进一步增强模型表达能力和鲁棒性。

LMFD 数学表达式如下:

$$\boldsymbol{X}' = f_{\text{Conv}}^{1\times1}(\boldsymbol{X}) \tag{1}$$

$$\boldsymbol{X}_1' = f_{\text{PWConv}}^{1\times1}(f_{\text{DWConv}}^{3\times3,2}(f_{\text{PWConv}}^{1\times1}(\text{Split}(\boldsymbol{X}')))) \tag{2}$$

$$\boldsymbol{X}_2' = f_{\text{DWConv}}^{5\times5,2}(\text{Split}(\boldsymbol{X}')) \tag{3}$$

$$\boldsymbol{Y} = \text{Shuffle}(\text{Cat}(\boldsymbol{X}_1', \boldsymbol{X}_2')) \tag{4}$$

式中: $f_{\text{Conv}}^{1\times1}$表示卷积核为 1×1 的标准卷积; $f_{\text{PWConv}}^{1\times1}$表示卷积核为 1×1 的逐点卷积; $f_{\text{DWConv}}^{3\times3,2}$和$f_{\text{DWConv}}^{5\times5,2}$分别表示步距为 2, 卷积核为 3×3 和 5×5 的深度卷积; Split(·)表示特征图通道切分操作; Cat(·)表示特征图通道方向拼接操作; Shuffle(·)表示特征图通道混洗操作; $\boldsymbol{X}$表示输入特征图, $\boldsymbol{X}'$由式 (1) 得到; $\boldsymbol{X}_1'$和$\boldsymbol{X}_2'$分别表示上分支和下分支输出; $\boldsymbol{Y}$表示 LMFD 输出特征图。

此外, 模块的轻量化设计主要通过逐点卷积和深度卷积实现。标准卷积参数量为$C_{\text{in}}\times C_{\text{out}}\times k\times k$, 而本文设计的 LMFD 卷积参数量为$C_{\text{in}}\times C_{\text{out}}+C_{\text{out}}/2\times(k_1\times k_1+k_2\times k_2+C_{\text{out}})$。假设$C_{\text{in}}=64$, $C_{\text{out}}=128$, $k=3$, $k_1=3$, $k_2=5$, 标准卷积参数量为 73 728, LMFD 的卷积参数量为 18 560, 则 LMFD 参数量减少了 74.83%。

这使得模型在保证多特征提取能力的同时, 极大地降低了计算复杂度。

1.2　快速双空间金字塔池化模块

针对空间非合作小目标检测, 不仅要关注局部特征信息, 也需要更多的全局上下文特征信息。SPP[27] 和 SPPF[28] 模块都采用最大池化提取不同尺度局部特征, 忽略了全局上下文特征的提取。因此, 为了聚合局部显著特征和全局上下文特征, 加强特征泛化能力, 本文提出 DSPPF, 如图 3 所示。

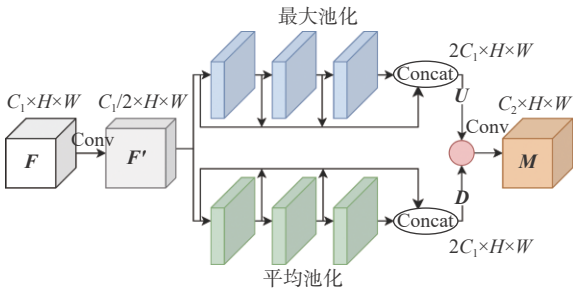


图 3　DSPPF 结构

Fig. 3　Structure of DSPPF

DSPPF 采用双分支特征提取, 分别使用最大池化和平均池化提取空间目标的局部特征和全局特征, 如图 3 所示。平均池化能够保留更多背景细节信息和上下文信息, 最大池化提取局部显著特征, 两者结合可生成更加丰富的特征, 这对空间目标检测非常有利。首先, 利用 1×1 标准卷积对输入特征图 $\boldsymbol{F}$ 降维操作, 得到特征图 $\boldsymbol{F}'$, 减少计算复杂度。然后, 对 $\boldsymbol{F}'$ 分别进行金字塔最大池化和平均池化, 得到特征图 $\boldsymbol{U}$ 和 $\boldsymbol{D}$。最后, 使用逐元素加法进行特征融合, 得到特征图 $\boldsymbol{M}$。具体公式如下:

$$\boldsymbol{U}=\mathrm{Cat}(P_{\mathrm{m}}(\boldsymbol{F}'),P_{\mathrm{m}}(P_{\mathrm{m}}(\boldsymbol{F}')),P_{\mathrm{m}}(P_{\mathrm{m}}(P_{\mathrm{m}}(\boldsymbol{F}'))),\boldsymbol{F}') \tag{5}$$

$$\boldsymbol{D}=\mathrm{Cat}(P_{\mathrm{a}}(\boldsymbol{F}'),P_{\mathrm{a}}(P_{\mathrm{a}}(\boldsymbol{F}')),P_{\mathrm{a}}(P_{\mathrm{a}}(P_{\mathrm{a}}(\boldsymbol{F}'))),\boldsymbol{F}') \tag{6}$$

$$\boldsymbol{M}=\boldsymbol{U}\oplus\boldsymbol{D} \tag{7}$$

式中: $P_{\mathrm{m}}(\cdot)$ 和 $P_{\mathrm{a}}(\cdot)$ 分别表示最大池化和平均池化; $\oplus$ 表示广播逐元素加法。

1.3　跨维度三重特征增强模块

针对小尺度的空间非合作目标, 当处于低信噪比和低光照的相似背景下时, 提取目标特征相对困难。在 LMFD 和 DSPPF 之后, 特征图已经考虑了局部显著特征、全局上下文信息, 并捕获了空间非合作目标不同尺度特征。在颈部建模小目标和背景之间的全局关系比在骨干网络更有效。全局上下文信息可用于表示跨空间像素之间的关系, 增强空间目标和背景之间的区分度, 帮助模型更好地实现目标的定位检测。因此, 本文提出 CTFEM, 具体结构如图 4 所示。

增强的通道注意力模块 (enhanced channel attention module, ECAM) 如图 4(a) 所示, 在不降维的情况下, 使用自适应最大池化[29] 和自适应平均池化[30] 聚合卷积特征后, 进行广播逐元素相乘。然后, 执行卷积核为 3 的 1D 卷积和 Sigmoid 函数来学习通道注意力权重 $\boldsymbol{\psi}$。最后, $\boldsymbol{\psi}$ 与输入特征 $\boldsymbol{F}_{\mathrm{c}}$ 进行广播逐元素相乘得到输出特征 $\boldsymbol{F}'_{\mathrm{c}}$。具体表达式如下:

$$\boldsymbol{\psi}=\mathrm{Sigmoid}(f^{3}_{\mathrm{conv1d}}(P_{\mathrm{am}}(\boldsymbol{F}_{\mathrm{c}})\odot P_{\mathrm{av}}(\boldsymbol{F}_{\mathrm{c}}))) \tag{8}$$

$$\boldsymbol{F}'_{\mathrm{c}}=\boldsymbol{\psi}\odot\boldsymbol{F}_{\mathrm{c}} \tag{9}$$

式中: $P_{\mathrm{am}}(\cdot)$ 和 $P_{\mathrm{av}}(\cdot)$ 分别表示自适应最大池化和自适应平均池化; f^{3}_{conv1d} 表示卷积核为 3 的 1D 卷积; Sigmoid(·) 表示 Sigmoid 函数; $\odot$ 表示广播逐元素相乘。

空间注意力模块 (spatial attention module, SAM) 如图 4(b) 所示, 利用特征之间的空间关系生成空间注意力图, 与通道注意力互补。首先, 将输入特征 $\boldsymbol{F}_{\mathrm{s}}$ 沿通道应用最大池化和平均池化, 并进行直接拼接生成一个有效的特征描述子。在保留丰富特征的同时, 收缩深度, 进一步降低计算复杂度。然后, 应用 7×7 标准卷积层生成空间注意力特征图。最后, 使用 Sigmoid 函数进行激活得到 $\boldsymbol{F}'_{\mathrm{s}}$。SAM 具体表达式如下:

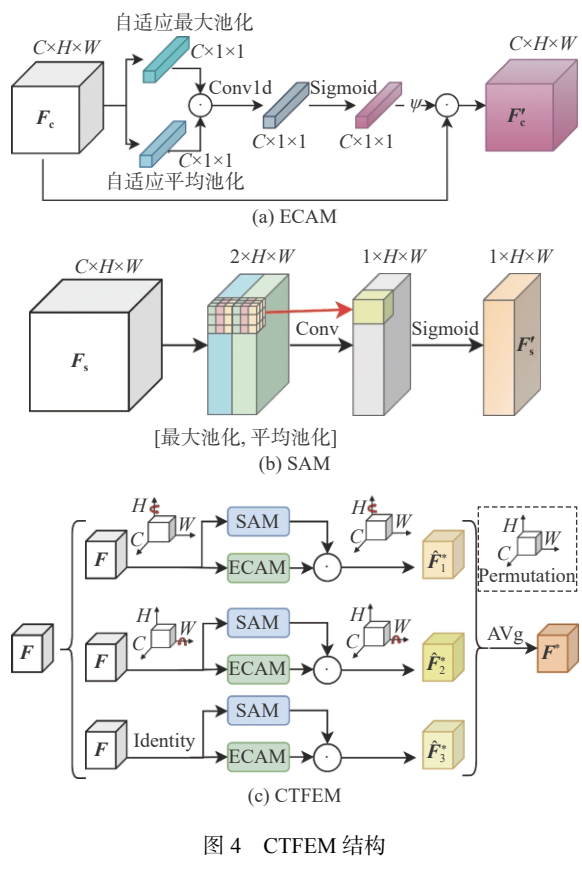


图 4　CTFEM 结构

Fig. 4　Structure of CTFEM

$$\boldsymbol{F}'_{\mathrm{s}}=\mathrm{Sigmoid}(f_{\mathrm{Conv}}^{7\times7}(\mathrm{Cat}(P_{\mathrm{m}}(\boldsymbol{F}_{\mathrm{s}}),P_{\mathrm{a}}(\boldsymbol{F}_{\mathrm{s}}))))\tag{10}$$

式中：$f_{\mathrm{Conv}}^{7\times7}$表示卷积核为7×7的标准卷积。

跨维度三重特征增强模块(CTFEM)具体结构如图4(c)所示，CTFEM利用三分支结构来捕获跨维度交互，以计算注意力权重。顶部分支负责计算通道维度C和空间维度H的注意力权重，中间分支计算通道维度C和空间维度W的注意力权重，最后一个分支捕获空间维度H和W之间的交互关系。当输入特征图$\boldsymbol{F}\in\mathbf{R}^{C\times H\times W}$，3个分支具体实现如下：

在顶部分支和中间分支，首先，输入特征图$\boldsymbol{F}$分别沿H轴和W轴逆时针旋转90°，分别建立维度W和通道C及维度H和通道C之间的交互，以获得旋转特征图$\hat{\boldsymbol{F}}_1\in\mathbf{R}^{W\times H\times C}$和$\hat{\boldsymbol{F}}_2\in\mathbf{R}^{H\times C\times W}$；然后，分别经过SAM和ECAM模块的输出$\boldsymbol{F}'_{\mathrm{c}}$和$\boldsymbol{F}'_{\mathrm{s}}$直接进行逐元素相乘获得特征图$\hat{\boldsymbol{F}}_1^*\in\mathbf{R}^{W\times H\times C}$和$\hat{\boldsymbol{F}}_2^*\in\mathbf{R}^{H\times C\times W}$；最后，分别沿$H$轴和$W$轴顺时针旋转90°以保持如输入特征图形状一致。对于底部分支，输入特征图$\boldsymbol{F}$直接分别经过SAM和ECAM模块，2个模块输出$\boldsymbol{F}'_{\mathrm{c}}$和$\boldsymbol{F}'_{\mathrm{s}}$直接进行逐元素相乘获得特征图$\hat{\boldsymbol{F}}_3^*\in\mathbf{R}^{C\times H\times W}$。通过简单平均来聚合由3个分支中的每个生成的形状为$(C\times H\times W)$的增强特征图$\boldsymbol{F}^*$，具体表达式如下：

$$\boldsymbol{F}^*=\frac{1}{3}(\hat{\boldsymbol{F}}_1^*+\hat{\boldsymbol{F}}_2^*+\hat{\boldsymbol{F}}_3^*)\tag{11}$$

通过结合跨维度信息交互，该方法解决了使用传统方法计算单个维度的注意力权重时出现的信息表达能力不足问题，能够在学习任务中捕获更复杂的关联和依赖关系，更有利于空间小尺度目标的检测。

1.4 动态上采样

YOLOv8目标检测算法应用最近邻插值法实现特征图的上采样操作，从而实现不同层之间的特征融合。虽然计算量小、运算速度快，但简单的最近邻插值法[31]会导致细节信息丢失，对于空间小尺度目标特征损失较严重，特征表达能力不足，随着网络深度传递会严重影响空间小目标检测精度。因此，本文引入了一种超轻量可学习的动态上采样(DySample)[32]，来缓解特征丢失问题，提高特征表达能力和精确度。具体结构如图5所示。

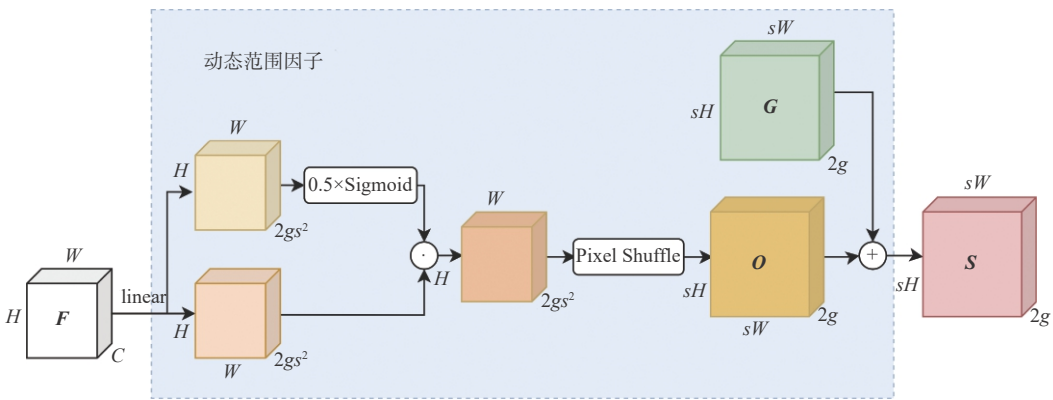


图5 动态上采样点生成器

Fig. 5 Dynamic upsampling point generator

给定上采样比例因子s和大小为$C\times H\times W$的特征图$\boldsymbol{F}$，沿着通道维度将特征图划分为$g(g=4)$组，可进一步降低计算量。经过一个线性层，生成大小为$2gs^2\times H\times W$的偏移。为了增加偏移的灵活性，通过使用Sigmoid函数和0.5静态因子进一步生成逐点的“动态范围因子”，动态范围取[0,0.5]范围内的值。最后，通过像素洗牌P_{s}将其重塑为$2g\times sH\times sW$的偏移$\boldsymbol{O}$，数学表达式如下：

$$\boldsymbol{O}=P_{\mathrm{s}}(0.5\times\mathrm{Sigmoid}(\mathrm{linear}(\boldsymbol{F})\odot\mathrm{linear}(\boldsymbol{F})))\tag{12}$$

则采样集$\boldsymbol{S}$为偏移量$\boldsymbol{O}$与原始采样网格$\boldsymbol{G}$之和：

$$\boldsymbol{S}=\boldsymbol{G}+\boldsymbol{O}\tag{13}$$

2 实验与分析

本文使用的操作系统为Ubuntu 22.04，CUDA版本为12.1；实验在NVIDIA RTX 4090 (24 G) GPU和16 vCPU Intel(R) Xeon(R) Platinum 8352V CPU @ 2.10 GHz的计算机上进行；开发语言为Python 3.10和PyTorch 2.1.0。在训练过程中，部分关键参数设置如表1所示，其他参数使用YOLOv8默认参数。其中，优化器为随机梯度下降(stochastic gradient descent, SGD)。

本文采用准确率P、召回率R、mAP50、mAP50-95、APS、APM、APL、浮点运算量、检测速度、参数量、权重文件等指标作为模型评价指标。其中，浮点运算量、参数量和权重文件衡量目标检测模型大

表 1　网络模型的训练参数

Table 1　Training parameters of the network model

参数	数值
训练轮数	200
批次大小	32
输入图像尺寸/(像素×像素)	640×640
早停耐心值	100
初始学习率	0.01
最终学习率系数	0.01
动量系数	0.937
权重衰减系数	0.000 5
Mosaic数据增强系数	1.0

小, 检测速度代表模型每秒检测图像帧数, 衡量模型实时性。mAP50 表示 IoU 为 0.5 时所有类别的平均精度; mAP50-95 表示在 0.50～0.95 之间不同 IoU 阈值下计算得出的平均精度均值; APS 表示目标像素面积小于 32^2 所有类别的平均精度; APM 表示目标像素面积大于 32^2 并小于 96^2 所有类别的平均精度; APL 表示目标像素面积大于 96^2 所有类别的平均精度。

2.1　SSAD 数据集构建

为了构建空间态势感知数据集 SSAD, 本文采用网络图片、视频收集联合 STK(Satellite Tool Kit)软件仿真的方式获取大量的卫星和空间碎片图像进行扩展和标注。此外, 在制作 SSAD 数据集时采集相对正常运行航天器较远处的非合作目标, 此时空间非合作目标更多成像为小尺度目标。为丰富样本数据多样性, 利用 STK 仿真视频模拟了卫星不同姿态、尺度、背景等, 每个视频序列包含 1～2 类卫星。通过网络搜集的未知型号卫星在 SSAD 中统一归为 Satellite 类别。数据集类别及标签 ID 如表 2 所示。

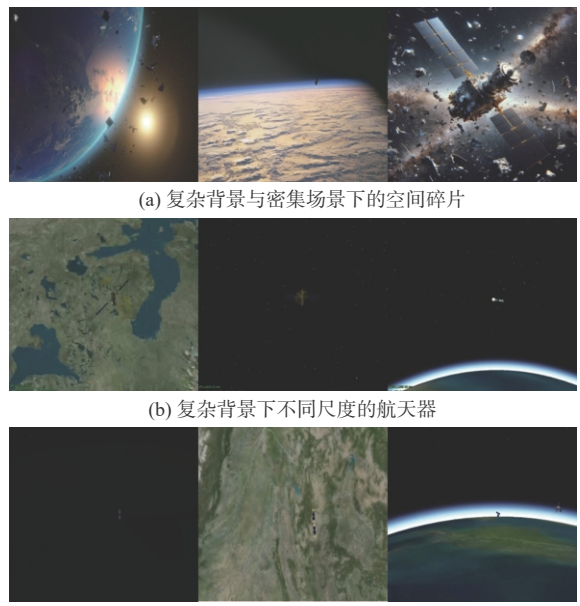
表 2　SSAD 数据集类别及标签统计

Table 2　SSAD dataset categories and labelling statistics

ID	类别名称	标签数量	ID	类别名称	标签数量
0	space debris	3 342	11	hubble	3 117
1	satellite	2 710	12	ikonos	3 221
2	aces	3 167	13	inmarsat4	3 070
3	apollo-soyuz	3 287	14	intelsat8	3 251
4	beidou	3 220	15	iss_stg3r	2 996
5	chandra	3 095	16	meteor	3 051
6	discoverer	3 123	17	mgs	3 287
7	dmsp	3 216	18	milstar	3 062
8	est-vil	3 149	19	mir	3 055
9	gps2	3 138	20	msx	3 271
10	gravityprobe	3 002	21	quickbird2	3 095

因此, SSAD 数据集共包含 22 种类别空间目标, 共 50 563 张图片, 68 925 个标签。仿真模拟生成的图像分辨率大小为 1 440×880, 为了保证数据的均衡性, 平均每类目标的标签约 3 000 个。数据使用 X-AnyLabeling 半自动标注软件完成, 首先每类人工标注 500 张, 使用 YOLOv8n 训练 300 个 epoch, 将训练权重导出为 ONNX 格式, 再导入 X-AnyLabeling 软件, 完成剩余图像标注并进行人工修正。

SSAD 数据集按照 6:2:2 的比例划分为训练集、验证集、测试集。图 6 为 SSAD 数据集中样本图像。



(a) 复杂背景与密集场景下的空间碎片

(b) 复杂背景下不同尺度的航天器

(c) 复杂背景下不同型号的航天器

图 6　SSAD 数据集中样本图像

Fig. 6　Sample images of SSAD dataset

2.2　消融实验

本文基于 YOLOv8n 提出了空间目标检测模型 S-YOLO, 使用 LMFD 替换跨步卷积下采样模块, 并使用 DSPPF、CTFEM 和 DySample 模块对该模型进行优化。为了评估每个优化模块的性能, 采用变量控制方法进行消融实验。在 VisDrone2019[33] 公开小目标数据集上用相同训练参数, 训练 200 个 epoch 的结果如表 3 所示, 表中加粗数值表示本文提出的 S-YOLO 模型的评价指标结果。

从表 3 中可观察到, 采用 LMFD 模块的模型 2 与模型 1(YOLOv8n) 相比, 在 mAP50 和 mAP50-95 上分别提高了 0.5% 和 0.6%, 但将网络模型参数数量从 3.2×10^6 减少到 2.57×10^6, 减少 19.69%, 浮点运算量降低了 2×10^8 次。模型 3 在模型 2 基础上增加 DSPPF 模块, 提高了准确率 P、召回率 R、mAP50 和 mAP50-95, mAP50 和 mAP50-95 分别提高 0.5% 和 0.2%。模型 4 在模型 3 基础上增加 CTFEM 模块, mAP50 和 mAP50-95 分别提高 0.4% 和 0.3%, 同时浮点运算量增加了 2×10^8 次, 但与模型 1 保持一致。最后, 模型 5(S-YOLO)在模型 4 基础上引入

表3 S-YOLO的消融实验结果

Table 3 Ablation experiment results of S-YOLO

模型	LMFD	DSPPF	CTFEM	DySample	参数量	浮点运算量/10^9次	P/%	R/%	mAP50/%	mAP50-95/%
1					3.20×10^6	8.2	43.2	32.4	32.1	18.3
2	√				2.57×10^6	8.0	43.8	32.8	32.6	18.9
3	√	√			2.57×10^6	8.0	43.9	34.0	33.1	19.1
4	√	√	√		2.57×10^6	8.2	44.3	**34.1**	33.5	19.4
5	√	√	√	√	2.58×10^6	8.2	**45.8**	33.7	**34.1**	**19.7**

了DySample组件，mAP50和mAP50-95分别提高了0.6%和0.3%，同时准确率P和召回率R也达到了最优，分别为45.8%和33.7%。此外，与基线模型YOLOv8n相比，S-YOLO模型在准确率P、召回率R、mAP50和mAP50-95分别提高2.6%、1.3%、2.0%和1.4%，达到45.8%、33.7%、34.1%和19.7%，而模型参数量仅为2.58×10^6，减少19.38%。消融实验结果证明了改进策略的有效性，特别是在提高小目标检测精度和减少参数量方面。

2.3 SSAD数据集实验结果

为验证本文算法的性能，本文将S-YOLO模型与最先进的目标检测方法YOLOv3-tiny[34]、YOLOv5n、YOLOv6n[35]、YOLOv7-tiny[36]、YOLOv8n[28]、LACTA[37]、YOLOv10n[38]、CS-YOLO[22]、在SADD数据集上进行比较，结果如表4所示，表中加粗数值表示各列评价指标的最优值。其中，CS-YOLO和LACTA是基于YOLO针对小目标改进的检测算法。对于空间目标探测任务，不仅要关注能否找到空间目标，还要关注空间目标的位置，因此，要关注mAP50和mAP50-95这2个重要指标。为了更好地衡量不同尺寸目标的检测性能，引入APS、APM、APL评估指标。

表4 不同检测算法在SSAD数据集上的实验结果

Table 4 Experimental results of different detection algorithms on SSAD dataset

模型	参数量	浮点运算量/10^9次	P/%	R/%	mAP50/%	mAP50-95/%	APS/%	APM/%	APL/%	检测速度/(帧·s^{-1})	模型权重/MB
YOLOv3-tiny*[34]	12.14×10^6	19.1	94.2	87.6	92.2	79.2	36.5	78.1	92.8	**240**	24.4
YOLOv5n*	2.51×10^6	**7.2**	96.8	94.6	96.0	83.1	48.5	80.3	93.0	138	5.3
YOLOv6n*[35]	4.24×10^6	11.9	96.4	94.4	95.7	82.4	46.5	80.1	93.0	163	8.7
YOLOv7-tiny*[36]	8.12×10^6	21.3	96.5	94.5	95.9	82.6	48.4	80.2	92.9	140	16.5
YOLOv8n[28]	3.20×10^6	8.2	96.9	94.7	96.2	83.8	48.6	80.6	93.9	150	6.3
CS-YOLO[22]	7.18×10^6	15.1	96.7	94.6	96.2	83.3	48.6	80.7	94.0	87	14.7
LACTA[37]	**1.20**$\times10^6$	9.6	96.2	94.2	95.9	81.8	48.5	80.4	93.0	157	**2.6**
YOLOv10n[38]	2.71×10^6	8.4	96.3	94.5	95.8	81.9	48.5	80.4	93.8	111	5.8
S-YOLO	2.58×10^6	8.2	96.9	94.9	**96.4**	**85.0**	**49.8**	**82.4**	**94.0**	77	5.5

注：*表示将网络模型的骨干网络移植到YOLOv8工程。

从表4可以得到，S-YOLO在mAP50、mAP50-95、APS、APM、APL指标上分别达到96.4%、85.0%、49.8%、82.4%、94.0%，优于基线YOLOv8n。与最新发布的YOLOv10n相比，mAP50、mAP50-95和APS分别提高0.6%、3.1%和1.3%。与YOLOv3-tiny相比，S-YOLO的mAP50、mAP50-95和APS指标分别提高4.2%、5.8%和13.3%。与YOLOv5n、YOLOv6n和YOLOv7-tiny相比，S-YOLO的mAP50分别提高0.4%、0.7%和0.5%，mAP50-95分别提高1.9%、2.6%和2.4%，APS分别提高了1.3%、3.3%和1.4%。与针对弱小空间目标检测的CS-YOLO相比，S-YOLO的mAP50、mAP50-95和APS分别提高0.2%、1.7%和1.2%，同时参数量减少64.07%，浮点运算量减少6.9×10^9次。与针对小目标检测的LACTA相比，mAP50、mAP50-95和APS分别提高了0.5%、3.2%和1.3%，但S-YOLO参数高于LACTA。虽然S-YOLO的检测速度只有77帧/s，但仍达到高于25帧/s实时性要求。因此，本文S-YOLO模型在保持轻量的同时，具有优越的检测精度和良好的整体性能。

2.4 VisDrone2019数据集实验结果

为进一步验证本文S-YOLO的优越性，在公开

小目标数据集 VisDrone2019[33] 上进行了测试, 该数据集包含 10 个类别, 超过 2.6×10^6 万个常用目标标注框, 具有场景可见性、对象类别和遮挡等重要属性, 提升了数据的可利用性。实验结果如表 5 所示, 表中加粗数值表示各列评价指标的最优值。与基线 YOLOv8n 相比, S-YOLO 在准确率 P、召回率 R、mAP50、mAP50-95、APS、APM 和 APL 指标上分别提高了 2.6%、1.2%、2.0%、1.4%、1.0%、1.2% 和 1.6%, 检测速度略有下降, 但仍可以达到 70 帧/s, 满足实时性需求。与最新发布的 YOLOv10n 相比, S-YOLO 的 mAP50、mAP50-95 和 APS 分别提高 2.3%、1.3% 和 1.1%。与 YOLOv3-tiny、YOLOv5n、YOLOv6n 和 YOLOv7-tiny 相比, S-YOLO 的 mAP50 分别提高 11.2%、2.1%、4.5% 和 1.8%, mAP50-95 分别提高 7.0%、1.7%、2.7% 和 1.6%, APS 分别提高了 5.8%、1.0%、2.2% 和 1.0%。与针对弱小空间目标检测的 CS-YOLO 相比, S-YOLO 的 mAP50、mAP50-95 和 APS 分别提高了 2.2%、1.4% 和 1.0%。与针对小目标检测的 LACTA 相比, S-YOLO 的 mAP50、mAP50-95 和 APS 分别提高了 1.7%、1.2% 和 0.7%。因此, S-YOLO 模型在小目标的检测中仍然表现出优越性能。

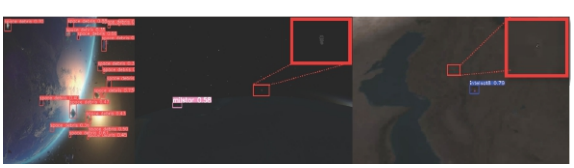
表 5　不同检测算法在 VisDrone2019 数据集上的实验结果

Table 5　Experimental results of different detection algorithms on VisDrone2019 dataset

模型	参数量	浮点运算量/10^9次	P/%	R/%	mAP50/%	mAP50-95/%	APS/%	APM/%	APL/%	检测速度/(帧·s^{-1})	模型大小/MB
YOLOv3-tiny*[34]	12.14×10^6	19.1	37.7	23.6	22.9	12.7	3.8	19.7	35.5	**179**	24.4
YOLOv5n*	2.51×10^6	**7.2**	43.1	32.2	32.0	18.0	8.6	26.2	35.5	112	5.3
YOLOv6n*[35]	4.24×10^6	11.9	40.8	30.2	29.6	17.0	7.4	24.9	34.6	129	8.7
YOLOv7-tiny*[36]	8.12×10^6	21.3	42.3	32.5	32.3	18.1	8.6	27.7	35.7	116	16.5
CS-YOLO[22]	7.18×10^6	15.1	42.0	32.2	31.9	18.3	8.6	25.9	35.9	76	14.7
LACTA[37]	**1.20**$\times10^6$	9.6	42.3	33.1	32.4	18.5	8.9	26.6	35.7	128	**2.6**
YOLOv8n[28]	3.20×10^6	8.2	43.2	32.4	32.1	18.3	8.6	27.2	35.2	118	6.3
YOLOv10n[38]	2.71×10^6	8.4	43.3	31.9	31.7	18.4	8.5	27.1	35.2	113	5.8
S-YOLO	2.58×10^6	8.2	**45.8**	**33.6**	**34.1**	**19.7**	**9.6**	**28.4**	**36.8**	70	5.5

2.5　可视化结果分析

为更加直观地验证 S-YOLO 算法对小尺度目标的检测性能, 进行可视化分析。本文从自建 SSAD 测试集和 VisDrone2019 挑战性测试集中选取不同场景图片, 使用 YOLOv8n 和 S-YOLO 模型进行推理实验, 结果如图 7 和图 8 所示。



(a) YOLOv8n 检测结果

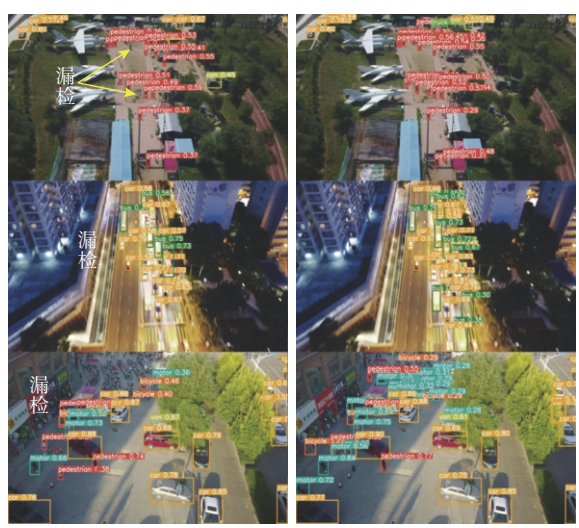


(b) S-YOLO 检测结果

图 7　SSAD 测试集检测结果

Fig. 7　Detection results of SSAD dataset

图 7 实验结果表明, S-YOLO 对密集场景、低光照、低对比度下的小目标具有最优的检测精度, 漏检率较低。图 8 实验结果表明, YOLOv8n 在不同场景下存在明显的漏检, 并有一定的误检率, S-YOLO 在密集场景下针对小目标检测的误检率和漏检率得到显著改善。实验结果表明, S-YOLO 在适应不同场景下对小目标的检测具有更高的检测精度, 具有更高的鲁棒性。



(a) YOLOv8n 检测结果　　(b) S-YOLO 检测结果

图 8　VisDrone 挑战性测试集检测结果

Fig. 8　Detection results of VisDrone dataset

3 结 论

1）本文构建了一个空间态势感知数据集SSAD，该数据集具有更大比例的小目标和多场景，为深入研究天基空间目标探测技术提供了一个大规模数据集。

2）本文设计了3个轻量级即插即用模块LMFD、DSPPF和CTFEM。LMFD具有双分支结构，采用不同大小的卷积核扩大模型感受野，提取不同尺度的空间目标特征。DSPPF通过双分支金字塔池化结构聚合目标局部和全局特征，获取更多背景细节信息和上下文信息。CTFEM跨通道交互学习通道之间的相关性，增强小目标弱特征表示，提高对空间小尺度目标的检测能力。

3）实验结果表明，本文S-YOLO在SSAD上的mAP50、mAP50-95和APS分别达到96.3%、85.0%和49.8%，检测速度为77帧/s。在模型参数量减少19.38%情况下，检测准确率仍然超过基准模型YOLOv8n。在VisDrone2019小目标数据集上，S-YOLO相比其他检测算法的检测精度同样具有明显优势。

虽然本文S-YOLO在空间非合作小目标检测任务中表现出色，可实现航天器实时目标检测，但是在硬件部署之前需要进一步优化模型推理速度。

参考文献（References）

[1] Zhang Z P, Deng C W, Deng Z Y. A diverse space target dataset with multidebris and realistic on-orbit environment[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 15: 9102-9114.

[2] Miao L N, Zhou D, Li X. Spatial non-cooperative object detection based on deep learning[C]// Proceedings of the 2021 China Automation Congress. Piscataway: IEEE Press, 2022: 116-121.

[3] Wu A D, Zhang S Y, Shu L Z, et al. Non-cooperative spacecraft relative navigation based on monocular camera in space on-orbit servicing[C]// Proceedings of the 2022 International Conference on Service Robotics. Piscataway: IEEE Press, 2023: 133-138.

[4] Shan M H, Guo J, Gill E. Review and comparison of active space debris capturing and removal methods[J]. Progress in Aerospace Sciences, 2016, 80: 18-32.

[5] Massimi F, Ferrara P, Petrucci R, et al. Deep learning-based space debris detection for space situational awareness: a feasibility study applied to the radar processing[J]. IET Radar, Sonar & Navigation, 2024, 18(4): 635-648.

[6] Girshick R. Fast R-CNN[C]// Proceedings of the 2015 IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2016: 1440-1448.

[7] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[M]// Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.

[8] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]// Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 779-788.

[9] 王坤, 冯康威. 基于改进YOLOv5-s的交通场景小目标检测算法[J]. 北京航空航天大学学报, 2026, 52(4): 1015-1027.
Wang K, Feng K W. Small target detection algorithm for traffic scenes based on improved YOLOv5-s[J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(4): 1015-1027 (in Chinese).

[10] Wu T, Yang X, Song B, et al. T-SCNN: a two-stage convolutional neural network for space target recognition[C]// Proceedings of the 2019 IEEE International Geoscience and Remote Sensing Symposium. Piscataway: IEEE Press, 2019: 1334-1337.

[11] Xiang Y B, Xi J B, Cong M, et al. Space debris detection with fast grid-based learning[C]// Proceedings of the 2020 IEEE 3rd International Conference of Safe Production and Informatization. Piscataway: IEEE Press, 2021: 205-209.

[12] Wang G J, Lei N W, Liu H M. Improved-YOLOv3 network for object detection in simulated Space Solar Power Systems images[C]// Proceedings of the 2020 39th Chinese Control Conference. Piscataway: IEEE Press, 2020: 7177-7181.

[13] Jia P, Liu Q, Sun Y Y. Detection and classification of astronomical targets with deep neural networks in wide-field small aperture telescopes[J]. The Astronomical Journal, 2020, 159(5): 212.

[14] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.

[15] Aldahoul N, Karim H A, De Castro A, et al. Localization and classification of space objects using EfficientDet detector for space situational awareness[J]. Scientific Reports, 2022, 12: 21896.

[16] Mahendrakar T, White R T, Wilde M, et al. SpaceYOLO: a human-inspired model for real-time, on-board spacecraft feature detection[C]// Proceedings of the 2023 IEEE Aerospace Conference. Piscataway: IEEE Press, 2023: 1-11.

[17] Tang Q, Li X W, Xie M L, et al. Intelligent space object detection driven by data from space objects[J]. Applied Sciences, 2024, 14(1): 333.

[18] Ai H, Zhang H F, Ren L, et al. Detection and recognition of spatial non-cooperative objects based on improved YOLOX_L[J]. Electronics, 2022, 11(21): 3433.

[19] Guo X J, Chen T, Liu J C, et al. Dim space target detection via convolutional neural network in single optical image[J]. IEEE Access, 2022, 10: 52306-52318.

[20] Jiang Y X, Tang Y J, Ying C C. Finding a needle in a haystack: faint and small space object detection in 16-bit astronomical images using a deep learning-based approach[J]. Electronics, 2023, 12(23): 4820.

[21] Tao J, Cao Y F, Ding M. SDebrisNet: a spatial-temporal saliency network for space debris detection[J]. Applied Sciences, 2023, 13(8): 4955.

[22] Yuan Y M, Bai H Y, Wu P F, et al. An intelligent detection method for small and weak objects in space[J]. Remote Sensing, 2023,

15(12): 3169.

[23] 刘一诺, 张琪, 王蓉, 等. 针对航拍小目标检测的 YOLOv7 改进方法[J]. 北京航空航天大学学报, 2025, 51(7): 2506-2512.
Liu Y N, Zhang Q, Wang R, et al. Improved YOLOv7 method for aerial small target detection in aerial photography[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(7): 2506-2512 (in Chinese).

[24] 邓天民, 余洋, 陈月田, 等. 基于自适应复合卷积的航拍小目标检测算法[J]. 北京航空航天大学学报, 2024: 1-14.
Deng T M, Yu Y, Cheng Y T, et al. Small object detection algorithm for aerial photography based on adaptive compound convolution[J]. Journal of Beijing University of Aeronautics and Astronautics, 2024: 1-14 (in Chinese).

[25] Howard A G, Zhu M L, Chen B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications[EB/OL]. (2017-04-17)[2024-07-03]. https://arxiv.org/abs/1704.04861.

[26] Zhang X Y, Zhou X Y, Lin M X, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices[C]// Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 6848-6856.

[27] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]// Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2014: 580-587.

[28] Varghese R, M S. YOLOv8: a novel object detection algorithm with enhanced performance and robustness[C]// Proceedings of the 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems. Piscataway: IEEE Press, 2024: 1-6.

[29] Zeng N Y, Li X Y, Wu P S, et al. A novel tensor decomposition-based efficient detector for low-altitude aerial objects with knowledge distillation scheme[J]. IEEE/CAA Journal of Automatica Sinica, 2024, 11(2): 487-501.

[30] Wang Q L, Wu B G, Zhu P F, et al. ECA-net: efficient channel attention for deep convolutional neural networks[C]// Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 11531-11539.

[31] Wang J Q, Chen K, Xu R, et al. CARAFE: content-aware ReAssembly of FEatures[C]// Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2019: 3007-3016.

[32] Liu W Z, Lu H, Fu H T, et al. Learning to upsample by learning to sample[C]// Proceedings of the 2023 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2024: 6004-6014.

[33] Zhu P F, Wen L Y, Du D W, et al. Detection and tracking meet drones challenge[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(11): 7380-7399.

[34] Redmon J, Farhadi A. YOLOv3: an incremental improvement [EB/OL]. (2018-04-08)[2024-07-03]. https://arxiv.org/abs/1804.02767.

[35] Li C Y, Li L L, Jiang H L, et al. YOLOv6: a single-stage object detection framework for industrial applications[EB/OL]. (2022-09-07)[2024-07-03]. https://arxiv.org/abs/2209.02976.

[36] Wang C Y, Bochkovskiy A, Liao H M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]// Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2023: 7464-7475.

[37] Gao J, Zhang J X, Zhang F, et al. LACTA: a lightweight and accurate algorithm for cherry tomato detection in unstructured environments[J]. Expert Systems with Applications, 2024, 238: 122073.

[38] Wang A, Chen H, Liu L H, et al. YOLOv10: real-time end-to-end object detection[EB/OL]. (2024-05-23)[2024-07-03]. https://arxiv.org/abs/2405.14458.

Lightweight multi-scale feature fusion enhancement algorithm for spatial non-cooperative small target detection

LIU Zhenjiang[1], ZHANG Huijuan[2,*], JI Miaoxin[1], LU Tao[1], ZHANG Chi[1], YU Yuanjin[2]

(1. School of Electrical Engineering, Henan University of Technology, Zhengzhou 450001, China;
2. School of Automation, Beijing Institute of Technology, Beijing 100081, China)

Abstract: In deep space environments, the feature of the non-cooperative small targets cannot be fully extracted, so the detection accuracy of uncooperative small targets will decrease. Furthermore, the computational resources are limited for space applications. To solve the above-mentioned problems, a lightweight multi-scale feature fusion, enhancement and context-aware spatial target detection algorithm is proposed. Multi-scale characteristics of spatially non-cooperative targets are extracted using a lightweight multi-feature downsampling module, which may improve the capacity to obtain fine-grained features. A fast dual spatial pyramid pooling module is developed to enhance the extraction of global contextual features, and the locally salient and global features are aggregated to improve the ability of feature generalization. A cross-dimension triple feature enhancement module (CTFEM) is designed, which could model the global context in term of different dimensional information. Therefore, the CTFEM module could further enhance the feature information of small targets and suppress the confused background information. The VisDrone2019 dataset and a self-built spatial situational awareness dataset (SSAD) are used to validate the suggested method in this research. The experimental findings show that the proposed method decreases the model parameters by 19.38% when compared to the benchmark model YOLOv8n. On the SSAD dataset, the mAP50 and mAP50-95 of the proposed method are improved by 0.2% and 1.2%, respectively. On the VisDrone2019 dataset, the mAP50 and mAP50-95 of the proposed method are improved by 2.0% and 1.4%, respectively.

Keywords: space non-cooperative target detection; small target detection; feature fusion; context information; lightweight network

Received: 2024-07-03; **Accepted**: 2024-09-13; **Published Online**: 2024-09-20 10:37

URL: link.cnki.net/urlid/11.2625.V.20240919.1640.008

Foundation items: Postdoctoral Fellowship Program of CPSF (GZC20233408); National Natural Science Foundation of China (62222304,62173039, 62201199); Innovative Funds of Henan University of Technology(2021ZKCJ07)

* **Corresponding author**. E-mail: zhanghjqy@bit.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0548

多核上下文特征引导下的无人机航拍图像可信检测算法

张志豪，杜丽霞*，郝紫微，侯越
(兰州交通大学 电子与信息工程学院，兰州 730000)

摘 要：针对复杂背景下无人机（UAV）航拍图像目标尺度分布不均匀导致检测精度低的问题，提出一种用于无人机小目标检测的多核上下文特征可信检测算法（MCCF）。在主干网络部分设计多核上下文特征引导模块，该模块利用多尺度卷积核和全局上下文注意力以实现局部细节和全局结构的特征信息融合，从而有效抑制背景噪声；提出可学习位置编码器，该编码器通过动态位置编码自适应调整目标特征的位置表示，降低了采样过程中小目标的空间位置信息损失；为有效识别复杂区域的微小目标，提出多尺度细节融合模块，融合局部空间位置信息和全局结构语义信息，以有效捕捉不同尺度目标的细粒化特征。在 VisDrone2019-DET 数据集和 Drone 数据集的实验结果表明：相较于 RT-DETR 模型，MCCF 模型的 mAP0.5 分别提升了 2.1% 和 6.8%，有效改善了无人机航拍图像目标漏检和误检的问题。

关 键 词：无人机小目标检测；全局上下文注意力；多核上下文特征；编码器；特征融合
中图分类号：TP391.41
文献标志码：A **文章编号**：1001-5965(2026)11-4051-12

近年来，以卷积神经网络(convolutional neural network, CNN)为基础的检测技术表现出优异的性能，基于卷积神经网络的无人机目标检测已被广泛应用于各行各业，如军事打击[1]、交通管制[2]、行人检测[3]及交通监视检测等[4]。然而，由于无人机飞行高度不定、拍摄位置和角度具有特殊性[5]，致使航拍图像存在背景复杂、目标尺度分布不均匀等问题[6-7]，从而影响检测算法的准确性。因此，需要设计一种适用于无人机航拍图像的目标检测模型，以满足实际应用场景需求。

基于卷积神经网络的检测器分为2类：单阶段检测器[8]和双阶段检测器[9]。首先，双阶段检测器通过候选区域定位，其次，细化目标分类以进行准确检测。双阶段检测算法主要包括基于区域的卷积神经网络(region-based convolutional neural networks, RCNN)[10]、Faster-RCNN[11]和 Mask-RCNN 系列[12]，但上述方法由于生成大量边界框导致检测效率降低，难以有效满足无人机目标检测实时性的要求。相较于双阶段检测算法，单阶段检测算法具有较高的实时性，能有效满足无人机小目标检测的需求，主要包括YOLO 系列[13-15]、SSD 系列[16]、Efficient 模型[17]和 Refinedet 模型[18]等。其主要通过物体特征直接对目标类别进行识别和分类，使检测模型无需选择候选区域直接完成端到端的目标检测，从而提升模型的检测效率。目前，已有研究人员将单阶段目标检测算法应用于无人机航拍图像领域。Wang 等[19]基于 YOLOv5 检测框架提出了无人机图像目标检测器 SPB-YOLO，通过条形瓶颈模块和路径聚合网络提高了单阶段检测器在无人机密集目标检测任务中的准确性。薛珊等[20]提出无人机图像检测方

收稿日期：2024-07-18；**录用日期**：2024-09-30；**网络出版时间**：2024-11-01 13:31
网络出版地址：link.cnki.net/urlid/11.2625.V.20241101.1122.001
基金项目：国家自然科学基金 (62063014,62363020)；甘肃省自然科学基金 (22JR5RA365)
* **通信作者**. E-mail：dlx1228@mail.lzjtu.cn

引用格式：张志豪，杜丽霞，郝紫微，等. 多核上下文特征引导下的无人机航拍图像可信检测算法 [J]. 北京航空航天大学学报，2026，52（11）：4051-4062. Zhang Z H，Du L X，Hao Z W，et al. Multi-core contextual feature-guided algorithm for trusted detection of UAV aerial images [J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：4051-4062 （in Chinese）.

法YOLO-Ads,通过引入协调注意力模块以有效加强检测网络对空间和通道的关注度,提升检测模型的准确性和鲁棒性。Liu等[21]基于YOLOv3检测框架提出UAV-YOLO,通过增强浅层卷积以丰富空间信息,但对于小目标存在漏检和误检的问题。刘婷婷等[22]提出一种基于YOLOv3框架的无人机检测网络,将轻量化主干网络和场景上下文信息相融合以提升检测精度,但会遗漏目标关键特征信息。尽管单阶段检测算法在检测速度和检测精度上取得了一定的提升,但仍存在尺度不均匀目标检测精度低的问题。

鉴于无人机航拍图像中目标尺度分布不均匀,远距离目标特征难以有效提取的问题[23],深度学习建模理论中的扩大感受野[24]和自注意力机制[25],为实时、准确地提取目标全局上下文信息,提供了更为有效的解决方案。Yu等[26]利用扩张卷积以增加感受野范围,从而有效提取目标全局结构特征。Dai等[27]设计可变形卷积,通过卷积偏移学习重新定位空间采样位置,丰富空间特征信息,从而有效提取目标特征。Hu等[28]设计SENet,利用全局池化操作和注意力聚合全局上下文信息以进一步提高检测精度。Li等[29]设计LSKNet,利用大卷积核扩大感受野以有效提取目标全局上下文信息。Dosovitskiy等[30]设计ViT网络,通过分层窗口化捕获每个窗口内的长距离信息,并应用级联转换器提取不同窗口内的目标特征向量,但ViT无法有效提取局部细节信息。Peng等[31]设计Conformer混合网络结构,通过融合卷积运算和自注意机制以增强目标全局-局部信息表示,从而有效提升目标检测的准确性,但小目标信息交互时仍会遗漏细节信息。综上所述,扩大感受野通常会引入相当大的背景噪声,而自注意力则存在忽略目标局部特征表示的风险[32-33]。

针对上述问题,本文提出一种用于无人机航拍图像检测的多核上下文特征可信检测算法(multi-core contextual feature trusted detection network, MCCF)。该算法由多核上下文特征引导模块、可学习位置编码器和多尺度细节融合模块组成。多核上下文特征引导模块主要包括多核交互模块和全局上下文注意力。其中,多核交互模块主要捕获目标局部细节信息,而全局上下文注意力关注目标的全局结构特征,融合目标局部细节信息和全局结构特征以实现背景上下文关键特征信息的提取。在此基础上,提出基于可学习位置编码的编码器,该编码器通过可学习的位置编码方式以有效提取目标全局位置信息,进而增强模型的特征表达能力,同时缓解了小目标空间信息丢失问题。最后,针对区域内尺度不均目标检测精度低的问题,本文设计了多尺度细节融合模块,通过全局上下文引导模块与局部提取模块结合的方式,增强目标局部细节信息和全局结构信息间的交互融合能力,从而提升小目标检测的准确性。此外,为验证模型在极端天气条件下的鲁棒性,本研究引入了雾霾、风雪、阴雨极端天气的干扰测试,实验证明多核上下文特征可信检测算法在极端天气条件下的有效性和稳健性性。为解释改进思路在模型决策中的过程,本文对模型的全局感受野、整体模型对小目标的关注进行了解释性分析,以突出本文模型改进点对决策结果的影响。本文提出如下创新方法:

1)设计多核上下文特征引导模块,主要通过并行排列多个无膨胀率的多尺度卷积核在不同的感受野中提取密集的目标细节特征,其细节特征沿着通道维度自适应融合,从而聚合局部上下文信息,并行设计全局上下文注意力,利用全局平均池化和一维带状卷积以捕获远处目标特征间关系并增强局部区域内的特征,从而提高无人机航拍图像检测的准确性。

2)设计可学习位置编码器,通过动态位置编码学习到目标的最优空间位置信息,以弥补检测网络在特征提取过程中的信息损失。

3)设计多尺度细节融合模块,利用全局池化层和深度卷积核以融合局部位置信息和全局语义信息,从而更为精细地识别无人机航拍图像复杂区域的微小目标。

4)设计模型鲁棒性增强实验,通过引入极端天气扰动因素,以验证模型应对极端天气事件的稳健性。同时,为提升检测模型的可信性,对模型关键层特征分布、整体模型对小目标关注程度均进行特征可视化操作,以进一步突出改进点对决策结果的影响。

1 本文算法

本文提出基于RT-DETR模型的多核上下文特征可信检测算法,其网络结构如图1所示。首先,在主干网络中设计多核上下文特征交互模块(multi core context feature guidance module, MCF),利用多个无膨胀率的多尺度卷积核在不同感受野中收集目标的局部细节信息,并行设计全局上下文注意力机制以捕获全局结构信息。其次,设计可学习深度位置编码器(learnable position encoder, LPE),利用动态的学习位置编码自适应调整目标特征的空间位置信息,以有效弥补区域内目标特征丢失问题。最后,设计多尺度细节融合模块(multi scale detail

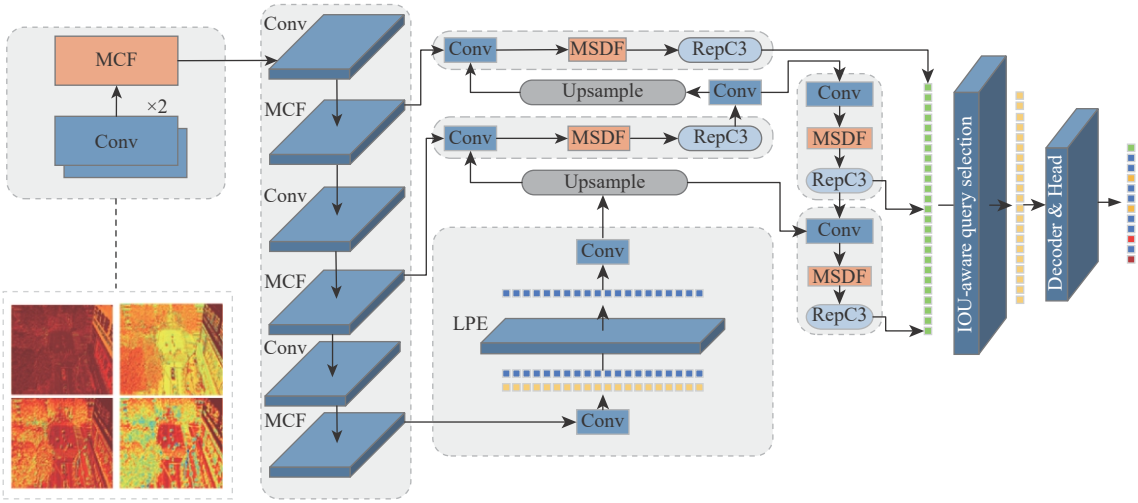


图 1　多核上下文特征可信检测算法网络整体架构

Fig. 1　Overall architecture of multi-core contextual feature trusted detection network

fusion module, MSDF), 通过融合目标局部细节和全局结构特征的方式实现对不同尺度目标的特征信息提取。

1.1　多核上下文特征引导网络

与常规目标检测不同, 无人机航拍图像目标检测常面临背景复杂和目标尺度不均匀的问题, 致使目标全局-局部交互特征难以有效表示, 进而导致目标关键特征无法有效提取。鉴于此, 本文提出多核上下文特征引导模块以有效筛选目标全局和局部关键特征信息, 其整体结构如图 2 所示。多核上下文特征引导模块由多核交互(multi core interaction, MCI)模块和全局上下文注意力(global contextual attention, GCA)组成。其中, 多核交互模块主要利用 1×1 深度卷积核来捕获图像细节信息, 然后利用一组并行设计的多尺度卷积核来捕获局部上下文信息。

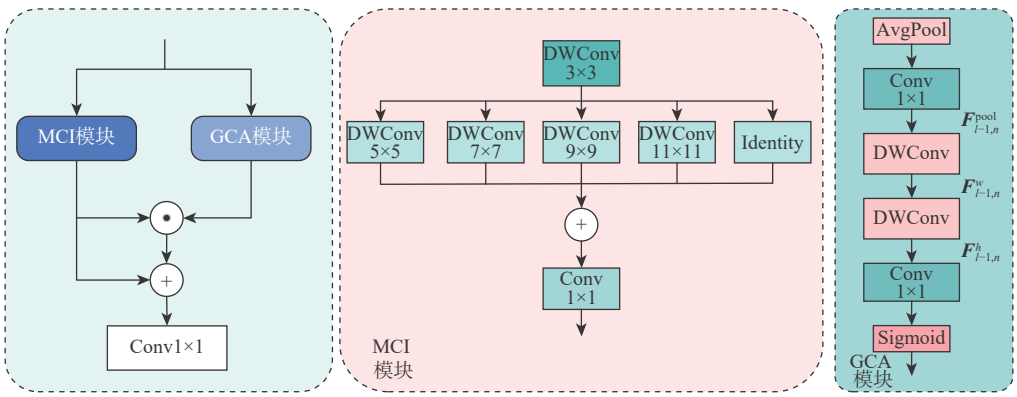


图 2　多核上下文特征引导模块

Fig. 2　Multicore contextual feature bootstrap module

多核交互模块第 1 阶段的第 n 个多核块内的卷积核具体表示如下:

$$\boldsymbol{L}_{l-1,n}=\mathrm{Conv}_{k_s\times k_s}(\boldsymbol{X}) \tag{1}$$

$$\boldsymbol{Z}_{l-1,n}^{(m)}=\mathrm{DWConv}_{k^{(m)}\times k^{(m)}}(\boldsymbol{L}_{l-1,n}) \qquad m=1,2,3,4 \tag{2}$$

式中: $\mathrm{Conv}_{k_s\times k_s}$ 表示 $k_s\times k_s$ 卷积神经网络, $k_s=3$ 表示 3×3 卷积; X 表示输入图像; $\boldsymbol{L}_{l-1,n}\in\mathbf{R}^{1/2C_l\times H_l\times W_l}$ 表示 $k_s\times k_s$ 卷积提取的局部特征; $\boldsymbol{Z}_{l-1,n}^{(m)}\in\mathbf{R}^{1/2C_l\times H_l\times W_l}$ 表示第 m 个 $k^{(m)}\times k^{(m)}$ 深度卷积; $\mathrm{DWConv}_{k^{(m)}\times k^{(m)}}$ 表示卷积核大小为 $k^{(m)}\times k^{(m)}$ 的逐通道深度卷积操作, $k^{(m)}=(m+1)\times 2+1$ 表示多尺度卷积核。

通过大小为 1×1 的卷积以融合局部特征和上下文特征, 表征各个通道之间的相互关系的具体操作如下:

$$\boldsymbol{P}_{l-1,n}=\mathrm{Conv}_{1\times 1}\left(\boldsymbol{L}_{l-1,n}+\sum_{m=1}^{4}\boldsymbol{Z}_{l-1,n}^{(m)}\right) \tag{3}$$

式中: $\boldsymbol{P}_{l-1,n}\in\mathbf{R}^{1/2C_l\times H_l\times W_l}$; $\mathrm{Conv}_{1\times 1}$ 卷积作为通道融合机制以集成具有不同感受野大小的特征。

多核交互模块利用多个无膨胀率的卷积核在有效捕捉不同尺度的特征空间信息的同时, 避免了过于稀疏的特征表示提取。最后将获取的尺度不均匀目标特征信息进行卷积融合, 使融合后的特征

空间具备丰富的局部上下文信息，从而提升无人机航拍图像在复杂背景下的检测精度。

为更好地提取无人机航拍图像小目标的全局上下文信息，弱化复杂背景信息的干扰。本文提出全局上下文注意力来捕获远距离目标之间的关系，并将全局上下文注意力集成到多核交互模块中以实现目标全局-局部信息之间的交互。该注意力利用全局平均池化和一维带状卷积来捕获远程目标之间的上下文相互依赖性并增强全局结构特征。其结构如图2所示。以第1阶段第 n 个多核上下文交互模块中的全局上下文注意力为例，本文采用平均池化和1×1卷积来获得全局目标特征：

$$\boldsymbol{F}_{l-1,n}^{\text{pool}} = \text{Conv}_{1\times1}(P_{\text{avg}}(\boldsymbol{X})) \tag{4}$$

式中：$\boldsymbol{F}_{l-1,n}^{\text{pool}}$ 为全局细节特征；$\boldsymbol{P}_{\text{avg}}$ 表示平均池化操作；$\boldsymbol{X}$ 表示输入图像。

$$\boldsymbol{F}_{l-1,n}^{w} = \text{DWConv}_{1\times k_b}(\boldsymbol{F}_{l-1,n}^{\text{pool}}) \tag{5}$$

$$\boldsymbol{F}_{l-1,n}^{h} = \text{DWConv}_{k_b\times1}(\boldsymbol{F}_{l-1,n}^{w}) \tag{6}$$

$$\boldsymbol{A}_{l-1,n} = \text{Sigmoid}(\text{Conv}_{1\times1}(\boldsymbol{F}_{l-1,n}^{h})) \tag{7}$$

$$\boldsymbol{F}_{l-1,\text{n}}^{\text{attn}} = (\boldsymbol{A}_{l-1,n}\odot\boldsymbol{P}_{l-1,n})\oplus\boldsymbol{P}_{l-1,n} \tag{8}$$

式中：$\boldsymbol{F}_{l-1,n}^{w}$ 和 $\boldsymbol{F}_{l-1,n}^{h}$ 表示不同深度方向的卷积输出；w 表示宽度；h 表示高度；$\text{DWConv}_{1\times k_b}$ 表示具有选择性深度方向的一维带状卷积；$\boldsymbol{A}_{l-1,n}$ 表示注意力图的输出；Sigmoid激活函数保证注意力图在(0,1)的范围内；$\boldsymbol{F}_{l-1,\text{n}}^{\text{attn}}$ 表示多核上下文特征引导模块的特征输出；⊙表示逐元素乘法；⊕表示逐元素求和。

1.2 可学习位置编码器

在多核上下文特征交互模块利用多尺度卷积核和全局上下文注意力进行全局-局部目标特征信息交互时，由于图像尺度变化，易导致远处目标的空间位置信息丢失，从而影响无人机航拍图像的检测性能。鉴于此，本文设计了一种基于可学习位置编码的编码器以获取目标的空间位置信息和特征信息。可学习位置编码器结构如图3所示，图3在编码器架构下将固有位置编码替换为可学习位置编码。该编码器能够在目标全局-局部特征信息的指导下，通过嵌入层(Embedding)学习每个输入图像的位置表示，使得编码器可以在训练过程中更新图像特征的位置矩阵，以实现每个目标位置信息的最优表示。然后，将无人机航拍图像采样的位置表示馈送至多头自注意力关注以捕捉不同位置表示的目标关键特征，有助于识别和定位图像中的多个目标。由此，可学习位置编码器通过可学习性的位置编码自适应地选择目标空间位置，并动态调整目标空间位置的数量和分布，从而有效解决了远处目标尺寸变化导致的空间位置信息丢失问题。

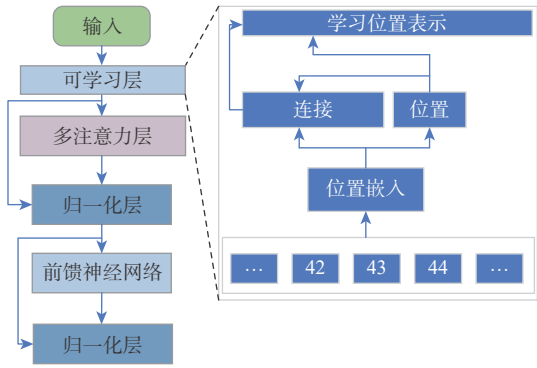


图3 可学习位置编码器架构

Fig. 3 Learning position encoder architecture

在训练过程中，可学习嵌入矩阵 $\boldsymbol{E}$ 的具体表达式可以表示为

$$\boldsymbol{E} = \alpha\cdot\nabla_{\boldsymbol{E}}\boldsymbol{L} \tag{9}$$

式中：α 为学习率，控制了每次更新位置的大小；$\nabla_{\boldsymbol{E}}$ 为损失函数；$\boldsymbol{L}$ 为关于嵌入矩阵 $\boldsymbol{E}$ 的梯度。

1.3 多尺度细节融合模块

针对复杂区域尺度不均匀航拍目标难以有效检测的问题，本文提出一种多尺度细节融合模块以实现局部位置信息与全局语义特征信息的融合，如图4所示。该模块由全局上下文引导模块和局部提取模块组成。其中，全局上下文引导模块通过全局平均池化层和全连接层捕获全局结构信息，使小目标全局结构特征更为显著。继而采用局部提取模块对目标全局上下文信息进行深度卷积操作，获得目标局部细节信息，进而增强目标局部细节信息和全局结构信息间的交互融合能力，从而效捕捉不均匀尺度目标的细粒化特征。为减少空间使用率，降低计算复杂度，本文将全局上下文注意力和局部提取模块串联操作，在降低多尺度细节融合模块复杂度的同时，避免遗漏了不同特征间的细节信息。

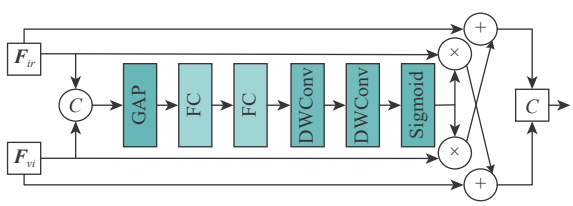


图4 多尺度细节融合模块架构

Fig. 4 Architecture diagram of the multi-scale detail fusion module

多尺度细节融合模块中的深度卷积和全局上下文引导模块对输入图像的增强特征表示如下：

$$\tilde{\boldsymbol{F}}_{ir}^{i}=\boldsymbol{F}_{ir}^{i}\oplus(\boldsymbol{F}_{vi}^{i}\otimes\delta(\mathrm{DWConv}^{n}(\boldsymbol{A}_{\mathrm{tten}ir})))\tag{10}$$

$$\boldsymbol{A}_{\mathrm{tten}ir}=\mathrm{GAP}(C(\boldsymbol{F}_{ir}^{i},\boldsymbol{F}_{vi}^{i}))\tag{11}$$

$$\tilde{\boldsymbol{F}}_{vi}^{i}=\boldsymbol{F}_{vi}^{i}\oplus(\boldsymbol{F}_{vi}^{i}\otimes\delta(\mathrm{DWConv}^{n}(\boldsymbol{A}_{\mathrm{tten}_{vi}})))\tag{12}$$

$$\boldsymbol{A}_{\mathrm{tten}_{vi}}=\mathrm{GAP}(C(\boldsymbol{F}_{ir}^{i},\boldsymbol{F}_{vi}^{i}))\tag{13}$$

式中: $\tilde{\boldsymbol{F}}_{ir}^{i}$和$\tilde{\boldsymbol{F}}_{vi}^{i}$分别表示局部空间位置信息和全局结构语义信息的输出; C表示连接 2 个位置的信息; $\boldsymbol{F}_{ir}^{i}$和$\boldsymbol{F}_{vi}^{i}$分别表示浅层位置信息和深层语义特征; $\oplus$表示逐元素求; $\otimes$表示逐元素乘法; DWConv^{n}表示n个深度卷积层; $(\cdot)$表示通道维度上的串联操作; $\delta(\cdot)$和$\mathrm{GAP}(\cdot)$分别表示Sigmoid函数和全局平均池化。

2　实　验

2.1　实验数据集

在无人机航拍中, 小目标占用的面积不到总面积的 1%～5%, 小目标的大小通常在 10～100 像素。同时, 随着无人机飞行高低和摄像头角度之间距离的变化, 目标的大小也会发生变化, 导致目标变小, 容易被忽视。因此, 为了验证本文模型在复杂环境中检测小目标的准确性, 本文在 2 个不同的数据集上进行了检测实验。

本文实验所采用数据集为 VisDrone2019-DET 无人机图像目标检测公开数据集和某市无人机实际采集的 Drone 数据集, 其详细介绍如下。

1) VisDrone2019-DET: 是一个基于无人机视觉的公开目标检测和跟踪数据集, 由 6 471 张训练图像、548 张验证图像和 3 190 张测试图像组成, 共计 10 209 张静态图像, 每张航拍图像的分布和比例不同, 使得航拍目标的实际尺寸远小于其他背景物体或其他类别的目标, 并存在密集小目标和小目标遮挡的现象。该数据集包含几个场景, 本文选择 10 个预定义的类别: 行人、人、汽车、卡车、公共汽车、卡车、机动车、自行车、遮阳三轮车和三轮车。

2) Drone 数据集: 在某市无人机监控捕获的实际数据集上验证了本文算法, 共包含 8 851 张训练集、2 213 张验证集, 像素维持在 1 920×1 920。每张航拍图像的分布和比例不同, 使得远处车辆目标的实际尺寸远小于其他靠近无人机摄像头的目标, 并且远处存在密集小目标和小目标遮挡的现象。预定类别为汽车、行人、摩托车、面包车、公交车、卡车、三轮车、自行车、摩托车、送货车、施工车。

2.2　评估指标和基准模型

实验平台使用 Ubuntu22.04 操作系统, 以 Pycharm 平台为编码工具, 结合 Pytorch1.8 构建模型, GPU 为 NVIDIA GeForce RTX 3080Ti。为了公平对比算法的性能, 所有算法采用相同的超参数设置进行训练、验证, 初始模型的参数设置为运行尺寸为 6, 运行轮数为 100, 比例尺寸为 0.5, 动量为 0.9, 权重衰减为 0.005。为验证本文算法的有效性和先进性, 本文使用召回率本文算 R、准确率 P、mAP0.5、mAP0.5∶0.95 和 mAP 的度量作为模型性能评估指标。其中, 平均精度均值(mean average precision, mAP)表示对所有类别的 AP 值求平均值, mAP0.5 为 IOU=0.5 时的 mAP, mAP0.5∶0.95 表示设置 10 个 IOU 阈值, 从 0.5~0.95, 步长为 0.05 时的 mAP。AP 和 mAP 的计算式如下:

$$P=\frac{N_{\mathrm{TP}}}{N_{\mathrm{TP}}+N_{\mathrm{FP}}}\tag{14}$$

$$R=\frac{N_{\mathrm{TP}}}{N_{\mathrm{TP}}+N_{\mathrm{FN}}}\tag{15}$$

$$A_{\mathrm{P}}=\int_{0}^{1}P(R)\,\mathrm{d}(R)\tag{16}$$

$$m_{\mathrm{AP}}=\frac{\sum_{i=1}^{N}A_{\mathrm{P}_i}}{N}\tag{17}$$

式中: N为物体类别个数; N_{FP}为假正样本, 即误检; N_{FN}为假负样本, 即漏报; N_{TP}为真正样本, 即正确检测。为了在无人机航拍图像检测任务中验证本文算法, 本文比较了几种最先进的检测框架, 即 Faster-RCNN、RetinaNet、CenterNet、SSD、ATSS-FPN-DyHead、TOOD、DINO、YOLOX-Tiny、GFL、RTMDet、YOLOv3、YOLOv4、YOLOv5、YOLOv7 和 RT-DETR。

在实际生活中, 由于单阶段检测框架实时性表现较好, 因此, 在 Drone 数据集中, 将本文与单阶段检测算法进行比较, 以 YOLOv3、YOLOv5、YOLOv6、YOLOv8、YOLOv8-Decoder 及 RT-DETR 为基准线。

2.3　消融实验

为验证本文多核上下文特征交互模块、可学习位置编码器和多尺度细节融合模块的有效性, 选用 RT-DETR 模型为消融实验的基准模型, 依次加入各个模块进行消融实验, 所有消融实验均在 VisDrone2019-DET 数据集上进行。首先, 在基准模型 RT-DETR 中加入多核上下文特征交互模块, 并将其命名为 G-MCF, 在此基础上, 加入可学习位置编码器, 将其命名为 G-LPE, 最后, 加入多尺度细节融合模块, 将其命名为 G-MCDF, 由此进行消融实验分析, 具体结果如表 1 所示。

表 1 给出了不同改进模型的微小目标识别性能。由表 1 可知, 基础 RT-DETR 模型的 R、P、mAP0.5、

表1 VisDrone2019-DET数据集中不同改进模块的客观指标对比

Table 1 Comparison of objective metrics for different improvement modules in VisDrone2019-DET dataset %

模型	*R*	*P*	mAP0.5	mAP0.5∶0.95
RT-DETR	40.8	56.5	42.5	25.7
G-MCF	41.0	57.6	43.0	26.0
G-LPE	41.5	58.0	43.6	26.4
G-MCDF	43.3	58.2	44.6	26.9

mAP0.5∶0.95分别为40.8%、56.5%、42.5%、25.7%,其目标识别精度不高。G-MCF模型的*R*、*P*、mAP0.5、mAP0.5∶0.95评价指标分别为41.0%、57.6%、43.0%和26.0%,相较于RT-DETR模型,其性能分别提升了0.2%、1.1%、0.5%和0.3%,这表明多核上下文特征交互模块能够有效提取目标的局部细节和全局结构,从而减少背景噪声的影响。G-LPE模型在G-MCF模型的基础上,增加了可学习位置编码器,其*R*、*P*、mAP0.5、mAP0.5∶0.95评价指标分别是41.5%、58.0%、43.6%和26.4%,相较于G-MCF模型,识别精度进一步提升,其指标分别提升了0.5%、0.4%、0.6%和0.4%,证明可学习位置编码器有效解决了目标特征信息丢失问题。G-MCDF模型在G-LPE模型基础上,增加了多尺度细节融合模块,其*R*、*P*、mAP0.5、mAP0.5∶0.95评价指标分别是43.3%、58.2%、44.6%和26.9%,其特征提取和融合能力进一步提升,其性能分别提升了1.8%、0.2%、1.0%和0.5%,意味着多尺度细节融合模块可以很好地处理尺度分布不均匀目标特征提取和融合问题。

2.4 类别错误消融实验

传统消融实验主要选用mAP作为模型性能评估指标。然而,mAP通常不透明,无法具体指明模型改进的细节,如性能的具体提升点或优化的错误类型。因此,需要更细致的分析方法来解释模型的改进,在本文消融实验中,实现了准确的类别错误检测,具体错误类型包括分类错误(Cls)、定位错误(Loc)、重复检测框错误(Dupe)、背景误差(Bkg)、漏检(Miss)、错误预测为负样本的数量(FN),以及错误预测为正样本的数量(FP)。这种细致的错误分析方法不仅揭示了模型在哪些方面需要改进,而且展示了改进模块在提高无人机巡检图像分析准确性方面的具体贡献。

从表2可以看出,RT-DETR模型的Cls、Loc、Dupe、Bkg、Miss、FP和FN分别是20.98、3.82、0.21、2.12、13.31、10.92和37.54,其模型检测性能较差。首先,加入多核上下文特征交互模块(G-MCF)后,G-MCF模型的Loc、Dupe、Bkg、Miss和FP分别是3.67、0.19、2.09、13.24和10.86,相较于RT-DETR模型,其筛选目标全局-局部特征信息的性能表现较优,其Loc、Dupe、Bkg、FP分别降低了0.15、0.02、0.03、0.07和0.06,表明本文设计的多核上下文特征引导模块有效捕捉到目标全局-局部关键信息,使模型聚焦于目标全局上下文区域。其次,添加可学习位置编码器后,G-LPE的Cls、Bkg和FP分别是20.45、2.07和10.44,相较于G-MCF模型,G-LPE的Cls、Bkg和FP分别降低了0.72、0.02和0.42,由此看出,可通过弥补复杂区域内丢失目标特征信息的方式,有效提升检测模型的准确性。最后,添加多尺度细节融合模块,G-MCDF的Dupe、Miss和FN分别是0.19、13.05、37.72,相较于G-LPE模型,其Dupe、Miss和FN分别降低了0.02、0.59和1.20,表明上下文特征融合模块有效提取了全局目标结构信息。综上所述,在无人机航拍图像检测领域,本文算法明显优于RT-DETR模型。

表2 VisDrone2019数据集中不同模型的性能比较

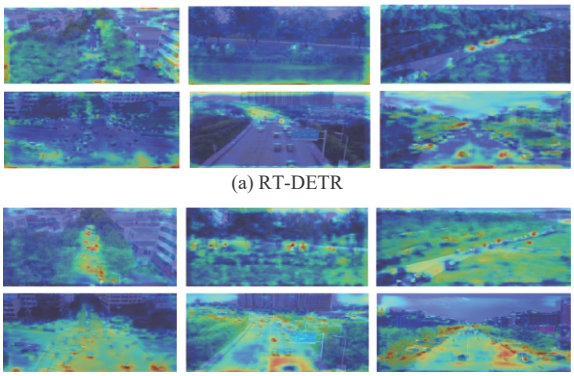
Table 2 Performance comparison of different models in the VisDrone2019 dataset

模型	Cls	Loc	Dupe	Bkg	Miss	FP	FN
RT-DETR	20.98	3.82	0.21	2.12	13.31	10.92	37.54
G-MCF	21.17	3.67	0.19	2.09	13.24	10.86	37.66
G-LPE	20.45	3.84	0.21	2.07	13.64	10.44	38.92
G-MCDF	20.98	3.92	0.19	2.24	13.05	10.90	37.72

2.5 可解释性实验

为提升改进模型的可信性,本节对本文算法进行可视化解释,如图5所示。其中,蓝色的区域为网络模型着重关注区域,颜色越深代表关注度越高。通过这种方法,可以更好地理解模型如何识别和处理图像中的不同特征,从而提高对改进模型的信任度和接受度。

由图5可知,本文算法的红色关注特征区域相较于RT-DETR更加广泛和准确,这意味着本文算法能够关注到全局上下文信息,并利用目标局部细节信息和全局结构之间的交互性来突出目标显著特征。而无人机航拍图像中的目标尺度分布不均



(a) RT-DETR

(b) 本文算法

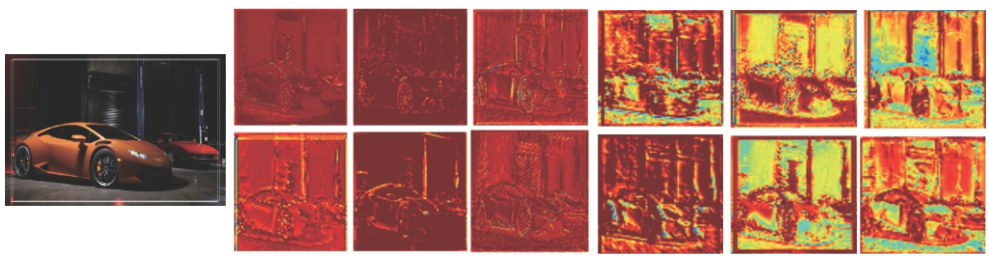
图 5　本文算法的模型决策关注可视化过程

Fig. 5　Model decision making in the proposed algorithm focuses on visualisation processes

匀, RT-DETR 模型的特征关注点较为有限, 无法有效识别远距离目标特征, 尤其是在树木遮挡区域, RT-DETR 模型无法对遮挡目标细节特征进行有效关注, 易导致小目标漏检和误检的问题。本文算法的优势不仅体现在其对目标局部细节和全局上下文结构的理解上, 还在于其能够有效利用动态位置编码以实现对目标最优位置的特征表示, 并利用细节融合模块有效识别遮挡区域和密集区域的小目标, 对于在复杂场景下的无人机航拍图像检测至关重要。

2.6　可视化实验

在目标检测领域, 理解模型如何做出决策至关重要。因此, 本文通过分析 CNN、Transformer 和本文算法的特征层变化, 揭示模型可解释性的决策过程。图 6 展示了这 3 种模型在处理图像时的差异: 基于 CNN 的 YOLOv5 检测模型能够识别具有显著特征的局部区域, 如图 6(a)、图 6(d)中的车辆局部细节特征, 但其忽略了反射在镜子中的红色车头, 远距离目标特征难以有效表示, 表明基于 CNN 的单阶段检测器在提取目标全局结构特征信息时存在一定的局限性。相比之下, 基于 Transformer 的 RT-DETR 模型虽然能够捕捉到图像全局结构的基本轮廓, 但在局部细节上表现不佳, 如图 6(b)、图 6(e)中, 如反射在镜子中的红色车头特征难以有效表征, 意味着基于 Transformer 的 RT-DETR 模型擅长处理提取远距离目标特征, 但缺乏对局部信息细节的捕捉。而本文算法通过全局和局部上下文信息的交互, 成功地提取了完整的局部对象特征和全局结构关系, 如图 6(c)、图 6(f)黄色车辆和红色车头的特征。该方法分析不仅展示了模型的决策过程, 而且强调了全局部上下文信息对于多核上下文特征网络的重要性, 由此进一步表明本文算法可实现较高精度检测。



(a) 原图　(b) YOLOv5 (浅层)　(c) RT-DETR (浅层)　(d) 本文算法 (浅层)　(e) YOLOv5 (深层)　(f) RT-DETR (深层)　(g) 本文算法 (深层)

图 6　CNN(YOLOv5)、Transformer(RT-DETR) 和 MCCF 的特征图比较

Fig. 6　Comparison of feature maps of CNN (YOLOv5), Transformer (RT-DETR), and MCCF

2.7　鲁棒性实验

近年来, 极端天气的频繁出现对无人机交通巡检的准确性构成了挑战。为了探索无人机航拍图像检测网络在复杂天气条件下的性能, 本文通过调整 VisDrone2019-DET 数据集中图像的室外环境, 模拟极端天气情况来验证本文网络的鲁棒性。在本文算法中设计了数据增强方法, 增加阴雨天气、雾霾天气、风雪天气作为干扰因素, 测试模型在极端天气中的适用性。不同极端天气中的部分航空目标检测结果如表 3 所示, 表中, 加粗数值为不同模型时对比下的最优数值。本文算法对于鲁棒性的评价指标为 mAP0.5。

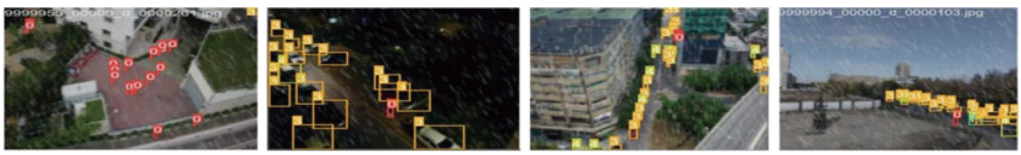
恶劣天气下的鲁棒性实验主要是验证多核上下文特征引导下的无人机航拍图像可信检测算法在极端天气条件下的鲁棒性能, 并确保其在复杂环境中仍然保持出色的检测能力。图 7 显示了阴雨天气、雾霾天气、风雪天气的可视化。

在阴雨天气的模拟场景中, RT-DETR 模型、YOLOv5-Decoder 模型和 YOLOv8-Deocder 模型的 mAP0.5 分别为 32.6%、21.5% 和 20.9%, 而本文算法在 640 像素×640 像素输入尺寸下的性能在所有模型中最为优越, mAP0.5 为 33.6%, 相较于 RT-DETR 模型、YOLOv5-Decoder 模型和 YOLOv8-Deocder 模型的 mAP0.5 分别提升了 1%、12.1%、12.7%。即使调整各个模型的输入尺寸, 本文算法仍然优于大多数其他模型。这表明, 本文算法通过利用自适应跨

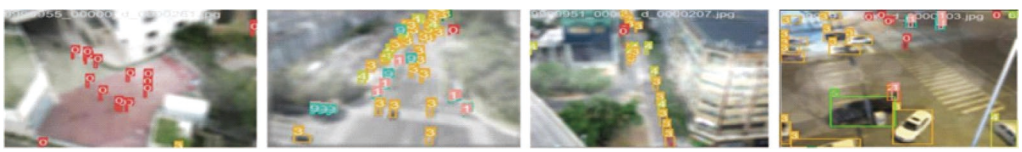
表3 VisDrone2019-DET数据集进行极端天气鲁棒性实验

Table 3 Conducting extreme weather robustness experiments on the VisDrone2019-DET dataset

算法	输入尺寸/(像素×像素)	mAP0.5/%		
		阴雨天气	雾霾天气	风雪天气
YOLOv5-Decoder	640×640	21.5	16.4	18.9
YOLOv5-Decoder	608×608	20.0	16.2	20.0
YOLOv8-Decoder	640×640	20.9	20.3	23.5
YOLOv8-Decoder	608×608	19.6	19.1	22.3
RT-DETR	640×640	32.6	30.3	34.1
RT-DETR	704×704	35.3	33.4	36.7
本文算法	**640×640**	**33.6**	**31.9**	**37.8**



(a) 阴雨天气



(b) 雾霾天气



(c) 风雪天气

图7 极端天气的可视化

Fig. 7 Visualization of extreme weather conditions

层注意力交互模块,有效地提升了目标特征地感受野并增强了检测模型对于目标关键特征的提取,而RT-DETR本身的自注意力机制,善于捕捉图像的全局结构信息,在阴雨天气无法有效识别目标的局部细节,特别是使局部特征密集区域。YOLOv5-Decoder模型和YOLOv8-Deocder模型擅长捕捉目标的局部细节,但无法有效识别远距离目标的关键特征。在降雨影响视野的情况下,MCCF有效地识别了图像中的目标并提升了检测模型的准确率。

在雾霾天气下,输入尺寸为640像素×640像素的RT-DETR模型、YOLOv5-Decoder模型和YOLOv8-Deocder模型的mAP0.5分别为30.3%、16.4%和20.3%,而输入尺寸为640像素×640像素的MCCF模型的性能在所有模型中最为优越,mAP0.5达到31.9%,相较于RT-DETR模型、YOLOv5-Decoder模型和YOLOv8-Deocder模型的mAP0.5分别提升了1.6%、15.5%、11.6%。即使输入不同尺寸的图像,MCCF模型也仍然优于大多数其他模型。在风雪天气下,输入尺寸为640像素×640像素的RT-DETR、YOLOv5-Decoder模型和YOLOv8-Deocder模型的mAP0.5分别为34.1%、18.9%和23.5%,本文算法在所有输入尺寸为640像素×640像素的图像中准确度最优,mAP0.5达到37.8%,相较于RT-DETR模型、YOLOv5-Decoder模型和YOLOv8-Deocder模型的mAP0.5分别提升了3.7%、18.9%、14.3%。这表明,本文算法能够通过其自适应跨层注意力交互模型和可变形编码器提取机制有效地扩大目标感受野并提取目标的深层语义信息。特别是在低分辨率和遮挡背景下,本文算法的多尺度交叉融合模块可以有效地收集目标的全局-局部交互特征信息和频域信息,以实现准确的目标特征识别和融合,这表明该算法在处理视觉噪声和光照变化方面具有出色的鲁棒性。

2.8 算法总体分析

为了验证本文算法的有效性,在VisDrone2019-DET数据集上将本文算法与目前主流的检测模型对比,即Faster-RCNN、RetinaNet、CenterNet、SSD、ATSS-FPN-DyHead、TOOD、DINO、YOLOX-Tiny、GFL、RTMSet和YOLO系列。如表4所示,本文算

表 4　各算法在 VisDrone2019-DET 数据集上总体性能比较

Table 4　Overall performance comparison of different algorithms on the VisDrone2019-DET dataset

算法	基准网络	mAP/%	mAP0.5/%	参数量
Faster-RCNN	ResNet50	21.5	35.7	41.700×10^6
RetinaNet	ResNet50	16.1	27.3	21.370×10^6
CenterNet	DLA-34	12.4	22.7	25.600×10^6
SSD	VGG-16	8.6	16.6	4.230×10^6
YOLOv3	MobileNet	8.1	17.7	3.750×10^6
YOLOv4	ResNet50	18.6	25.4	6.060×10^6
YOLOv5	CSPDarkNet	19.1	29.8	7.050×10^6
YOLOv7	CSPDarkNet	22.9	34.5	37.260×10^6
ATSS-FPN-DyHead	ResNet50	20.4	33.8	38.910×10^6
TOOD	ResNet50	20.4	33.9	32.400×10^6
DINO	DETR	25.3	44.5	47.560×10^6
YOLOX-Tiny	CSPDarkNet	14.8	27.8	5.035×10^6
GFL	CSPDarkNet	19.3	32.1	32.279×10^6
RTMDet	CSPDarkNet	18.4	31.2	4.876×10^6
RT-DETR	ResNet18	32.6	42.5	21.300×10^6
本文算法	ResNet18	**33.7**	**44.6**	$\mathbf{17.200\times10^6}$

法相较于其他几种经典的通用目标检测算法中具有良好的检测性能，其中，本文算法的 mAP 和 mAP0.5 分别是 33.7% 和 44.6%，相较于 Faster-RCNN 算法和 SSD 算法，mAP 和 mAP0.5 分别提升了 12.2%、8.9% 和 25.1%、28%；且本文算法的参数远低于 Faster-RCNN；相较于 ATSS-FPN-DyHead 和 TOOD，mAP 和 mAP0.5 分别提升了 13.3%、10.8% 和 13.3%、10.7%，而且本文算法的参数量远小于 ATSS-FPN-DyHead 和 TOOD；相较于 DINO、GFL 和 RTMDet，mAP 和 mAP0.5 分别提升了 8.4%、14.4%，15.3%、0.1% 和 12.5%、13.4%；相较于 Retina-Net 算法和 CenterNet 模型，mAP 和 mAP0.5 分别提升了 17.6%、21.3% 和 17.3%、21.9%；相较于 YOLOX-Tiny，mAP 和 mAP0.5 分别提升 18.9% 和 16.8%；与 YOLOv3 模型相比，mAP 提升了 25.6%，mAP0.5 提升了 26.9%；与 YOLOv4 模型相比，mAP 提升了 15.1%，mAP0.5 提升了 19.22%，相较于 RT-DETR 模型，mAP 提升了 1.1%，mAP0.5 提升了 2.1%。与上述模型相比，本文算法依然具有良好的检测能力。

图 8 显示了本文算法在 VisDrone2019-DET 数据集的实际应用场景可视化。从可视化图可以看出，本文算法能够高度准确地检测微小尺度目标，尤其是密集行人特征识别。本文使用 TP、FP 和 FN 作为指标，其中，绿色框（TP）表示正确的检测和真实的标签；红色框（FN）为漏检，未检测到；蓝色框（FP）表示错误检测。在实际场景可视化中，绿色边界框偏多，尤其是在识别远距离目标特征和密集目标特征时，绿色边界框的数量多于蓝色边界框和红色边界框。

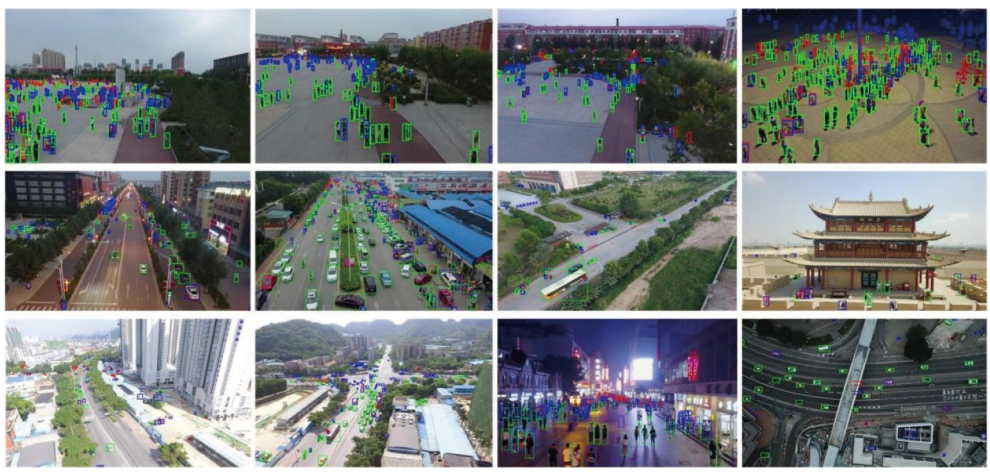


图 8　VisDrone2019-DET 数据集的实际应用场景可视化

Fig. 8　Visualisation of real-world application scenarios for the VisDrone2019-DET dataset

在某市实际无人机航拍图像数据集中测试了本文算法，以评估在实际场景中的泛化能力，并与 YOLOv3、YOLOv5、YOLOv6、YOLOv8、YOLOv8-Decoder 和 RT-DETR 进行对比，实验结果如表 5 和图 9 所示。本文算法的 R、P、mAP0.5、mAP0.5∶0.95 分别是 79.7%、86.0%、82.9% 和 60.2%，而 YOLOV3 的 R、P、mAP0.5、mAP0.5∶0.95 分别是 41.4%、82.6%、52.1%、30.9%，相较于 YOLOv3，本文算法的 R、P 分别提升了 38.3% 和 3.4%，mAP0.5 和 mAP0.5∶0.95 分别提升了 30.8% 和 29.3%；而 YOLOv5 的 R、P、mAP0.5、mAP0.5∶0.95 分别是 48.5%、88.1%、56.7%、38.6%，相较于 YOLOv5，本文算法的 R 提升了 31.2%，mAP0.5 和 mAP0.5∶0.95 分别提高了 26.2% 和 21.6%；YOLOv6 的 R、P、mAP0.5、mAP0.5∶0.95 分别是 40.4%、72.0%、45.2%、31.7%，相较于 YOLOv6 模型，本文算法的 R 和 P 分别提升了 39.3% 和 14%，mAP0.5 和 mAP0.5∶0.95 分别提升了 37.3% 和 28.5%。YOLOv8 的 R、P、mAP0.5、mAP0.5∶0.95

分别是47.4%、61.3%、52.1%、36.7%,相较于YOLOv8模型,本文算法的R和P分别提升了32.3%和24.7%,mAP0.5和mAP0.5∶0.95分别提升了30.8%和23.5%;YOLOv8-Decoder的R、P、mAP0.5、mAP0.5∶0.95分别是49.5%、76.7%、55.1%和37.2%,相较于YOLOv8-Decoder模型,本文算法的R和P分别提升了30.2%和9.3%,mAP0.5和mAP0.5∶0.95分别提升了27.8%和23.0%。RT-DETR的R、P、mAP0.5、mAP0.5∶0.95分别是64.9%、87.9%、76.1%和51.7%,相较于RT-DETR模型,本文算法的R提升了14.8%,mAP0.5和mAP0.5∶0.95分别提升了6.8%和8.5%。在表5中,与YOLO系列相比,多核上下文特征引导下的无人机航拍图像可信检测算法实现了比其他框架更高的mAP。综上所述,本文算法通过利用多核上下文特征引导模块和全局注意力模块,有效地捕捉全局和局部的上下文信息,使模型在处理复杂场景时可以有效实现局部细节与全局结构的特征信息融合。相比之下,YOLO系列模型主要依赖于标准的卷积神经网络结构,局限于局部区域特征,无法有效捕捉长距离依赖和全局特征信息。因此,本文算法能够更好地处理背景复杂、目标分布不均匀的无人机航拍场景。

表5 各算法在Drone数据集上的总体性能比较

Table 5 Overall performance comparison of different algorithms on the Drone dataset

Baseline	R/%	P/%	mAP0.5/%	mAP0.5∶0.95/%
YOLOv3	41.4	82.6	52.1	30.9
YOLOv5	48.5	88.1	56.7	38.6
YOLOv6	40.4	72.0	45.2	31.7
YOLOv8	47.4	61.3	52.1	36.7
YOLOv8-Decoder	49.5	76.7	55.1	37.2
RT-DETR	64.9	87.9	76.1	51.7
本文算法	79.7	86.0	82.9	60.2



图9 Drone数据集检测结果可视化

Fig. 9 Visualisation of Drone dataset detection results

图9显示了本文算法在Drone数据集的实际应用场景可视化。从可视化图可以看出,本文算法可以有效识别微小尺度目标,尤其是远距离目标特征。本文使用TP、FP和FN作为指标,其中,绿色框(TP)表示正确的检测和真实的标签;红色框(FN)为漏检,未检测到;蓝色框(FP)表示错误检测。在实际场景可视化中,近距离目标的绿色边界框偏多,尤其是在识别远距离目标特征时,绿色边界框的数量也多于蓝色边界框。

3 结 论

针对无人机航拍图像存在的背景信息复杂、目标尺度分布不均等问题,本文提出用于无人机小目标检测的多核上下文特征可信检测算法。首先,该算法在ResNet18主干网络部分设计多核上下文特征交互模块,通过全局上下文注意力和多尺度卷积核对全局上下文关键特征进行筛选和提取,从而缓解背景噪声问题。其次,构建可学习位置编码器,通过动态位置编码自适应调整目标空间位置信息,弥补目标丢失特征。最后,为有效识别关注区域内的目标特征,构建多尺度细节融合模块,利用全局上下文引导模块和深度卷积核捕获局部区域的目标全局-局部特征,以有效融合不同尺度的目标特征。

此外,为验证本文算法的鲁棒性,增加极端天气干扰因素,证明了本文算法的鲁棒性更优。实验结果表明,本文算法在不同场景中均表现出良好的检测性能。本文设计的多核上下文特征网络在探索计算成本和检测精度之间的平衡方面取得了很好的结果,但仍然存在一些限制。因此,期待着在

目标检测方面进一步改进本文算法。

参考文献（References）

[1] 姚雨, 宋春林, 邵江琦. 无人机航拍军事车辆实时检测及定位算法[J]. 兵工学报, 2024, 45(S1): 354-360.
Yao Y, Song C L, Shao J Q. Real-time detection and localization algorithm for military vehicles in drone aerial photography[J]. Acta Armamentarii, 2024, 45(S1): 354-360(in Chinese).

[2] 张河山, 谭鑫, 范梦伟, 等. 无人机高空航拍视角下小尺度车辆精确检测方法[J]. 交通运输系统工程与信息, 2024, 24(3): 299-309.
Zhang H S, Tan X, Fan M W, et al. Accurate detection method of small-scale vehicles from perspective of unmanned aerial vehicle high-altitude aerial photography[J]. Journal of Transportation Systems Engineering and Information Technology, 2024, 24(3): 299-309 (in Chinese).

[3] 张嘉辉, 赵威, 王子琛, 等. 基于检测和重识别的无人机行人跟踪算法[J]. 北京航空航天大学学报, 2024, 50(8): 2538-2546.
Zhang J H, Zhao W, Wang Z C, et al. UAV pedestrian tracking algorithm based on detection and re-identification[J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50(8): 2538-2546(in Chinese).

[4] 冒国韬, 邓天民, 于楠晶. 基于多尺度分割注意力的无人机航拍图像目标检测算法[J]. 航空学报, 2023, 44(5): 268-278.
Mao G T, Deng T M, Yu N J. Object detection in UAV images based on multi-scale split attention[J]. Acta Aeronautica et Astronautica Sinica, 2023, 44(5): 268-278(in Chinese).

[5] 王殿伟, 胡里晨, 房杰, 等. 基于改进 Double-Head RCNN 的无人机航拍图像小目标检测算法[J]. 北京航空航天大学学报, 2024, 50(7): 2141-2149.
Wang D W, Hu L C, Fang J, et al. Small target detection algorithm based on improved Double-Head RCNN for UAV aerial images[J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50(7): 2141-2149(in Chinese).

[6] 李超, 黄新宇, 王凯. 基于特征融合和自学习锚框的高分辨率图像小目标检测算法[J]. 电子学报, 2022, 50(7): 1684-1695.
Li C, Huang X Y, Wang K. Small object detection of high-resolution images based on feature fusion and learnable anchor[J]. Acta Electronica Sinica, 2022, 50(7): 1684-1695(in Chinese).

[7] 刘芳, 韩笑. 基于多尺度深度学习的自适应航拍目标检测[J]. 航空学报, 2022, 43(5): 463-474.
Liu F, Han X. Adaptive aerial object detection based on multi-scale deep learning[J]. Acta Aeronautica et Astronautica Sinica, 2022, 43(5): 463-474(in Chinese).

[8] 张娜, 戚旭磊, 包晓安, 等. 基于优化预测定位的单阶段目标检测算法[J]. 浙江大学学报 (工学版), 2022, 56(4): 783-794.
Zhang N, Qi X L, Bao X A, et al. Single-stage object detection algorithm based on optimizing position prediction[J]. Journal of Zhejiang University (Engineering Science), 2022, 56(4): 783-794(in Chinese).

[9] 曹磊, 王强, 史润佳, 等. 基于改进 RPN 的 Faster-RCNN 网络 SAR 图像车辆目标检测方法[J]. 东南大学学报 (自然科学版), 2021, 51(1): 87-91.
Cao L, Wang Q, Shi R J, et al. Method for vehicle target detection on SAR image based on improved RPN in Faster-RCNN[J]. Journal of Southeast University (Natural Science Edition), 2021, 51(1): 87-91(in Chinese).

[10] Girshick R, Donahue J, Darrell T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]// Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2014: 580-587.

[11] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[C]//Proceedings of the Advances in Neural Information Processing Systems. Red Hook: Curran Associates, 2015, 28: 91-99.

[12] He K M, Gkioxari G, Dollar P, et al. Mask R-CNN[C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway: IEEE, 2017: 2961-2969.

[13] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]// Preceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 779-788.

[14] Redmon J, Farhadi A. YOLO9000: better, faster, stronger[C]// Preceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2017: 6517-6525.

[15] Redmon J, Farhadi A. YOLOv3: an incremental improvement [EB/OL]. (2018-04-08)[2024-07-18]. https://arxiv.org/abs/1804.02767.

[16] Liu W, Anguelov D, Erhan D, et al. SSD: single shot MultiBox detector[M]// Computer Vision-ECCV 2016. Cham: Springer International Publishing, 2016: 21-37.

[17] Tan M X, Pang R M, Le Q V. EfficientDet: scalable and efficient object detection[C]// Preceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 10778-10787.

[18] Zhang S F, Wen L Y, Bian X, et al. Single-shot refinement neural network for object detection[C]// Preceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 4203-4212.

[19] Wang X R, Li W H, Guo W, et al. SPB-YOLO: an efficient real-time detector for unmanned aerial vehicle images[C]// Preceedings of the 2021 International Conference on Artificial Intelligence in Information and Communication. Piscataway: IEEE Press, 2021: 99-104.

[20] 薛珊, 卢涛, 吕琼莹, 等. 基于多尺度融合和轻量化网络的无人机目标检测算法[J]. 湖南大学学报 (自然科学版), 2023, 50(8): 82-93.
Xue S, Lu T, Lyu Q Y, et al. Drone target detection algorithm based on multi-scale fusion and lightweight network[J]. Journal of Hunan University (Natural Sciences), 2023, 50(8): 82-93(in Chinese).

[21] Liu M J, Wang X H, Zhou A J, et al. UAV-YOLO: small object detection on unmanned aerial vehicle perspective[J]. Sensors, 2020, 20(8): 2238.

[22] 刘婷婷, 苗华, 李琳, 等. 融合场景上下文的轻量级目标检测网络[J]. 激光与光电子学进展, 2021, 58(20): 2010005.
Liu T T, Miao H, Li L, et al. Lightweight target detection network integrating scene context[J]. Laser & Optoelectronics Progress, 2021, 58(20): 2010005(in Chinese).

[23] 韩俊, 袁小平, 王准, 等. 基于 YOLOv5s 的无人机密集小目标检测算法[J]. 浙江大学学报 (工学版), 2023, 57(6): 1224-1233.
Han J, Yuan X P, Wang Z, et al. UAV dense small target detection

algorithm based on YOLOv5s[J]. Journal of Zhejiang University (Engineering Science), 2023, 57(6): 1224-1233(in Chinese).

[24] Yu F, Koltun V, Funkhouser T. Dilated residual networks[C]// Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2017: 636-644.

[25] Aswani A, Shazeer N, Parmar N, et al. Attention is all you need[EB/OL]. (2023-08-02)[2024-07-18]. https://arxiv.org/abs/1706.03762.

[26] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions[EB/OL]. (2016-04-30)[2024-07-18]. https://arxiv.org/abs/1511.07122.

[27] Dai J F, Qi H Z, Xiong Y W, et al. Deformable convolutional networks[C]// Proceedings of the 2017 IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2017: 764-773.

[28] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]// Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 7132-7141.

[29] Li Y X, Hou Q B, Zheng Z H, et al. Large selective kernel network for remote sensing object detection[C]// Proceedings of the 2023 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2024: 16748-16759.

[30] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16x16 words: Transformers for image recognition at scale[EB/OL]. (2021-06-03)[2024-07-18]. https://arxiv.org/abs/2010.11929.

[31] Peng Z L, Huang W, Gu S Z, et al. Conformer: local features coupling global representations for visual recognition[C]// Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2022: 357-366.

[32] 吴一全, 童康. 基于深度学习的无人机航拍图像小目标检测研究进展[J]. 航空学报, 2025, 46(3): 174-200.
Wu Y Q, Tong K. Research advances on deep learning-based small object detection in UAV aerial images[J]. Acta Aeronautica et Astronautica Sinica, 2025, 46(3): 174-200(in Chinese).

[33] 陈金林, 吴一全, 苑玉彬. 无人机视角下目标检测的YOLO系列算法研究进展[J]. 北京航空航天大学学报, 2026, 52(10): 3509-3534.
Chen J L, Wu Y Q, Yuan Y B. Research progress of YOLO series algorithms for target detection under UAV viewpoint[J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(10): 3509-3534(in Chinese).

Multi-core contextual feature-guided algorithm for trusted detection of UAV aerial images

ZHANG Zhihao，DU Lixia*，HAO Ziwei，HOU Yue

(School of Electronic and Information Engineering，Lanzhou Jiaotong University，Lanzhou 730000，China)

Abstract：A multi-core contextual feature trusted detection network (MCCF) is developed for unmanned aerial vehicle (UAV) tiny target detection in order to address the issue of low detection accuracy caused by uneven target scale distribution in UAV aerial photos under complicated background. Firstly, a multicore contextual feature guidance module is designed in the backbone network part, which utilises multi-scale convolutional kernel and global contextual attention in order to achieve the fusion of feature information of local details and global structure, so as to effectively suppress the background noise. Secondly, in order to minimize the loss of spatial position information of small targets during the sampling process, a learnable position encoder is suggested that dynamically modifies the position representation of target characteristics. Finally, in order to effectively identify tiny targets in complex regions, this paper proposes a multi-scale detail fusion module, which fuses local spatial position information and global structural semantic information in order to effectively capture fine-grained features of targets at different scales. Finally, the experimental results on the VisDrone2019-DET dataset and the Drone dataset show that the mAP0.5 of the MCCF model is improved by 2.1% and 6.8%, respectively, compared to the RT-DETR model, which effectively improves the problems of target leakage and misdetection in UAV aerial images.

Keywords：unmanned aerial vehicle small target detection; global contextual attention; multi core contextual features; encoder; feature fusion

Received：2024-07-18；**Accepted**：2024-09-30；**Published Online**：2024-11-01 13：31

URL：link.cnki.net/urlid/11.2625.V.20241101.1122.001

Foundation items：National Natural Science Foundation of China (62063014,62363020); Natural Science Foundation of Gansu Province (22JR5RA365)

* **Corresponding author**. E-mail：dlx1228@mail.lzjtu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0627

基于BN的民机驾驶舱显示界面可用性综合评价模型

肖瑶[1]，陈登凯[1,*]，周垚[1]，肖江浩[1]，侯玉宏[1,2]

(1. 西北工业大学 工业设计与人机工效工信部重点实验室，西安 710072；2. 中国飞行试验研究院，西安 710089)

摘　　要：研究民机驾驶舱显示界面可用性有助于优化设计界面，针对民机驾驶舱显示界面可用性评价的不确定性，提出一种基于贝叶斯网络(BN)的可用性综合评价模型。基于执行过程交互控制(EPIC)模型获取的可用性评价指标体系建立贝叶斯网络，定量根节点以专家眼动度量指标的加权评价为先验概率，定性根节点采用专家三角模糊数评价为先验概率；为降低专家的决策次数，使用Noisy-OR模型填充贝叶斯网络的条件概率表，并利用GeNIe软件搭建模型。以主飞行显示器界面进行实例验证，结果表明：模型因果推理结果与系统可用性量表(SUS)评价结果一致，该界面的评价等级均为“良”，验证所提模型的有效性，并对模型敏感性分析得到的敏感因子提出改进措施。

关 键 词：民机驾驶舱；显示界面；可用性评价；贝叶斯网络；眼动

中图分类号：V241.0

文献标志码：A　　**文章编号**：1001-5965(2026)11-4063-12

民机驾驶舱显示界面是飞行员与飞机之间的人机交互接口与核心枢纽，旨在向飞行员提供飞机的位置、速度、高度及燃油状态等基本飞行信息和各系统的状态信息。影响航空飞行事故关键致因归结为4类，即人为因素、环境因素、机械故障因素和管理因素[1]。国际民航组织(International Civil Aviation Organization, ICAO)发布的事故报告显示，人为因素造成的飞行事故占总事故数的70%，人为差错是危及世界航空安全的主要因素[2]。因此，对民机驾驶舱显示界面的可用性评价展开研究，让设计师更好地了解显示界面与飞行员认知需求的匹配度，为后续的迭代优化提供改进建议和指导有重要意义。

软件质量模型(ISO/ICE 9126)[3]规定“可用性是在特定使用环境下，用户达成预期目标的满意程度和效率”。针对民机驾驶舱显示界面的可用性研究中，Xue等[4]构建了由出错、可学习性和满意度等9项指标组成的可用性评价模型，采用多元回归法得到各指标的权重系数，对各指标的可用性评分值进行加权后得到显示界面的可用性结果。张惠琳[5]从用户行为、用户认知和设计样式维度提炼民机驾驶舱显示界面的可用性评价指标模型，利用层次分析法(analytic hierarchy process, AHP)确定不同指标的权重系数后，对所有指标的可用性评分值进行加权，以获取显示界面的可用性结果。现有民机驾驶舱显示界面的研究忽略了飞行员与显示界面交互过程的整体考量，而且可用性评价模型没有对定量指标和定性指标进行分类和差异化评价。此外，显示界面可用性评价方法可分为主、客观评价和综合评价。主观评价是通过模型、可用性原则、实际问题来构建显示界面可用性评价体系，并利用可用性量表来分析界面可用性，常用的可用性量表有系统可用性量表(system usability scale, SUS)[6]、后测系统可用性问卷(post-study system usability, PSSUQ)[7]、NASA-TLX量表[8]等。客观评价是通过脑电信号、皮肤信号、绩效数据和眼动数据等进行分析，其中，

收稿日期：2024-08-28；**录用日期**：2024-09-23；**网络出版时间**：2024-10-16 14:38
网络出版地址：link.cnki.net/urlid/11.2625.V.20241016.1259.005
基金项目：陕西省重点研发计划(2022GY-311)
*通信作者. E-mail：chendengkai@nwpu.edu.cn

引用格式：肖瑶，陈登凯，周垚，等. 基于BN的民机驾驶舱显示界面可用性综合评价模型[J]. 北京航空航天大学学报，2026，52(11)：4063-4074. Xiao Y，Chen D K，Zhou Y，et al. BN-based comprehensive evaluation model for display interface usability in civil aircraft cockpit[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：4063-4074 (in Chinese).

眼动数据可有效反映用户与图形界面交互背后的深层机制，常用于检验界面设计的可用性，如李亚鸿等[9]通过眼动追踪可用性实验对比数字孪生系统优化前后设计界面实例，验证了基于质量屋优化设计方法的可行性。综合评价整合了主观评价与客观评价，如Chui等[10]结合心率、眼动实验和NASA-TLX量表来分析老年人医疗保健系统界面的可用性。近年来，还有学者采用各种理论方法对可用性评价展开研究，如江涛等[11]运用模糊层次分析法构建工业缝纫机可用性评价模型。在现阶段的可用性评价研究中，尚未有将显示界面可用性的综合评价方法与贝叶斯网络（Bayesian network, BN）相结合的尝试。因为，贝叶斯网络依托于概率论原理，即使缺乏相关历史数据支持，也能有效地推断出民机驾驶舱显示界面的可用性评价结果。贝叶斯网络是一种概率图模型，节点表示变量，有向边表示链接节点之间的依赖关系，条件概率可直接量化该依赖关系[12]。贝叶斯网络由一个有向无环图（directed acyclic graph, DAG）和若干条件概率表（conditional probability table, CPT）组成，DAG的结构和CPT的内容共同构成了贝叶斯网络的模型。CPT包含每个节点在给定其父节点状态的条件下，该节点各个状态的概率分布。贝叶斯网络的先验概率是在无领域知识或历史数据情况下确定的，后验概率是在获取新信息后对先验概率进行修正的结果。

针对民机驾驶舱显示界面可用性评价的复杂性和多维性，利用贝叶斯网络在不确定系统中的概率推理能力，是弥补现有可用性评价研究不足的关键途径。因此，本文提出一种基于贝叶斯网络的民机驾驶舱显示界面可用性综合评价模型，还借助GeNIe软件完成评价模型的搭建，最后以实例分析验证了该模型的有效性，并针对实例的敏感因子提出改进措施。

1 民机驾驶舱显示界面可用性评价指标体系

执行过程交互控制（executive process-interactive control, EPIC）模型是人机交互领域经典的认知心理学模型，用于研究人机界面的可用性及用户的认知过程[13]。EPIC模型示意如图1所示，基于EPIC模型对用户与界面的交互过程分析，本文提出从飞行任务、飞行员感官、飞行员认知和飞行交互4个维度对民机驾驶舱显示界面可用性进行综合评价。

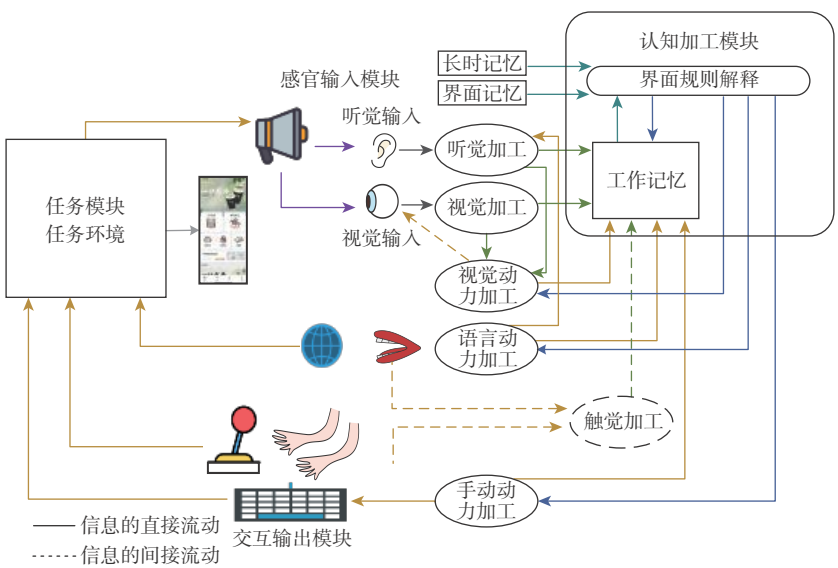


图1 EPIC认知加工模型

Fig. 1 EPIC cognitive processing model

整合国内外相关文献、行业标准与规范，完成民机驾驶舱显示界面可用性评价指标的选取工作。通过CNKI数据、Web of Science平台、万方数据等平台，以“民机驾驶舱”“显示界面”“指标体系”“可用性”等中英文关键词进行检索，获取4个维度的可用性评价初选指标，并结合Nielsen模型[14]和ISO/ICE 9126[3]对可用性评价指标进行补充和修正，最终梳理出44个民机驾驶舱显示界面可用性评价初选指标，如表1所示的指标层和删除指标。

邀请某飞行研究院的5位飞行专家，通过德尔菲法完成指标筛选工作。经过筛选后，保留了16个可用性评价指标，如表1所示的指标层。本文还运用层次结构模型，构建民机驾驶舱显示界面可

用性评价指标体系。表 1 列出了指标体系的目标层、维度层、指标层、指标语义、指标类型、删除指标和指标来源。在指标类型中, 定量指标可采用实验方法收集和处理数据资料做出定量结果的价值判断, 定性指标可根据专家的知识、经验直接做出定性结论的价值判断[15]。

表 1　民机驾驶舱显示界面可用性评价指标体系

Table 1　Usability indicator system for cockpit display interfaces of civil aircraft

目标层	维度层	指标层	指标编号	指标语义	指标类型	删除指标	指标来源
民机驾驶舱显示界面可用性 C^*	飞行任务 C_1	任务导向性	c_{11}	界面是否引导飞行员进行操作	定量	时间压力、任务适应性、任务优先级、任务匹配、任务完成时间、任务熟悉度、任务导航性、任务流畅度	文献[14]
		信息吸引力	c_{12}	界面信息是否吸引飞行员执行任务			
		信息复杂度	c_{13}	界面信息是否降低飞行任务复杂度			
		任务完成效率	c_{14}	界面是否能提高飞行员的任务完成度			
	飞行员感官 C_2	一致性	c_{21}	界面色彩、图标等方面是否有一致性	定性	层次性、均衡性、语音清晰度、音频可调性、音频优化、语音告警提示、语音确认操作	文献[14]
		简洁性	c_{22}	界面是否不包括重叠、冗余信息			
		信息呈现	c_{23}	界面呈现方式是否科学合理			
		信息易读性	c_{24}	界面信息是否易于飞行员阅读和查阅			
	飞行员认知 C_3	理解	c_{31}	界面是否能让飞行员快速地理解	定性	学习时长、熟悉、学习效率、回忆、注意力、可学习性	文献[3,16-17]
		易学性	c_{32}	界面是否降低飞行员学习使用的难度			
		满意度	c_{33}	界面是否能提高飞行员的视觉满意度			
		最小记忆负荷	c_{34}	界面是否尽量减少飞行员的记忆负荷			
	飞行交互 C_4	信息实时性	c_{41}	界面信息是否实现实时更新	定性	可预测性、交互规范性、交互及时响应、防撞预警、告警提示、信息容错、更改设置	文献[18-19]
		信息精确性	c_{42}	界面信息是否精确无误			
		错误预防	c_{43}	界面是否提供错误预防与恢复机制			
		交互反馈	c_{44}	界面是否提供明确的交互信息反馈			

2　民机驾驶舱显示界面可用性综合评价模型构建

基于贝叶斯网络的民机驾驶舱显示界面可用性综合评价模型框架如图 2 所示, 步骤如下:

步骤 1　根据民机驾驶舱显示界面可用性评价指标体系建立贝叶斯网络模型。

步骤 2　贝叶斯网络定量根节点的先验概率由眼动追踪的加权客观评价获取, 定性根节点的先验概率由三角模糊主观评价获取。

步骤 3　为完善贝叶斯网络模型搭建, 利用 Noisy-OR 模型填充贝叶斯网络节点的模糊条件概率表后, 计算获取非根节点的条件概率。

步骤 4　利用贝叶斯网络进行因果推理、诊断

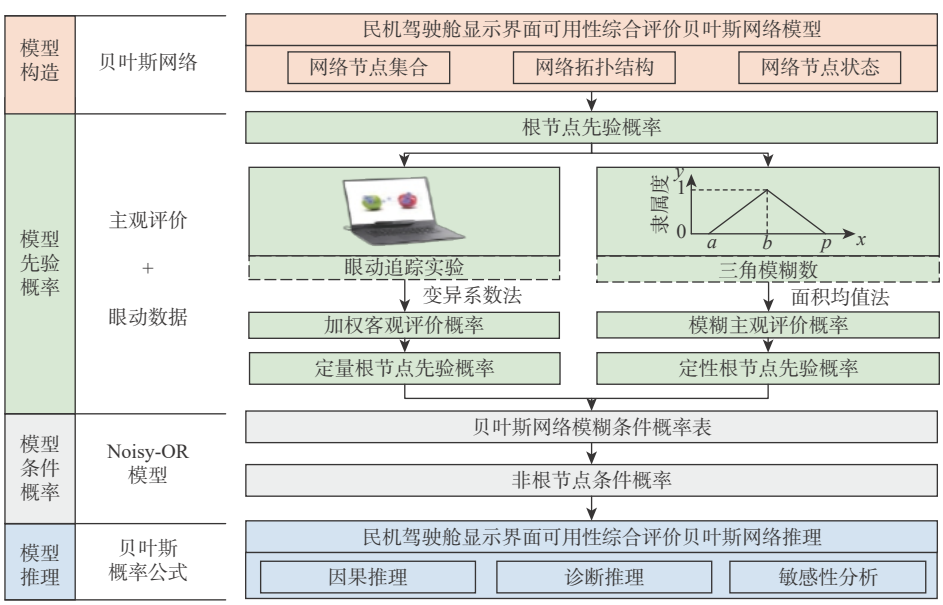


图 2　基于贝叶斯网络的民机驾驶舱显示界面可用性综合评价模型

Fig. 2　Comprehensive evaluation model for cockpit display interfaces of civil aircraft based on Bayesian network

推理和敏感性分析。

2.1 贝叶斯网络构造

根据民机驾驶舱显示界面可用性评价指标体系确定贝叶斯网络节点，节点$E=\{E_1,E_2,E_3\}$主要分为3种：①E_1为根节点，是贝叶斯网络的基本单元和底层节点，对应体系中指标层的民机驾驶舱显示界面可用性评价指标，根节点变量为$c_{im}(i=1,2,3,4;m\in N^*)$；②$E_2$为中间节点，起到连接贝叶斯网络的根节点与目标节点作用，对应维度层的4个维度，中间节点变量为$C_i(i=1,2,3,4)$；③E_3为叶节点，表示民机驾驶舱显示界面可用性评价等级，对应体系的目标层，叶节点变量为C^*。在网络节点确定的基础上，由根节点E_1指向中间节点E_2、中间节点E_2指向叶节点E_3，搭建如图3所示的民机驾驶舱显示界面可用性评价贝叶斯网络模型。假设根节点E_1及中间节点E_2由“STATE=0”和“STATE=1”2个状态组成，用$j\in\{0,\ 1\}$来表示，“STATE=0”表示对民机驾驶舱显示界面可用性的负面影响，“STATE=1”表示对民机驾驶舱显示界面可用性的积极影响，并将叶节点E_3的节点状态定义为$G_\beta=\{G_1,G_2,G_3,G_4\}=$ {优,良,中,差}。

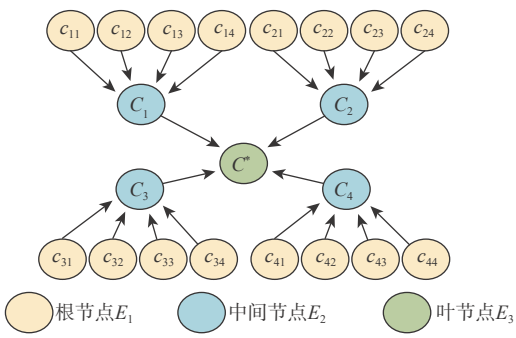


图3 民机驾驶舱显示界面可用性评价贝叶斯网络模型

Fig. 3 Bayesian network modelling for usability evaluation in cockpit display interfaces of civil aircraft

2.2 根节点先验概率获取

2.2.1 定量根节点先验概率

由飞行任务C_1中间节点对应的根节点组成定量根节点集$K=\{c_{11},c_{12},c_{13},c_{14}\}$，其中，定量根节点$c_{im}(i=1)$同样具有“STATE=0”和“STATE=1”2种状态，用$j\in\{0,\ 1\}$来表示。

眼动追踪技术通过记录被试的眼球运动轨迹注视行为，获取有关视觉注意、搜索行为等方面的数据，判断显示界面的信息复杂性、吸引性、引导性和搜索效率。设全部眼动度量指标集$Y=\{Y_1,Y_2,\cdots,Y_e\cdots,Y_{10}\}$，$e=1,2,\cdots,10$，定量根节点的度量指标分析如表2所示。

在此基础上，根据眼动度量指标的实验数据计算各根节点的先验概率，具体步骤如下：

表2 定量根节点的度量指标分析

Table 2 Metrics analysis of quantitative root nodes

定量根节点	度量指标Y	正负性
任务导向性c_{11}	眼跳次数Y_1	负相关
	扫描路径时间Y_2	负相关
	扫描路径长度Y_3	负相关
信息吸引力c_{12}	AOI注视总持续时间Y_4	正相关
	AOI内注视次数Y_5	正相关
	AOI首次注视持续时间Y_6	正相关
信息复杂度c_{13}	注视点数量Y_7	负相关
	回视次数Y_8	负相关
任务完成效率c_{14}	任务准确率Y_9	正相关
	任务完成时间Y_{10}	负相关

注：兴趣区域(area of interest, AOI)。

步骤1 设参与实验的专家总数为s，收集定量根节点$c_{im}(i=1;m\in N^*)$处于状态j下s名专家的所有度量指标集Y的实验初始数据，构建眼动初始数据矩阵：

$$\boldsymbol{Y}=\begin{bmatrix} Y_{11} & Y_{12} & \cdots & Y_{1e} & \cdots & Y_{1s} \\ Y_{21} & Y_{22} & \cdots & Y_{2e} & \cdots & Y_{2s} \\ \vdots & \vdots & & \vdots & & \vdots \\ Y_{t1} & Y_{t2} & \cdots & Y_{te} & \cdots & Y_{es} \\ \vdots & \vdots & & \vdots & & \vdots \\ Y_{s1} & Y_{s2} & \cdots & Y_{se} & \cdots & Y_{s10} \end{bmatrix} \tag{1}$$

式中：$Y_{te}(e=1,2,\cdots,10;\ t=1,2,\cdots,s)$为第$t$名专家的第$e$个度量指标的原始数据。

针对正相关的度量指标原始数据，标准化公式：

$$r_{te}=\frac{Y_{te}-\min(Y_e)}{\max(Y_e)-\min(Y_e)} \tag{2}$$

针对负相关的度量指标原始数据，标准化公式：

$$r_{te}=\frac{\max(Y_e)-Y_{te}}{\max(Y_e)-\min(Y_e)} \tag{3}$$

式中：$\max(Y_e)$、$\min(Y_e)$分别为同一度量指标下s名专家原始数据的最大值、最小值；r_{te}为第t名专家的第e个度量指标原始数据归一化后的标准值。

步骤2 变异系数法是一种定量赋权法，其核心思想在于通过计算数据的标准差与平均值之比得出相对变异的度量，从而提供一种相对于平均值的标准化评估。若某个定量根节点$c_{im}(i=1;m\in N^*)$中度量指标数为ρ，利用变异系数法求某一定量根节点$c_{im}(i=1;m\in N^*)$所含度量指标权重的步骤如下：

$$\bar{r}_\rho=\sum_{t=1}^{s}r_{t\rho}/s \tag{4}$$

$$\sigma_\rho=\sqrt{\frac{\sum_{t=1}^{s}(r_{t\rho}-\bar{r}_\rho)^2}{s-1}} \tag{5}$$

$$\varphi_\rho=\bar{r}_\rho/\sigma_\rho \tag{6}$$

$$\delta_\rho = \varphi_\rho / \sum \varphi_\rho \tag{7}$$

式中: $\bar{r}_\rho$为某个定量根节点$c_{im}(i=1)$包含的第ρ个度量指标的平均值; σ_ρ为某一定量根节点$c_{im}(i=1)$包含的第ρ个度量指标的标准差; φ_ρ为第ρ个度量指标的变异系数; δ_ρ为第ρ个度量指标的权重, $0 \leqslant \delta_\rho \leqslant 1$, 且$\sum \delta_\rho = 1$。

步骤 3　已知某个定量根节点$c_{im}(i=1)$所含度量指标权重, 其加权评价概率:

$$P(c_{1mj}) = \sum \bar{r}_\rho \delta_\rho \tag{8}$$

此时, $P(c_{1mj})$为贝叶斯网络定量根节点$c_{im}(i=1)$处于状态j的先验概率。

2.2.2　定性根节点先验概率

飞行员感官C_2、飞行认知C_3和飞行交互C_4维度的根节点组成定性根节点集$X=\{c_{21},c_{22},\cdots,c_{im},\cdots,c_{43},c_{44}\}(i=2,3,4;m\in N^*)$, 其中, 定性根节点$c_{im}(i=2,3,4;m\in N^*)$有 2 种状态“STATE=0”和“STATE=1”, 用$j\in\{0,\ 1\}$表示。

三角模糊数是模糊集理论中将模糊、不确定的语言变量转化为确定数值的方法, 在评价中能解决评价对象无法准确度量、只能用自然语言进行模糊评价的问题。因此, 本文引入三角模糊数, 结合专家定性意见获取定性根节点的模糊发生概率。三角模糊数$\tilde{P}(x)=(a,b,q)$的隶属度函数表达式为

$$\tilde{P}(x)=\begin{cases}0 & x<a\\ (x-a)/(b-a) & a\leqslant x<b\\ 1 & x=b\\ (q-x)/(q-b) & b<x\leqslant q\\ 0 & x\geqslant q\end{cases} \tag{9}$$

基于专家评价与三角模糊数, 计算定性根节点的先验概率, 具体步骤如下:

步骤 1　在无法准确获取根节点发生概率的情况下, 为减少专家在定性节点状态评估时的定性差异, 可使用模糊语言变量来量化专家经验的判断结果。假设定性根节点事件发生概率的专家模糊评价集$Q(c_{im})=\{$非常低 (VL), 低 (L), 较低 (FL), 中等 (M), 较高 (FH), 高 (H), 非常高 (H)$\}(i=2,3,4;\ m\in N^*)$, 与三角模糊数$\tilde{P}(x)=(a,b,q)$的对应关系如表 3 所示。

步骤 2　采用问卷方式获取多名专家对定性根节点集X发生概率的三角模糊评价, 弥补了无法利用数据资源获得定性根节点概率的不足。已知专家总数为s, 第$t(t\in s)$名专家给出的定性根节点$c_{im}(i=2,3,4;m\in N^*)$处于状态j概率的模糊语言变量$Q_j^t(c_{im})$可根据表 3 中语言变量与三角模糊数的对应关系转换为三角模糊概率表达式:

表 3　7 个语言变量与三角模糊数的对应关系

Table 3　Corresponding relationship between 7 linguistic variables and triangular fuzzy numbers

序号	语言变量	$\tilde{P}(x)=(a,b,q)$
1	非常低(VL)	(0,0,0.1)
2	低(L)	(0,0.1,0.3)
3	较低(FL)	(0.1,0.3,0.5)
4	中等(M)	(0.3,0.5,0.7)
5	较高(FH)	(0.5,0.7,0.9)
6	高(H)	(0.7,0.9,1.0)
7	非常高(VH)	(0.9,1.0,1.0)

$$\tilde{P}_{imj}^t=(a_{imj}^t,b_{imj}^t,q_{imj}^t)\qquad t=1,2,\cdots,s \tag{10}$$

步骤 3　考虑到不同专家的经验知识对定性根节点评价的准确性, 需要对影响专家意见的教育经历和相关专业等因素进行权重判断。本文在综合s名专家意见时, 参考文献 [20] 按照不同的年龄、学历、职称和工作年限对专家意见进行加权, 专家权重如表 4 所示。

表 4　专家权重

Table 4　Weight of experts

项目	类别	权重	项目	类别	权重
年龄	⩾50岁	$w_1=1.0$	职称	机长	$w_3=1.0$
	40～50岁	$w_1=0.9$		副机长	$w_3=0.9$
	30`40岁	$w_1=0.8$		飞行学员	$w_3=0.8$
	⩽30岁	$w_1=0.7$		研究人员	$w_3=0.7$
学历	博士	$w_2=1.0$	工作年限	⩾20年	$w_4=1.0$
	硕士	$w_2=0.9$		10～20年	$w_4=0.9$
	学士	$w_2=0.8$		5～10年	$w_4=0.8$
	专科	$w_2=0.7$		⩽5年	$w_4=0.7$

此时, 定性根节点$c_{im}(i=2,3,4;m\in N^*)$处于状态j下s名专家的综合评价三角模糊概率计算式:

$$\tilde{P}_{imj}=(a_{imj},b_{imj},q_{imj})=\frac{\sum_{t=1}^{s} w_{1t}w_{2t}w_{3t}w_{4t}\tilde{P}_{imj}^t}{\sum_{t=1}^{s} w_{1t}w_{2t}w_{3t}w_{4t}}\qquad t=1,2,\cdots,s \tag{11}$$

式中: w_{1t}为第t名专家的年龄权重; w_{2t}为第t名专家的学历权重; w_{3t}为第t名专家的职称权重; w_{4t}为第t名专家的工作年限权重; $\tilde{P}_{imj}^t$为第t名专家对定性根节点c_{im}处于状态j下发生概率的模糊语言所转化的三角模糊概率。

步骤 4　由于三角模糊概率不利于贝叶斯网络的推理计算, 应将综合专家评价三角模糊概率进行解模糊处理。本文采取面积均值法将综合专家评价三角模糊概率转化为精确概率, 定性根节点$c_{im}(i=2,3,4;m\in N^*)$处于状态j的精确概率:

$$P_{imj}=(a_{imj}+2b_{imj}+q_{imj})/4 \tag{12}$$

经过去模糊处理后，为满足同一定性根节点在各状态下的概率之和为1，需对各定性根节点所有状态的精确概率进行归一化处理。经过归一化后，定性根节点$c_{im}(i=2,3,4;m\in N^*)$处于状态j的先验概率：

$$P(c_{imj})=P_{imj}\Big/\sum_{j=0}^{1}P_{imj} \tag{13}$$

2.3 非根节点条件概率获取

已知贝叶斯网络存在节点A、B且A为B的父节点，节点B的条件概率为该节点在父节点A所有状态组合下处于不同状态的概率，即在节点A发生的条件下节点B发生的条件概率：

$$P(B|A)=\frac{P(B)}{P(A)}\qquad P(A>0) \tag{14}$$

非根节点(包括中间节点和叶节点)的条件概率通过三角模糊隶属度函数和7级语言变量获取。贝叶斯网络的条件概率存在指数爆炸问题。对于有n个父节点的子节点，如果每个父节点有2种状态，则需要2^n个条件概率参数，增加了专家的工作负荷，还会累积评价误差。为解决上述问题，本文运用Noisy-OR模型来填充CPT，简化条件概率获取步骤并减少专家决策次数。通过获取专家在单一父节点影响下的条件概率，便可计算多个父节点对同一子节点的综合影响。

假定二元变量Y具有n个父节点X，每个节点X存在0和1(事件不发生为“0”，事件发生为“1”)2种状态，Noisy-OR模型如图4所示。

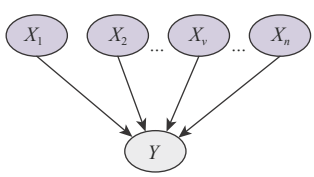


图4 Noisy-OR模型

Fig. 4 Noisy-OR model

根据贝叶斯网络条件概率公式，由事件$X_v(v\in 1,2,\cdots,n)$发生独立引起事件Y发生的概率：

$$P(Y\leftarrow X_v)=P(Y|\overline{X}_1,\ \overline{X}_2,\cdots,X_v,\cdots,\overline{X}_n) \tag{15}$$

式中：X_v表示事件v发生，$\overline{X}_1$、$\overline{X}_2$、$\overline{X}_n$表示事件1、2、n不发生；$P(Y\leftarrow X_v)$表示在仅考虑父节点X_v发生、其余父节点均不发生条件下，子节点Y的发生概率。

令父节点$X_v\in(X_1,X_2,\cdots,X_n)$构成集合$X_a$，在获取$n$个父节点独立影响子节点$Y$的条件概率后，子节点$Y$受$n$个父节点$X$共同影响下的条件概率：

$$P(Y|X_p)=1-P(Y\leftarrow X_p)=1-\prod_{v:\ X_v\in X_p}(1-P(Y\leftarrow X_v)) \tag{16}$$

2.4 贝叶斯网络推理

2.4.1 因果推理

基于贝叶斯网络的条件概率表，可依次求得中间节点与根节点处于不同状态的先验概率。对贝叶斯网络进行正向因果推理，可得到民机驾驶舱显示界面可用性评价等级状况。

在贝叶斯网络中，假设存在节点A、B_1、B_2、$\cdots$、$B_n(B_i\in B_n)$，$P(B_i)>0$，$i=1,2,\cdots,n$，则节点A的全概率公式表示为

$$P(A)=\sum_{i=1}^{n}P(B_i)P(A|B_i) \tag{17}$$

叶节点C^*民机驾驶舱显示界面可用性评价等级为$G_\beta=\{G_1,G_2,G_3,G_4\}=\{$优,良,中,差$\}$，利用贝叶斯网络的全概率公式计算在中间节点$C_i(i=1,2,3,4)$影响下的叶节点$C^*$在$G_\beta(\beta$=1,2,3,4)状态的全概率：

$$P(C^*=G_\beta)=\sum_{i=1}^{4}P(C_i)P(C^*=G_\beta|C_i) \tag{18}$$

将叶节点C^*的全概率$P(C^*=G_\beta)(\alpha$=1,2,3,4)数值进行对比，数值最大的节点状态即为民机驾驶舱显示界面可用性评价等级。本文采用金字塔等级来划分民机驾驶舱显示界面可用性评价等级$G_\beta(\beta=1,2,3,4)$的[0,1]区间，等级区间如表5所示。

表5 民机驾驶舱显示界面可用性评价等级区间

Table 5 Grade scale for cockpit display interface of civil aircraft usability evaluation

目标	评价等级G_β	等级区间
民机驾驶舱显示界面可用性评价等级	G_1=优	[0.95,1.00]
	G_2=良	[0.85,0.95)
	G_3=中	[0.70,0.85)
	G_4=差	[0.00,0.70)

2.4.2 诊断推理

诊断推理是从结果到原因的逆向推理，即叶节点C^*在可用性评价等级为“G_4=差”状态的发生概率为1时，利用贝叶斯网络的结构和概率分布逆向推理根节点不同状态的后验概率，获取可能的致因链、存在大影响力的父节点。

在贝叶斯网络中，若节点A为B的父节点，贝叶斯公式描述了节点A、B先验概率和后验概率的关系，其表达式为

$$P(A|B)=\frac{P(B|A)P(A)}{P(B)} \tag{19}$$

叶节点C^*在可用性评价等级G_4下，根节点

$c_{im}(i=1,2,3,4;m\in N^*)$在状态 $j=1$ 时的后验概率:

$$P\left(c_{im}=c_{im}^{j=1}|C^*=G_4\right)=\frac{P\left(C^*=G_4|c_{im}=c_{im}^{j=1}\right)P\left(c_{im}=c_{im}^{j=1}\right)}{P(C^*=G_4)} \tag{20}$$

此时, 根节点 $c_{im}(i=1,2,3,4;m\in N^*)$在状态 $j=0$ 时的后验概率:

$$P\left(c_{im}=c_{im}^{j=0}|C^*=G_4\right)=1-P\left(c_{im}=c_{im}^{j=1}|C^*=G_4\right) \tag{21}$$

2.4.3　敏感性分析

敏感性分析是指从众多不确定性父节点因素中找出对目标节点有重要影响的敏感因子, 即研究参数变化对目标节点条件概率所造成的影响。在贝叶斯网络诊断推理基础上, 采用风险促进值重要度 W、风险降低值重要度 R 和变化横向重要度 M 来衡量根节点 $c_{im}(i=1,2,3,4;m\in N^*)$对可用性评价等级的影响程度计算公式:

$$W(c_{im})=\frac{\max\left\{P\left(C^*=G_4|c_{im}=c_{im}^{j}\right)\right\}-P(C^*=G_4)}{P(C^*=G_4)} \tag{22}$$

$$R(c_{im})=\frac{P(C_*=G_4)-\min\left\{P\left(C^*=G_4|c_{im}=c_{im}^{j}\right)\right\}}{P(C^*=G_4)} \tag{23}$$

$$M(c_{im})=(A(c_{im})+R(c_{im}))/2 \tag{24}$$

3　实例分析

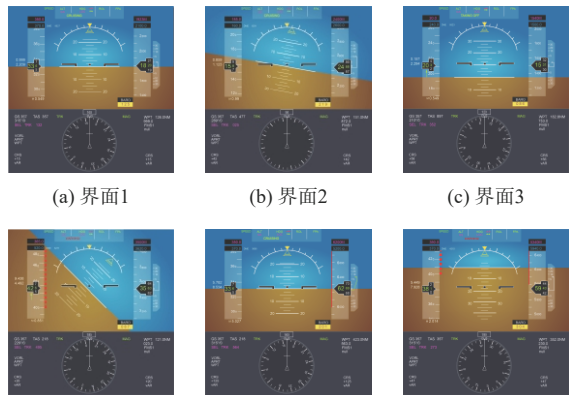
3.1　实验被试

本实验在西北工业大学机电学院进行, 共招募 15 名被试, 年龄范围在 24～30 岁, 平均年龄为 25.6 岁(S_D=2.616 岁), 大部分为与飞行或界面设计相关专业背景的博士、硕士研究生。在接受本实验任务前, 所有被试均受过实验飞行任务的培训, 熟练掌握实验操作方法。

3.2　实验设计

以根节点和中间节点的“STATE=1”状态展开实验设计。鉴于主飞行显示器界面是民机驾驶舱显示界面的核心, 本实验以主飞行显示器为研究对象。实验材料使用作者自绘的主飞行器界面, 如图 5 所示。该系列界面涵盖了巡航、起飞、告警 3 种不同驾驶状态, 对空速、高度、俯仰角、横滚角和航向角的数值和状态进行调整, 异常信息设定范围如表 6 所示。

实验任务为任务 1、任务 2 和任务 3, 并增加无任务设置。无任务要求被试在界面无异常信息时, 自由观察主飞行显示界面 30 s; 任务 1 要求被试自由观察主飞行显示界面 20 s, 记忆关键信息数值后, 点击关键信息的答案; 任务 2 要求被试在已知界面有几处异常值时, 观察界面 20 s 并记忆, 回复异常部位及其数值; 任务 3 要求被试在已知界面存在异常时, 观察界面 20 s 并记忆, 回复异常部位及其数值。



(a) 界面1　(b) 界面2　(c) 界面3

(d) 界面4　(e) 界面5　(f) 界面6

图 5　主飞行显示器界面实验材料

Fig. 5　Experimental materials of primary flight display interface

表 6　主飞行显示器的异常信息范围设置

Table 6　Abnormal message range settings for primary flight display

仪表类型	仪表信息	异常值
姿态仪	横滚角	>20°
	俯仰角	仰角>30°; 俯角>15°
罗盘标尺	航向角	>180°
空速表	空速	>400 kn
高度和垂直速度表	高度	>1 828.80 m

3.3　实验环境

为模拟真实民机驾驶舱情境, 实验在全封闭的室内环境中完成。实验设备包括联想 GeekPro 工作站一台, 被试距离屏幕 500～600 mm, 切视线与屏幕的夹角成 90°。实验选用 Tobii Pro Fusion 遥测式眼动仪, 分辨率设定为 120 Hz, 以记录定量根节点的度量指标参数。

3.4　实验流程

实验开始后让被试进行眼动校准, 接着界面会引导被试进入实验任务。被试完成任务 1、任务 2、任务 3 期间, 记录被试点击任务 1 的答案和口头回复任务 2、任务 3 的答案。眼动实验完成后每名被试需填写主观模糊评价量表、SUS 系统可用性量表、模糊条件评价量表, 其中, 模糊条件量表包括父节点对中间节点 $C_i(i=1,2,3,4)$和叶节点 C^*的影响。

4　实验结果分析

4.1　节点先验概率和条件概率计算

4.1.1　根节点先验概率

1) 定量根节点先验概率。将 15 名被试完成任务 3 的眼动数据作为定量根节点先验概率的来源,

由式(2)和式(3)得，定量根节点$c_{im}(i=1;m\in N^*)$在“STATE=1”状态下眼动度量指标的正相关和负相关标准化结果如表7所示。

利用变异系数法求度量指标权重时，根据式(1)～式(7)计算定量根节点$c_{im}(i=1;m\in N^*)$包含所有度量指标Y_e的平均值$\bar{r}_\rho$、标准差σ_ρ、变异系数φ_ρ和权重δ_ρ。根据式(8)可得，定量根节点$c_{im}(i=1;m\in N^*)$先验概率为所包含度量指标的平均值$\bar{r}_\rho$与权重δ_ρ的乘积之和，最终变异系数法求定量根节点的先验概率$P(c_{1mj})$结果如表8所示。

表7 “STATE=1”状态下眼动度量指标部分标准化结果

Table 7 Results of partial standardisation of eye movement metrics in “STATE=1” state

被试t	Y_1/次	Y_2/ms	Y_3/像素	Y_4/ms	Y_5/ms	Y_6/ms	Y_7/个	Y_8/次	Y_9/%	Y_{10}/ms
t_1	0.772 3	0.545 0	0.533 3	0.547 3	0.941 7	0.474 9	0.533 3	0.121 2	0.25	0.062 0
t_2	0.960 4	0.472 7	0.644 8	0.814 6	0.210 8	0.698 6	0.644 8	0.151 5	0.25	0.076 3
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
t_{14}	0.643 6	0.728 3	0	0.520 5	1	0.783 1	0	0.939 4	0.25	0.065 2
t_{15}	0.703 0	1	0.433 2	0.246 8	0.403 6	0.421 2	0.433 2	0.484 8	0.5	0.097 8

表8 “STATE=1”状态下定量根节点的先验概率

Table 8 Prior probabilitiy of eye movement metrics for quantitative root nodes in “STATE=1” state

c_{1m}	Y	$\bar{r}_\rho$	σ_ρ	φ_ρ	δ_ρ	$P(c_{1mj})$
c_{11}	Y_1	0.674 0	0.263 0	0.390 0	0.242 3	0.528 8
	Y_2	0.474 0	0.310 0	0.654 0	0.406 1	
	Y_3	0.492 0	0.279 0	0.566 0	0.351 7	
c_{12}	Y_4	0.579 0	0.317 0	0.548 0	0.339 2	0.536 3
	Y_5	0.469 0	0.303 0	0.646 0	0.399 9	
	Y_6	0.584 0	0.246 0	0.421 0	0.260 8	
c_{13}	Y_7	0.612 0	0.319 0	0.521 0	0.438 8	0.523 3
	Y_8	0.454 0	0.302 0	0.666 0	0.561 2	
c_{14}	Y_9	0.555 0	0.358 0	0.646 0	0.488 5	0.547 8
	Y_{10}	0.541 0	0.366 0	0.677 0	0.511 5	

2) 定性根节点先验概率。根据表4可得被试年龄、学历、职称、工作年限所对应的权重w_1、w_2、w_3、w_4。由于本实验只考虑“STATE=1”情况，不进行标准化处理。由式(11)～式(13)计算定性根节点$c_{im}(i=2,3,4;m\in N^*)$在“STATE=1”状态下被试的三角模糊概率$\tilde{P}^t_{imj}$、精确概率P_{imj}、先验概率$P(c_{imj})$结果如表9所示。

4.1.2 非根节点条件概率

非根节点的模糊条件概率获取同样采用7级自然语言变量来获取。综合模糊条件概率计算参考定性根节点的综合模糊评价概率计算过程，通过式(11)～式(13)得到父节点影响下的面积均值条件概率表。

重复条件概率计算过程，得到父节点影响下中间节点$C_i(i=1,2,3,4)$处于“STATE=1”状态和叶节点C^*处于$G_\beta=\{G_1,G_2,G_3,G_4\}=\{$优,良,中,差$\}$状态的条件概率表，其中叶节点$C^*$的条件概率如表10所示。

4.2 可用性综合评价模型贝叶斯网络推理

1) 因果推理。在GeNIe软件中填充所有节点的条件概率表，利用软件正向计算界面的可用性评价等级，因果推理结果如图6所示。叶节点C^*全概率$P(C^*=G_2)>P(C^*=G_1)>P(C^*=G_3)>P(C^*=G_4)$，结合表5可知，该主飞行显示器界面的可用性评价等级为“$G_2=$良”。

2) 模型有效性验证。系统可用性量表(system usability scale, SUS)由10个问题组成，其中，奇数项问题着重于积极描述，偶数项问题则偏向消极描述，通常采用5级李克特量表(Likert scale)评分。通过对15名被试的SUS系统可用性量表进行计算，能得到该主飞行显示器界面处于[0,1]区间的归一化SUS系统可用性评分：

$$S_{\mathrm{US}}=[2.5\times(\overline{S}_{\mathrm{q}}-\overline{S}_{\mathrm{p}}+20)]/100=0.87$$

式中：$\overline{S}_{\mathrm{q}}$和$\overline{S}_{\mathrm{p}}$分别表示15名被试对SUS量表中奇数项问题和偶数项问题评分的平均值之和。将主飞行显示器界面处于[0,1]区间的SUS系统可用性分数与表5比较，得到该主飞行显示器界面的可用性评价等级同样为“$G_2=$良”，验证了本文民机驾驶舱显示界面可用性综合评价模型的有效性。

3) 诊断推理。当该主飞行显示器界面的可用性评价等级为“$G_4=$差”时(即$P(C^*=G_4)=1$)，为保证根节点后验概率的负增长，本文还设定中间节

表 9　定性根节点的三角模糊概率和先验概率

Table 9　Triangular fuzzy and prior probabilities for qualitative root nodes

$c_{im}(i=2,3,4;m\in N^*)$	t_1	t_2	t_3	…	t_{15}	三角模糊概率	先验概率
一致性c_{21}	高(H) (0.7,0.9,1.0)	较高(FH) (0.5,0.7,0.9)	高(H) (0.7,0.9,1.0)	…	较高(FH) (0.5,0.7,0.9)	(0.588 6,0.756 6,0.883 8)	0.746 4
简洁性c_{22}	较高(FH) (0.5,0.7,0.9)	高(H) (0.7,0.9,1.0)	中等(M) (0.3,0.5,0.7)	…	较高(FH) (0.9,1.0,1.0)	(0.538 4,0.702 6,0.845 5)	0.696 4
信息呈现c_{23}	中等(M) (0.3,0.5,0.7)	高(H) (0.7,0.9,1.0)	较高(FH) (0.7,0.9,1.0)	…	中等(M) (0.3,0.5,0.7)	(0.581 7,0.756 1,0.894 3)	0.747 0
信息易读性c_{24}	较高(FH) (0.5,0.7,0.9)	高(H) (0.7,0.9,1.0)	高(H) (0.7,0.9,1.0)	…	较高(FH) (0.9,1.0,1.0)	(0.606 2,0.768 2,0.894 3)	0.759 2
理解c_{31}	中等(M) (0.3,0.5,0.7)	高(H) (0.7,0.9,1.0)	中等(M) (0.3,0.5,0.7)	…	较高(FH) (0.7,0.9,1.0)	(0.610 8,0.779 0,0.896 1)	0.766 2
易学性c_{32}	高(H) (0.7,0.9,1.0)	非常高(VH) (0.9,1.0,1.0)	高(H) (0.7,0.9,1.0)	…	中等(M) (0.3,0.5,0.7)	(0.567 8,0.729 8,0.868 7)	0.724 0
满意度c_{33}	中等(M) (0.3,0.5,0.7)	高(H) (0.7,0.9,1.0)	较高(FH) (0.7,0.9,1.0)	…	中等(M) (0.3,0.5,0.7)	(0.591 3,0.758 4,0.887 4)	0.748 9
最小记忆负荷c_{34}	中等(M) (0.3,0.5,0.7)	高(H) (0.7,0.9,1.0)	中等(M) (0.3,0.5,0.7)	…	中等(M) (0.3,0.5,0.7)	(0.490 9,0.665 1,0.807 1)	0.657 0
信息实时性c_{41}	较低(FL) (0.1,0.3,0.5)	高(H) (0.7,0.9,1.0)	较低(FL) (0.1,0.3,0.5)	…	高(H) (0.7,0.9,1.0)	(0.454 5,0.628 7,0.785 4)	0.624 4
信息精确性c_{42}	较高(FH) (0.7,0.9,1.0)	高(H) (0.7,0.9,1.0)	较高(FH) (0.7,0.9,1.0)	…	高(H) (0.7,0.9,1.0)	(0.478 1,0.638 6,0.767 8)	0.630 7
错误预防c_{43}	较低(FL) (0.1,0.3,0.5)	较高(FH) (0.7,0.9,1.0)	较高(FH) (0.7,0.9,1.0)	…	高(H) (0.7,0.9,1.0)	(0.351 9,0.519 9,0.685 6)	0.519 3
交互反馈c_{44}	低(L) (0,0.1,0.3)	较高(FH) (0.7,0.9,1.0)	中等(M) (0.3,0.5,0.7)	…	较高(FH) (0.7,0.9,1.0)	(0.430 4,0.584 3,0.738 2)	0.584 3

表 10　“STATE=1”状态下父节点对叶节点C^*影响下的条件概率表

Table 10　Conditional probability table under the influence of parent nodes on leaf node C^* in “STATE=1” state

C^*处于G_1状态时	条件概率值	C^*处于G_2状态时	条件概率值	C^*处于G_3状态时	条件概率值	C^*处于G_4状态时	条件概率值
$P(C^*=G_2\leftarrow C_1)$	0.315 4	$P(C^*=G_2\leftarrow C_1)$	0.425 6	$P(C^*=G_3\leftarrow C_1)$	0.213 3	$P(C^*=G_4\leftarrow C_1)$	0.047 5
$P(C^*=G_1\leftarrow C_2)$	0.421 7	$P(C^*=G_2\leftarrow C_2)$	0.512 5	$P(C^*=G_3\leftarrow C_2)$	0.065 5	$P(C^*=G_4\leftarrow C_2)$	0.003 0
$P(C^*=G_1\leftarrow C_3)$	0.414 6	$P(C^*=G_2\leftarrow C_3)$	0.425 9	$P(C^*=G_3\leftarrow C_3)$	0.147 6	$P(C^*=G_4\leftarrow C_3)$	0.019 9
$P(C^*=G_1\leftarrow C_4)$	0.145 2	$P(C^*=G_2\leftarrow C_4)$	0.264 3	$P(C^*=G_3\leftarrow C_4)$	0.387 2	$P(C^*=G_4\leftarrow C_4)$	0.203 3
$P(C^*=G_1\leftarrow C_1,C_2)$	0.369 7	$P(C^*=G_2\leftarrow C_1,C_2)$	0.421 8	$P(C^*=G_3\leftarrow C_1,C_2)$	0.129 7	$P(C^*=G_4\leftarrow C_1,C_2)$	0.078 8
$P(C^*=G_1\leftarrow C_1,C_3)$	0.258 7	$P(C^*=G_2\leftarrow C_1,C_3)$	0.346 4	$P(C^*=G_3\leftarrow C_1,C_3)$	0.358 8	$P(C^*=G_4\leftarrow C_1,C_3)$	0.036 1
$P(C^*=G_1\leftarrow C_1,C_4)$	0.123 1	$P(C^*=G_2\leftarrow C_1,C_4)$	0.310 5	$P(C^*=G_3\leftarrow C_1,C_4)$	0.456 3	$P(C^*=G_4\leftarrow C_1,C_4)$	0.110 1
$P(C^*=G_1\leftarrow C_2,C_3)$	0.454 3	$P(C^*=G_2\leftarrow C_2,C_3)$	0.425 1	$P(C^*=G_3\leftarrow C_2,C_3)$	0.116 0	$P(C^*=G_4\leftarrow C_2,C_3)$	0.004 6
$P(C^*=G_1\leftarrow C_2,C_4)$	0.297 6	$P(C^*=G_2\leftarrow C_2,C_4)$	0.402 0	$P(C^*=G_3\leftarrow C_2,C_4)$	0.214 1	$P(C^*=G_4\leftarrow C_2,C_4)$	0.086 3
$P(C^*=G_1\leftarrow C_3,C_4)$	0.265 2	$P(C^*=G_2\leftarrow C_3,C_4)$	0.396 8	$P(C^*=G_3\leftarrow C_3,C_4)$	0.278 1	$P(C^*=G_4\leftarrow C_3,C_4)$	0.059 9
$P(C^*=G_1\leftarrow C_1,C_2,C_3)$	0.394 4	$P(C^*=G_2\leftarrow C_1,C_2,C_3)$	0.362 3	$P(C^*=G_3\leftarrow C_1,C_2,C_3)$	0.156 3	$P(C^*=G_4\leftarrow C_1,C_2,C_3)$	0.087 0
$P(C^*=G_1\leftarrow C_1,C_2,C_4)$	0.375 2	$P(C^*=G_2\leftarrow C_1,C_2,C_4)$	0.412 0	$P(C^*=G_3\leftarrow C_1,C_2,C_4)$	0.118 9	$P(C^*=G_4\leftarrow C_1,C_2,C_4)$	0.093 9
$P(C^*=G_1\leftarrow C_2,C_3,C_4)$	0.218 9	$P(C^*=G_2\leftarrow C_1,C_3,C_4)$	0.371 3	$P(C^*=G_3\leftarrow C_1,C_3,C_4)$	0.301 1	$P(C^*=G_4\leftarrow C_1,C_3,C_4)$	0.106 9
$P(C^*=G_1\leftarrow C_2,C_3,C_4)$	0.192 3	$P(C^*=G_2\leftarrow C_2,C_3,C_4)$	0.421 0	$P(C^*=G_3\leftarrow C_2,C_3,C_4)$	0.376 4	$P(C^*=G_4\leftarrow C_2,C_3,C_4)$	0.010 3
$P(C^*=G_2\leftarrow C_1,C_2,C_3,C_4)$	0.365 4	$P(C^*=G_2\leftarrow C_1,C_2,C_3,C_4)$	0.552 1	$P(C^*=G_3\leftarrow C_1,C_2,C_3,C_4)$	0.075 1	$P(C^*=G_4\leftarrow C_1,C_2,C_3,C_4)$	0.007 4
$P(C^*=G_2\leftarrow \overline{C_1},\overline{C_2},\overline{C_3},\overline{C_4})$	0.075 0	$P(C^*=G_2\leftarrow \overline{C_1},\overline{C_2},\overline{C_3},\overline{C_4})$	0.008 6	$P(C^*=G_3\leftarrow C_1,C_2,C_3,C_4)$	0.258 2	$P(C^*=G_4\leftarrow C_1,C_2,C_3,C_4)$	0.658 2

点$C_i(i=1,2,3,4)$处于“STATE=0”消极状态的发生概率为 1。根据式(20)和式(21)计算各根节点的后验概率, 通过 GeNIe 软件建立的逆向诊断推理结果如图 7 所示。

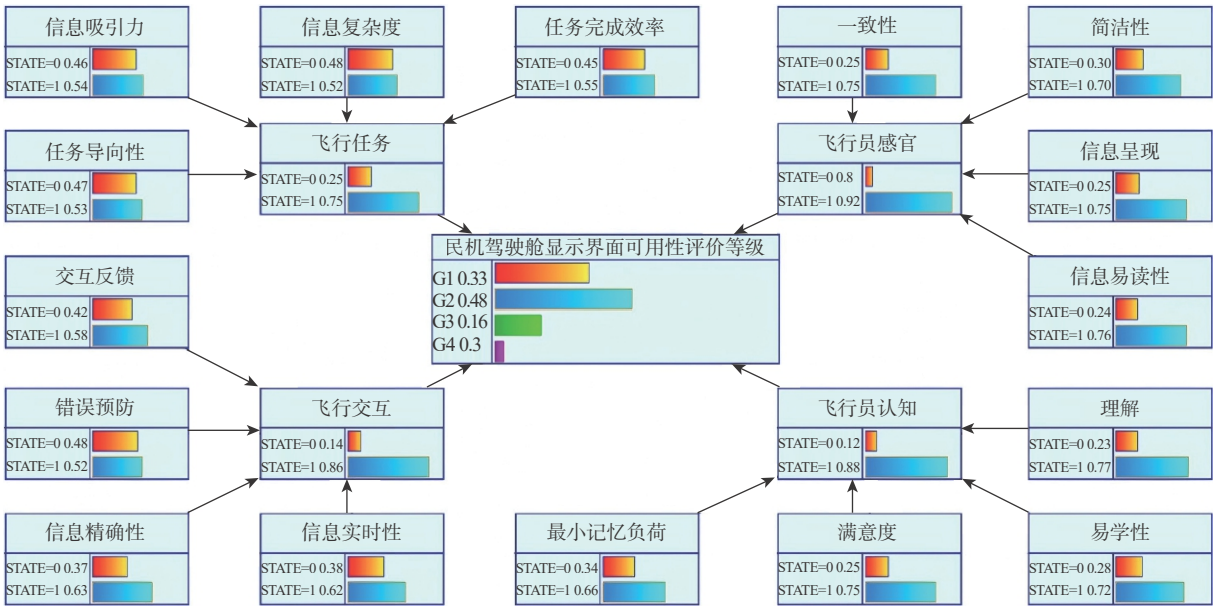


图6 可用性评价模型因果推理结果

Fig. 6 Causal reasoning result of usability evaluation model

根节点后验概率与先验概率的差值为变化百分比，若变化百分比越大，说明该根节点最能影响叶节点和中间节点。图8给出了根节点处于“STATE=1”状态下的先验概率、后验概率和变化百分比。由图8可知，该主飞行显示器界面对应的可用性评价指标均明显降低。当界面可用性状态最差时，根节点变化百分比＞10%的可用性评价指标有任务导向性c_{11}、一致性c_{21}、简洁性c_{22}、信息呈现c_{23}、信息易读性c_{24}、信息实时性c_{41}和信息精确性c_{42}。结果表明：在缺乏其他证据的情况下，上述有明显变化百分比的可用性评价指标可能是导致该界面可用性下降的最主要原因。

4）敏感性分析。根据式(22)～式(24)计算该界面中各根节点$W(c_{im})$、$R(c_{im})$和$M(c_{im})$的值，如图9所示。由图9可知，3项重要程度指标的排序结果相似，一致性c_{21}、简洁性c_{22}、信息呈现c_{23}、信息易读性c_{24}、信息实时性c_{41}和信息精确性c_{42}这6个敏感因子的排序最为靠前，应重点优化改进，具体措施如下。

在飞行员感官C_2维度，界面需弱化横滚针刻度线和航向角标识，选择更直观的图形或图标；替换背景颜色代表“天空”“大地”的色彩方案与对比度，调整字符排列和密度、各类仪表信息量大小。

在飞行交互C_4维度，界面需包含明确的反馈机

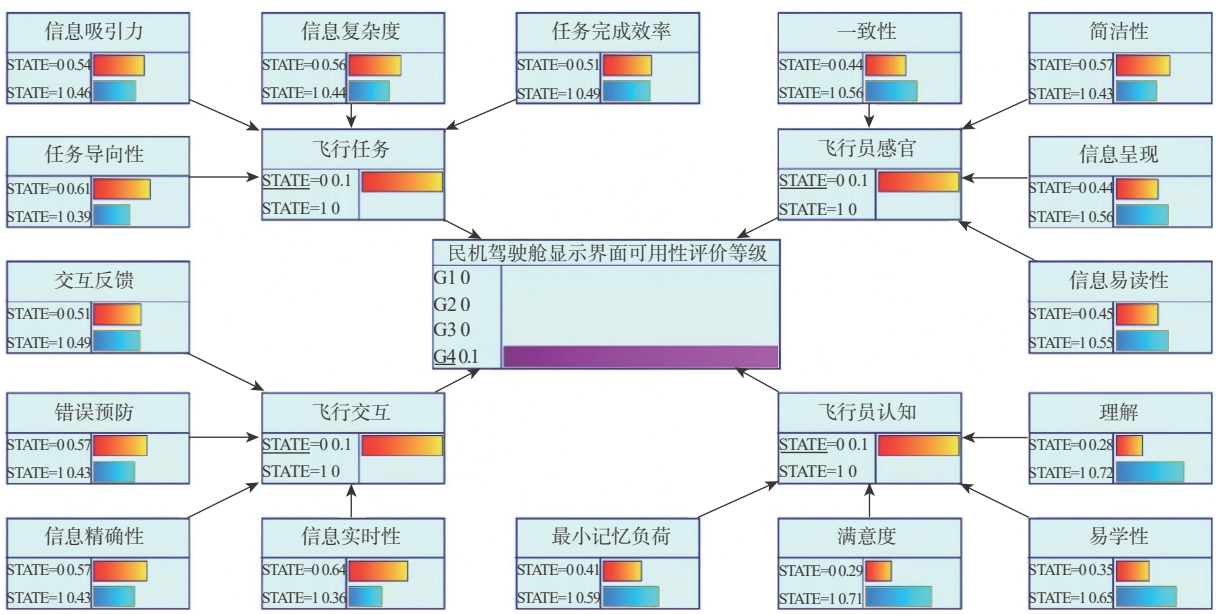


图7 可用性评价模型诊断推理结果

Fig. 7 Diagnostic reasoning result of usability evaluation model

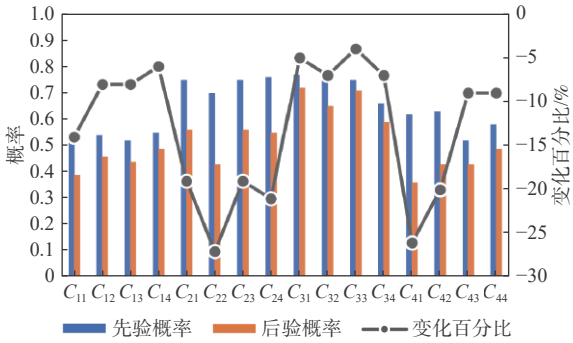


图 8　根节点处于“STATE=1”状态下的先验概率、后验概率和变化百分比

Fig. 8　Priori probability, posterior probability and percentage change of each root node in "STATE=1" state

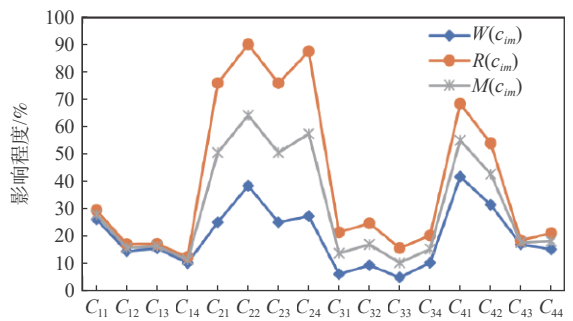


图 9　根节点重要程度

Fig. 9　Importance of root nodes

制, 如突出飞行空速、高度等关键参数的变化趋势和异常数值提示; 采用线框标明不同飞行状态, 增加对告警状态的预警响应。

5　结　论

1) 本文基于 EPIC 模型提取民机驾驶舱显示界面可用性评价指标的飞行任务、飞行员感官、飞行员认知和飞行交互维度, 在 4 个维度基础上, 提取并筛选出 4 个定性指标和 12 个定量指标。

2) 本文提出一种基于贝叶斯网络的民机驾驶舱显示界面可用性综合评价模型, 通过主飞行显示器界面的可用性评价模型因果推理结果与 SUS 量表评价结果相同, 验证了本文模型的有效性。

3) 可用性综合评价模型的定量根节点先验概率由眼动度量指标加权评价获得, 通过客观的行为数据减少评价偏差; 而定性根节点先验概率是基于专家和三角模糊数综合评价, 能有效处理评价的不确定性和主观性。

为提高模型贝叶斯网络中定量根节点先验概率的准确性, 可融合 Kinect、心率、呼吸等多源评价数据。

参考文献（References）

[1] 郑秀梅, 田晓康, 柳青, 等. 通用航空事故致因文本挖掘和社会网络分析[J]. 安全与环境学报, 2024, 24(2): 602-609.
Zheng X M, Tian X K, Liu Q, et al. Text mining and social network analysis of general aviation accident causes[J]. Journal of Safety and Environment, 2024, 24(2): 602-609(in Chinese).

[2] 王君, 孙宏. 航空飞行事故原因分析及预防[J]. 物流科技, 2021, 44(1): 81-84.
Wang J, Sun H. Analysis and prevention of aviation accidents[J]. Logistics Sci Tech, 2021, 44(1): 81-84(in Chinese).

[3] Al-Kilidar H, Cox K, Kitchenham B. The use and usefulness of the ISO/IEC 9126 quality standard[C]//Proceedings of the 2005 International Symposium on Empirical Software Engineering. Piscataway: IEEE Press, 2005: 7.

[4] Xue H J, Li T, Zhang X Y. An approach for assessing the usability of cockpit display system[C]//Proceedings of the Engineering psychology and cognitive ergonomics: Cognition and design. Berlin: Springer, 2017: 317-325.

[5] 张惠琳. 飞机驾驶舱数字界面的可用性评估研究[D]. 南京: 南京航空航天大学, 2020.
Zhang H L. Research on usability evaluationof aircraft cockpit digital interface[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2020(in Chinese).

[6] Lewis J R. The system usability scale: past, present, and future[J]. International Journal of Human-Computer Interaction, 2018, 34(7): 577-590.

[7] Zhong X, Cheng Y N, Yang J H, et al. Evaluation and optimization of in-vehicle HUD design by applying an entropy weight-VIKOR hybrid method[J]. Applied Sciences, 2023, 13(6): 3789.

[8] Choi H, Kim S, Jang W. User experience evaluation of a spinal surgery robot: workload, usability, and satisfaction study[J]. JMIR Human Factors, 2024, 11: e54425.

[9] 李亚鸿, 董占勋, 储程. 基于质量屋的数字孪生系统用户界面优化和可用性评价[J]. 计算机集成制造系统, 2023, 29(6): 1941-1949.
Li Y H, Dong Z X, Chu C. User interface optimization and usability evaluation for digital twin system based on house of quality[J]. Computer Integrated Manufacturing Systems, 2023, 29(6): 1941-1949(in Chinese).

[10] Chiu M C, Huang P H, Tsao S H. Redesigning the user interface of a healthcare management system for the elderly with a systematic usability testing method[J]. Journal of Industrial and Production Engineering, 2019, 36(5): 324-334.

[11] 江涛, 葛正浩, 雷静, 等. 基于模糊层次分析法的工业缝纫机可用性评价[J]. 机械设计, 2022, 39(12): 119-124.
Jiang T, Ge Z H, Lei J, et al. Usability evaluation of industrial sewing machine based on fuzzy analytic hierarchy process[J]. Journal of Machine Design, 2022, 39(12): 119-124(in Chinese).

[12] Kabir S, Papadopoulos Y. Applications of Bayesian networks and Petri nets in safety, reliability, and risk assessments: a review[J]. Safety Science, 2019, 115: 154-175.

[13] 杨海波, 汪洋, 张磊. 人机交互的 GOMS 模型与 EPIC 模型的比较[J]. 包装工程, 2015, 36(8): 96-99.
Yang H B, Wang Y, Zhang L. Comparison of human-computer interaction model of GOMS and EPIC[J]. Packaging Engineering, 2015, 36(8): 96-99(in Chinese).

[14] Nielsen J. The usability engineering life cycle[J]. Computer, 1992, 25(3): 12-22.

[15] 徐美姣, 薛善良, 张惠, 等. 基于 BP-AdaBoost 算法的复杂产品装配制造成熟度等级评估方法[J]. 中国机械工程, 2023, 34(20): 2513-2519.
Xu M J, Xue S L, Zhang H, et al. Manufacturing readiness level assessment method of complex product assembly based on BP-AdaBoost algorithm[J]. China Mechanical Engineering, 2023, 34(20): 2513-2519(in Chinese).
[16] Weichbroth P. Usability of mobile applications: a systematic literature study[J]. IEEE Access, 2020, 8: 55563-55577.
[17] Chen D K, Zhu M Y, Qiao Y D, et al. An ergonomic design method of manned cabin driven by human operation performance[J]. Advanced Design Research, 2023, 1(1): 12-20.
[18] 赵欣, 丁怡, 侯文军, 等. 复杂信息系统界面可用性指标体系研究[J]. 图学学报, 2018, 39(4): 716-722.
Zhao X, Ding Y, Hou W J, et al. On the usability evaluation index system of complex information system interface[J]. Journal of Graphics, 2018, 39(4): 716-722(in Chinese).
[19] Mohanavelu K, Poonguzhali S, Ravi D, et al. Cognitive workload analysis of fighter aircraft pilots in flight simulator environment[J]. Defence Science Journal, 2020, 70(2): 131-139.
[20] 李敏, 林志军, 鲁义, 等. 基于模糊贝叶斯网络的煤矿瓦斯爆炸风险评估[J]. 煤炭学报, 2023, 48(增刊 2): 626-637.
Li M, Lin Z J, Lu Y, et al. Risk assessment of gas explosionin coal mines based on fuzzy Bayesian network[J]. Journal of China Coal Society, 2023, 48(Sup 2): 626-637(in Chinese).

BN-based comprehensive evaluation model for display interface usability in civil aircraft cockpit

XIAO Yao[1], CHEN Dengkai[1,*], ZHOU Yao[1], XIAO Jianghao[1], HOU Yuhong[1,2]

(1. Key Laboratory of Industrial Design and Ergonomics, Ministry of Industry and Information Technology, Northwestern Polytechnical University, Xi'an 710072, China;
2. Chinese Flight Test Establishment, Xi'an 710089, China)

Abstract: Optimizing the design interface is aided by research on the usability of display interfaces in civil aircraft cockpits. Aiming at the uncertainty of usability evaluation of civil aircraft cockpit display interface, this paper proposes a comprehensive usability evaluation model based on the Bayesian network (BN). Firstly, a Bayesian network is established based on the usability evaluation indicator system obtained from the executive process-interactive control model (EPIC). Both the experts' triangle fuzzy number evaluation and the quantitative root nodes' weighted evaluation of expert eye movement measures served as prior probabilities. Secondly, in order to reduce the number of experts' decision-making, the Noisy-OR model was used to fill the conditional probability table of the Bayesian network, and the model was built using GeNIe software. A primary flight display interface is taken as an example for instance verification. The results show that the causal reasoning results of the model are consistent with evaluation results of the system usability scale (SUS) scale. The evaluation grade of the interface is "good", which verifies the effectiveness of the model, and proposes improvement measures for sensitive factors obtained by the model sensitivity analysis.

Keywords: civil aircraft cockpit; display interface; usability evaluation; Bayesian network; eye movement

Received: 2024-08-28; **Accepted**: 2024-09-23; **Published Online**: 2024-10-16 14:38
URL: link.cnki.net/urlid/11.2625.V.20241016.1259.005
Foundation item: Key Research and Development Program of Shaanxi (2022GY-311)
* **Corresponding author**. E-mail: chendengkai@nwpu.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0658

一种复杂动态场景实时视觉SLAM算法

赵舶廷[1]，刘军[1,*]，柴宏旭[2]，张健烨[1]，吴睿彬[1]

(1. 兰州理工大学 机电工程学院，兰州 730050；2. 甘肃省特种设备检验检测研究院，兰州 730050)

摘 要：针对存在动态物体的一般性或复杂动态场景下同步定位与地图构建（SLAM）系统往往存在强假设性条件或定位精度不足乃至失效等多种问题，提出一种复杂动态场景实时视觉SLAM算法。该算法以ORB-SLAM3为基础，部署基于加速模型推理的YOLOX-s获取语义先验信息以处理动态目标，并结合卡尔曼滤波和匈牙利算法补偿目标检测缺失；为提升算法定位精度和泛化性能，在利用基于网格的运动统计（GMS）特征匹配算法快速筛选有效匹配点的基础上，提出一种双类别动态场景处理策略，根据图像匹配精度将场景分为两类处理：对低动态帧，采用GMS算法快速过滤动态特征，避免进行大量矩阵运算从而提升运行效率；对高动态帧，在利用卡方检验识别运动异常值的同时，提出一种动态特征剔除策略，根据自适应阈值剔除动态点并保持跟踪稳定性。标准数据集与真实场景下的实验测试均表明，所提算法能解决室内外复杂动态场景下的实时定位问题，表现出良好的精确性、鲁棒性和及时性。

关 键 词：视觉SLAM；动态物体；深度学习；目标检测；场景分类

中图分类号：TP242.6

文献标志码：A **文章编号**：1001-5965(2026)11-4075-15

同步定位与地图构建(simultaneous localization and mapping, SLAM)是智能移动机器人环境感知和自主定位的关键技术之一，其是指机器人利用特定的传感器模组，在未知环境中估计自身运动，于运动过程中构建环境的模型[1]。自20世纪80年代首次提出该问题以来，经过数十年的研究，SLAM技术取得了显著进展，由于摄像机等视觉传感器具有成本低、信息量丰富、使用场景多样的特点，视觉SLAM具有巨大的发展潜力和广阔的应用前景。

前人一般基于静态场景开展相关SLAM技术研究，即假设环境中所有物体为静态刚体。但日常生活和工业应用等现实环境中普遍存在动态物体，其引入的误导性数据关联会影响相机的跟踪精度和生成地图的可靠性。

对于环境中的动态物体，普遍采用的解决方案是：从SLAM的输入数据中识别动态成分，将其视为异常值丢弃以避免其干扰相机位姿估计和地图构建。例如，基于定向FAST角点与旋转BRIEF描述子的同时定位与地图构建[2](oriented FAST and rotated BRIEF-simultaneous localization and mapping, ORB-SLAM)利用随机采样一致算法过滤外点，并行跟踪与地图构建[3](parallel tracking and mapping, PTAM)则使用鲁棒核函数处理异常值。也有一些算法在经典SLAM框架的基础上，为静态特征设置一个带几何约束的阈值，利用阈值检测动态特征，再将其视作离群值加以移除以应对场景中的动态物体。除此之外，各国学者围绕该问题也开展了一些其他的努力与尝试，Cheng等[4]通过比较相邻两帧图像之间的相似性和差异性，基于贝叶斯框架将场景划分为动态和静态区域，但由于其采用固定的阈值进

收稿日期：2024-09-05；录用日期：2024-11-07；网络出版时间：2024-12-03 12:14
网络出版地址：link.cnki.net/urlid/11.2625.V.20241203.0904.002
基金项目：国家自然科学基金(71861025)；甘肃省科技厅自主研发计划-工业类(22YF11GA315)；兰州市科技支撑专项（2024-8-46）
*通信作者. E-mail：lzhjliu@126.com

引用格式：赵舶廷，刘军，柴宏旭，等. 一种复杂动态场景实时视觉SLAM算法[J]. 北京航空航天大学学报，2026，52（11）：4075-4089.
Zhao B T，Liu J，Chai H X，et al. A real-time visual SLAM algorithm for complex dynamic scenarios[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：4075-4089（in Chinese）.

行区域划分，在低动态场景中常存在区域划分错误的情况；Dai等[5]使用Delaunay三角剖分法，利用特征点之间的相关性来分离动态点和静态点，但不适用于运动物体占比过大的场景；Du等[6]使用具有长期一致性的条件随机场，通过整合多帧长期观测信息来检测动态成分，但也存在静态场景跟踪失败的问题。总体而言，上述方法一般不依赖先验信息，部分方法中相关固定阈值主要基于经验进行确定，并且只能处理简单环境或动态物体较少的场景，当动态物体所占图像比例过大、数量较多或存在遮挡等复杂场景时，上述方法存在失效问题。

为此，部分学者近年来将神经网络集成至SLAM系统中，尝试利用深度学习方法解决该问题。其主要思路是利用神经网络处理语义先验信息来划分潜在动态区域，并进而结合几何约束消除动态特征对SLAM的影响。

例如，一些算法将语义分割网络和SLAM系统相结合，Bescos等[7]使用Mask R-CNN对先验动态物体进行像素级实例分割，再结合多视图几何方法剔除动态物体上的特征点；Yu等[8]使用轻量化网络SegNet获取语义掩膜，通过计算帧间匹配点的极线距离去除离群值；王浩等[9]结合实例分割网络YOLACT与深度图像聚类的结果，通过实例分割修补算法和基于实例级对象的运动状态判定算法，优化动态环境下的相机位姿估计。上述基于语义分割的方法可获得像素级掩膜，但精细分割导致计算成本过高，逐帧处理图像的方式往往难以保障实时性，不能满足在线处理的要求，而且掩膜边界的划分结果也并不完全可靠。

也有部分学者将目标检测网络作为附加线程引入到SLAM系统中，例如，齐浩等[10]采用轻量化网络YOLOv7-tiny结合光流检测动态区域，并基于图像对比度自适应调整特征点提取数量以应对光照变化对特征提取的不良影响；Soares等[11]先基于YOLOV3训练得到网络模型CYTi，再根据检测结果移除冗余特征点，但其不能有效识别人类以外的其他运动物体；Cheng等[12]创建了2个用于检测运动目标和构建语义地图的新线程，并提出了一个融合语义和几何信息的快速动态特征剔除算法；He等[13]在优化环节中，赋予每个特征点一个优化权重，降低潜在动态特征对位姿估计的不利影响。虽然结合目标检测的SLAM算法一般比语义分割的SLAM算法更加高效，但由于无法获取完整的物体边缘信息，检测框内可能包含其他背景信息，若简单移除框内所有特征点可能会导致算法失效，仍需额外制定对应处理策略；并且当2个检测框存在交集时可能会产生歧义；此外，若将所有动态特征视作同一属性，处理多变的现实场景时也存在算法泛化能力不足的问题。

总体而言，虽然当前基于神经网络的方法在不同程度上提高了部分动态环境下相关SLAM算法的跟踪精度，但均存在效率和性能难以兼顾的问题，各国学者仍在不断努力以满足不同应用场景下的技术需求。此外，该类方法大多具有一个强假设条件，即限定动态物体为某些特定类，如生活环境中的人类和车辆，但当出现未知动态物体时，其可靠性会大幅下降。

基于此，本文针对动态物体数量较多、运动速度、幅度差异性大或者物体间存在遮挡的复杂动态场景，提出一种实时语义动态视觉SLAM算法。该算法在ORB-SLAM3的框架上进行扩展，集成轻量化网络YOLOX-s获取目标对象的语义先验信息，假设所有被检测到的目标都可能处于运动状态；利用卡尔曼滤波与匈牙利算法预测目标的运动轨迹以补偿目标检测中可能出现的遗漏和缺失；通过在匹配优化中GMS算法得到的匹配结果计算匹配精度，再根据匹配精度将动态场景细分为两类进行针对性处理，在兼顾实时性应用需求的同时，有效提升算法定位精度；在此基础之上，结合静态目标的语义信息进行场景重建，构建具有全局一致性的静态稠密语义点云地图。

1 SLAM算法实现

鉴于ORB-SLAM3[14]在定位精度和鲁棒性方面优于同类基于特征点的视觉SLAM算法，且支持单目，双目和RGB-D等多种相机，选择以ORB-SLAM3为基础框架进行二次开发。

本文算法框架如图1所示，为实时、准确获取目标对象的语义类别标签和检测框的像素坐标，在ORB-SLAM3前端部署利用TensorRT (https://developer.nvidia.com/tensorrt)加速模型推理的轻量化网络YOLOX-s[15]进行目标检测。针对待检目标存在检测遗漏、缺失的问题，利用卡尔曼滤波预测目标运动轨迹，匈牙利算法建立数据关联，对目标检测结果进行补偿。

同时，在最小化运行时间成本的条件下，为提高不同动态程度场景下SLAM系统的定位精度，在图像特征匹配环节，首先利用GMS特征匹配过滤算法[16]快速筛选得到有效匹配点，在此基础上，设计一种基于匹配精度的双类别动态场景处理策略，根据帧间匹配精度将图像帧分为高低动态2个类别处理：对低动态场景，将GMS算法得到的匹配点

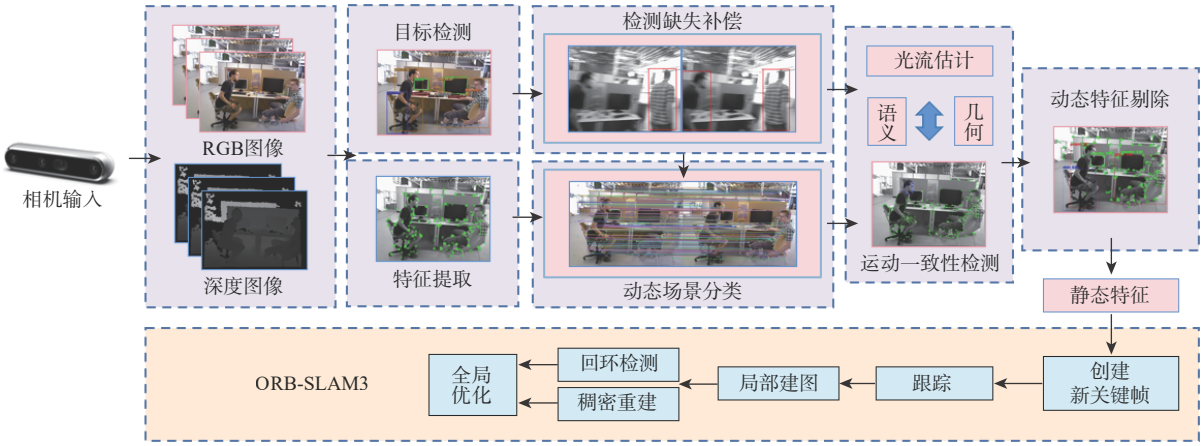


图 1　SLAM 算法框架

Fig. 1　Frame of SLAM algorithm

直接用于相机位姿估计，快速鲁棒地过滤轻微的动态特征；对高动态场景，结合光流和对极几何约束检测动态异常值，考虑到固定的经验阈值对未知环境的泛化性能不足，引入卡方检验识别检测框内点的运动状态，再结合语义先验移除离群值。

此外，本文提出一种动态特征剔除策略，根据检测框内特征点总数自适应调整阈值确定动态框，当检测框间存在重叠时，保留静态框内点和框外背景点，而不是简单地消除动态框内所有点以增加稳定的静态特征点数量，从而提升 SLAM 系统的跟踪稳定性。

最后，当以 RGB-D 相机作为输入时，将二维图像中静态目标的语义信息投影至三维点云，经过点云滤波、拼接和染色处理，构建具有全局一致性的静态语义点云地图，有助于机器人开展导航避障、识别抓取和人机交互等后续工作。

1.1　目标检测缺失补偿

有效检测和识别动态物体并针对性加以处理是提升动态场景下 SLAM 算法定位精度的关键之一。为保障及时性要求，本文采用推理效率相对较高但结构简单的 YOLOX-s 网络进行目标检测，其目的是利用神经网络获取目标对象的类别和位置信息，为后续处理策略提供语义先验。YOLOX-s 能够同时识别 80 类对象，基本满足现实场景的应用需要。并且，为进一步提高推理效率，本文亦采用模型推理优化器 TensorRT 从层和张量融合、内核自动调整、多流并行等角度，对 YOLOX-s 的网络结构进行重构和优化。

虽然轻量化目标检测网络推理效率高，但其模型参数和计算量有限、特征提取能力较弱，可能因运动模糊、视角转换、目标遮挡、视角内目标不完整等因素的干扰而失效，尤其是环境中存在动态目标，语义先验的缺失会影响图像特征提取并降低匹配精度，同时产生大量错误的数据关联，进而影响 SLAM 系统的跟踪和定位。对动态目标进行跟踪，利用跟踪结果补偿检测缺失可以在一定程度上弥补这种缺陷。

考虑到干扰因素可能导致相机输入图像质量下降，从而降低目标检测结果的置信度甚至出现检测缺失，本文将 YOLOX-s 的检测置信度阈值设为 0，而非常见的 0.4 或 0.5，即保留所有置信度大于 0 的检测框进行处理。在保证检测效率的基础上，最大限度地降低首帧中运动目标检测缺失的不良影响。

由于相机的采样频率通常在 30 Hz 以上，相邻图像帧间运动目标的移动距离较小，满足卡尔曼滤波的恒速运动模型假设，本文采用多目标跟踪算法 BoT-SORT[17] 对场景中的人类和车辆等潜在运动目标进行跟踪，对 YOLOX-s 的检测缺失进行补偿。

图 2 为本文使用的多目标跟踪算法流程，其中，S 为置信度。首先输入当前帧中潜在运动目标的检测结果 $\boldsymbol{D}_t$，包括检测框的置信度 θ、语义类别及图像平面上的二维坐标。再利用 OpenCV 库集成的相机全局运动补偿技术对上一帧的跟踪轨迹 $\boldsymbol{T}_{t-1}$ 进行校正，针对卡尔曼滤波只根据检测框宽高比进行轨迹预测，导致预测结果不佳的问题，直接对检测框的宽和高分别进行预测，获得更为准确的预测结果。通过卡尔曼滤波器对潜在运动目标进行轨迹预测，获得的结果 $\boldsymbol{T}_{\mathrm{p}}$ 可表示为

$$\boldsymbol{T}_{\mathrm{p}}=\begin{cases}\hat{\boldsymbol{x}}_t^{-}=\boldsymbol{F}_t\hat{\boldsymbol{x}}_{t-1}\\ \boldsymbol{P}_t^{-}=\boldsymbol{F}_{t-1}\boldsymbol{P}_{t-1}+\boldsymbol{Q}_t\end{cases}\tag{1}$$

输入为当前帧的系统噪声协方差矩阵 $\boldsymbol{Q}_t$，上一帧的跟踪轨迹状态转移矩阵 $\boldsymbol{F}_{t-1}$、状态向量 $\hat{\boldsymbol{x}}_{t-1}$ 和状态协方差矩阵 $\boldsymbol{P}_{t-1}$，输出为当前帧的预测轨迹状态向量 $\hat{\boldsymbol{x}}_t^{-}$ 和状态协方差矩阵 $\boldsymbol{P}_t^{-}$，预测轨迹状态向量

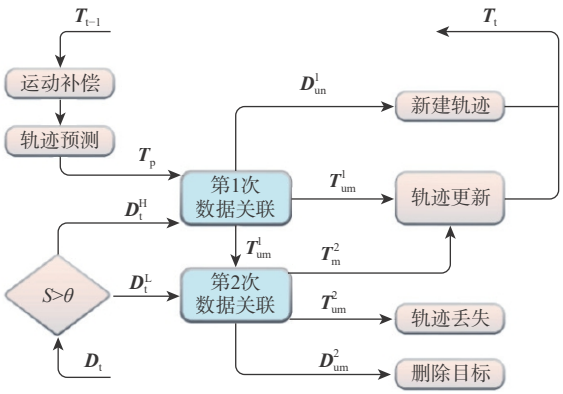


图2 多目标跟踪算法流程

Fig. 2 Multi object tracking algorithm flow chart

$\hat{\boldsymbol{x}}_t^-$可表示为

$$\hat{\boldsymbol{x}}_t^- = [x_c, y_c, w, h, x_c', y_c', w', h']^{\mathrm{T}} \tag{2}$$

式中：(x_c, y_c)为检测框的中心坐标；w和h分别为宽和高；x_c'、y_c'、w'、h'表示各项变化速率。

同时，将当前帧的检测结果$\boldsymbol{D}_t$分成低置信度$\boldsymbol{D}_t^{\mathrm{L}}$和高置信度$\boldsymbol{D}_t^{\mathrm{H}}$两类，为保持SLAM系统的整体运行效率，由式(3)计算$\boldsymbol{D}_t^{\mathrm{H}}$中的检测框$D_i$和预测框$P_i$的交并比(intersection of union, IoU)：

$$i(D_i, P_i) = \frac{D_i \cap P_i}{D_i \cup P_i} \tag{3}$$

使用交并比$i(D_i, P_i)$表示匹配相似度，若$i(D_i, P_i)$小于设定阈值，则表示预测框不能与YOLOX-s获取的检测框建立匹配关系，即当前帧中出现目标检测缺失，使用预测框作为当前帧的目标检测结果对检测缺失进行补偿。

数据关联则是通过计算一个$N \times M$代价矩阵实现，其中，N表示检测框的数量，M表示预测框的数量，代价矩阵$\boldsymbol{I}(\boldsymbol{D}, \boldsymbol{P})$的每个元素如下：

$$\boldsymbol{I}(\boldsymbol{D}, \boldsymbol{P}) = \begin{bmatrix} i(D_1, P_1) & \cdots & i(D_1, P_M) \\ i(D_2, P_1) & \cdots & i(D_2, P_M) \\ \vdots & & \vdots \\ i(D_N, P_1) & \cdots & i(D_N, P_M) \end{bmatrix} \tag{4}$$

匈牙利算法利用代价矩阵$\boldsymbol{I}(\boldsymbol{D}, \boldsymbol{P})$对检测框和预测框进行匹配，将其转化为最优任务分配问题，使得当前帧总体匹配相似度最大，进而确定预测框与检测框的对应关系，实现对潜在运动目标的连续跟踪。此外，根据匹配相似度建立代价矩阵进行2次数据关联，具有计算量小、可靠性高的优点，可实现算法运行效率与精度的均衡。

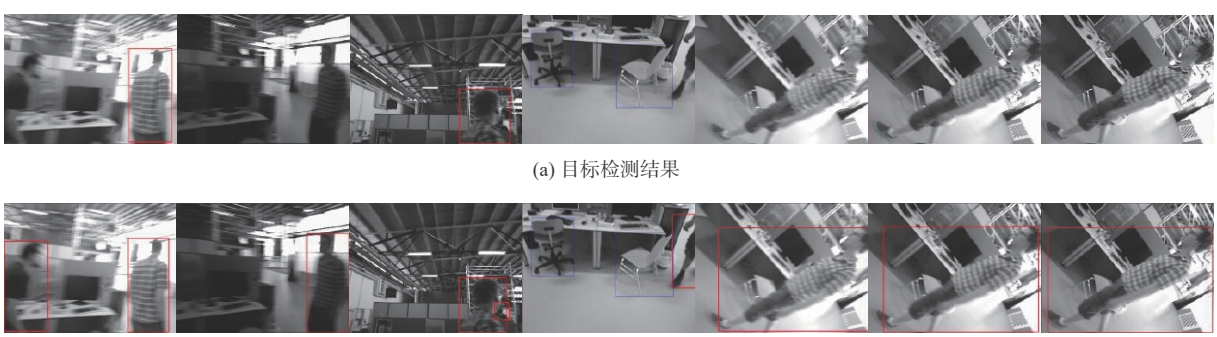
匹配失败的轨迹$\boldsymbol{T}_{\mathrm{um}}^1$可与$\boldsymbol{D}_t^{\mathrm{H}}$再次进行数据关联，删除匹配失败的轨迹$\boldsymbol{T}_{\mathrm{um}}^2$和低分检测框$\boldsymbol{D}_{\mathrm{um}}^{\mathrm{L}}$，再将有效匹配轨迹$\boldsymbol{T}_{\mathrm{m}}^1$和$\boldsymbol{T}_{\mathrm{m}}^2$输入卡尔曼滤波器进行轨迹更新，其更新公式为

$$\boldsymbol{T}_{\mathrm{u}} = \begin{cases} \hat{\boldsymbol{x}}_t = \hat{\boldsymbol{x}}_t^- + K_t(\boldsymbol{z}_t - \boldsymbol{H}_t\hat{\boldsymbol{x}}_t^-) \\ K_t = \boldsymbol{P}_t^- \boldsymbol{H}_t^{\mathrm{T}}(\boldsymbol{H}_t \boldsymbol{P}_t^- \boldsymbol{H}_t^{\mathrm{T}} + \boldsymbol{R}_t)^{-1} \\ \boldsymbol{P}_t = \boldsymbol{P}_t^- - \boldsymbol{P}_t^- K_t \boldsymbol{H}_t \end{cases} \tag{5}$$

式中：K_t为卡尔曼增益权重；$\boldsymbol{H}_t$为尺度转换矩阵；$\boldsymbol{R}_t$为检测噪声协方差矩阵；$\boldsymbol{z}_t$为当前帧的观测向量；输出为轨迹更新后的状态向量$\hat{\boldsymbol{x}}_t$和状态协方差矩阵为$\boldsymbol{P}_t$。

对于未匹配成功的高分检测框$\boldsymbol{D}_{\mathrm{um}}^{\mathrm{H}}$，为其新建一个轨迹，最终得到当前帧的全部跟踪轨迹$\boldsymbol{T}_t$。

图3为上述4种干扰因素和连续三帧检测缺失的检测补偿结果。其中，图3(a)为YOLOX-s的目标检测结果，图3(b)则是引入检测缺失补偿后的检测结果。对比图3(a)和图3(b)可以看出：通过对前后帧之间目标的运动状态进行连续估计，本文算法有效弥补了目标检测中存在的缺失和遗漏，可以更为准确、高效地获取目标对象的位置信息。



(a) 目标检测结果

(b) 检测补偿结果

图3 检测缺失补偿结果

Fig. 3 Results of missed detection compensation

1.2 双类别动态场景处理策略

对目标对象进行有效检测与跟踪，进而获得准确的语义先验信息，再根据特定的语义类别就能够识别出潜在运动目标。然而，现有结合语义信息和几何信息的SLAM算法处理动态目标时大多需要求解大量基础矩阵，算法运行效率难以保证。此

外, 其认为场景内所有运动物体都处于快速或大幅度运动状态, 对环境中微小的运动变化并不敏感, 导致算法在处理不同运动程度的物体时泛化性能不足。

针对此类问题, 本文提出一种基于特征匹配精度的双类别动态场景处理策略, 在图像特征匹配环节, 首先使用 GMS 算法快速筛选得到有效的匹配特征点, 再结合目标检测获得的语义信息计算图像帧间特征匹配精度, 并以此为依据划分该帧的动态程度, 将场景分成高动态和低动态两类。在低动态场景中, 直接使用 GMS 算法过滤异常点, 将筛选得到的匹配点用于相机位姿估计, 该方法不涉及复杂的矩阵分解, 运行速度更快; 在高动态场景中, 通过光流估计结合对极几何约束识别动态点, 再设计对应策略对其进行剔除。

对动态程度不同的场景加以区分, 再分别做针对性处理, 能够节约大量运行时间成本, 同时提升 SLAM 系统在复杂动态场景下的跟踪精度。

1.2.1　特征匹配筛选

GMS 算法遵循运动平滑假设, 即正确匹配的领域内具有运动一致性约束, 如果一个特征匹配点对匹配正确, 那么其周围还有其他特征匹配点对与之形成相互支持。借由像素网格划分候选区域, 统计运动支持度得分, 根据正误匹配概率分布的可分性, 设定阈值判定匹配的精确度, 再根据动态区域和静态区域的运动支持度得分不同, 可有效识别和处理场景中有限的动态特征[18]。

提取 ORB 特征点完毕后, 本文使用 Brute Force 算法进行粗匹配, 为加速特征匹配环节, 舍弃 GMS 原算法的扩展运动核, 忽略旋转变换和尺度变换对匹配精度的影响, 快速筛选并剔除误匹配。再丢弃临近图像边缘和匹配中心 3×3 邻域内存在明显像素差的匹配以优化匹配点候选序列。

设输入两帧图像为$\{I_a, I_b\}$, $C=\{c_1, c_2, \cdots, c_i, \cdots, c_n\}$为图像$I_a$与$I_b$之间所有最近邻特征匹配的集合, 其中, c_i表示特征点a_i和b_i的匹配, 定义c_i的邻域N_i和相似领域S_i分别为

$$N_i=\left\{c_j \mid c_j\in C, c_j\neq c_i, d(a_i,a_j)<r_1\right\} \tag{6}$$

$$S_i=\left\{c_j \mid c_j\in N_i, d(b_i,b_j)<r_2\right\} \tag{7}$$

式中: $d(\cdot,\cdot)$为两点间欧氏距离; r_1和r_2为距离阈值; 定义c_i的运动支持度$|S_i|$, 表示S_i中的匹配点数量。

在处理动态场景时, 如果不存在动态物体或动态物体在连续图像帧间没有明显移动, 则匹配点邻域内运动支持度较高, 相反, 当受到动态物体明显运动的影响时, 邻域内特征匹配误差较大, 使得其支持度较低。因此, 统计邻域内运动支持度$|S_i|$就可以有效区分动态场景下的正误匹配。假设匹配点间相互独立, 则$|S_i|$的概率分布模型近似满足二项分布:

$$|S_i|\sim\begin{cases}B(|N_i|,p_{\mathrm{t}}) & c_i\in T\\ B(|N_i|,p_{\mathrm{f}}) & c_i\in F\end{cases} \tag{8}$$

式中: $B(\cdot,\cdot)$表示二项分布; $|N_i|$为邻域N_i内匹配点数量; p_{t}和p_{f}分别为该邻域内正确匹配和错误匹配的运动支持概率; T和F分别为正确匹配和错误匹配的集合, 该二项分布模型的期望和标准差为

$$E_{|S_i|}=\begin{cases}E_{\mathrm{t}}=|N_i|p_{\mathrm{t}} & c_i\in T\\ E_{\mathrm{f}}=|N_i|p_{\mathrm{f}} & c_i\in F\end{cases} \tag{9}$$

$$S_{|S_i|}=\begin{cases}S_{\mathrm{t}}=\sqrt{|N_i|p_{\mathrm{t}}(1-p_{\mathrm{t}})} & c_i\in T\\ S_{\mathrm{f}}=\sqrt{|N_i|p_{\mathrm{f}}(1-p_{\mathrm{f}})} & c_i\in F\end{cases} \tag{10}$$

实际情况下, 正确匹配数量远大于错误匹配, 根据$|S_i|$的期望和标准差, 计算二者之间的区分度P_i:

$$P_i=\frac{E_{\mathrm{t}}-E_{\mathrm{f}}}{S_{\mathrm{t}}+S_{\mathrm{f}}}=\frac{|N_i|(p_{\mathrm{t}}-p_{\mathrm{f}})}{\sqrt{|N_i|p_{\mathrm{t}}(1-p_{\mathrm{t}})}+\sqrt{|N_i|p_{\mathrm{f}}(1-p_{\mathrm{f}})}} \tag{11}$$

由式 (6) 可得出, $P_i\propto\sqrt{|N_i|}$, 即正误匹配区分度P_i同$\sqrt{|N_i|}$正相关, 说明同一邻域内特征匹配数目越多, 正误匹配间的可区分度就越强, 利用这一特性, 设定阈值τ_i:

$$\tau_i=\alpha\sqrt{|N_i|} \tag{12}$$

式中: α为超参数, 通常取 4～6。如果某一邻域内的运动支持度$|S_i|$大于阈值τ_i, 就认为特征点a_i和b_i是一对正确匹配, 否则认为可能存在大量动态物体的干扰, 删除误匹配。这样既可以消除局部动态区域的不匹配, 又可以提高静态区域的整体匹配质量。

1.2.2　动态场景划分

若场景中存在大量动态信息的干扰, 经 GMS 算法筛选保留的特征匹配点总数和检测框内匹配点数量会明显减少, 匹配点分布均匀程度下降。根据得到的特征匹配筛选结果, 结合目标检测获得的语义先验信息和以下 3 个指标计算当前帧的特征匹配精度, 作为区分场景动态程度的依据。

1) 特征匹配点数量。充足的匹配点可以提供丰富的几何和纹理特征, 有助于提高匹配的准确性和稳定性。因此, 每帧图像获得的匹配点总数应至少为提取特征点总数n的 30%, 并记录当前帧匹配点总数为n_{t}。否则, 认为匹配精度不佳, 先前 GMS 算法滤除了大量误匹配, 环境中可能存在大量的运动干扰, 直接将当前帧划分至高动态类别。

2) 检测框内匹配点数量。实际情况下, 检测框内存在动态点的概率远大于框外背景点。如若受到运动目标的影响, 经 GMS 算法筛选过滤后, 检测

框内会缺少有效的匹配点，得到的少量剩余匹配点也并不可靠。因此，如式 (13) 和式 (14) 所示，根据比例阈值筛选出框内匹配点数量不足的潜在动态框，并对潜在动态框内的匹配点进行计数：

$$f(n_i^{\mathrm{b}}, s_i^{\mathrm{b}}) = \begin{cases} 1 & n_i^{\mathrm{b}}/n_{\mathrm{t}} < s_i^{\mathrm{b}}/2s_{\mathrm{t}} \\ 0 & \text{其他} \end{cases} \tag{13}$$

$$n_{\mathrm{t}}^{\mathrm{b}} = \sum_{i=1}^{n} f(n_i^{\mathrm{b}}, n_i^{\mathrm{b}}) n_i^{\mathrm{b}} \tag{14}$$

式中：n_i^{b}为第i个检测框内匹配点的数量；s_i^{b}和s_{t}分别为第i个检测框的面积和当前帧图像的总面积。理想状态下，检测框内匹配点数目与检测框面积大小成正比，设置阈值为s_i^{b}与s_{t}的比值，如果n_i^{b}与n_{t}的比值小于阈值的1/2，则认为检测框内可能存在大量已被剔除的动态点，将当前检测框标记为潜在动态属性，记录全部此类检测框内匹配点总数$n_{\mathrm{t}}^{\mathrm{b}}$。

3）匹配点分布均匀程度：均匀分布的匹配点可以避免在相同区域内冗余匹配。同时，当某些区域由于运动扰动而无法提供有效匹配时，可以确保其他区域仍有足够的匹配信息，从而提高鲁棒性。此处采用四叉树策略评估匹配点分布均匀程度，将图像划分成大小均匀的4个子区域，式 (15) 和式 (16) 用于根据比例阈值筛选出匹配点过度聚集和分散的异常子区域，并对异常子区域内匹配点进行计数：

$$f(n_i^{\mathrm{r}}, s_i^{\mathrm{r}}) = \begin{cases} 1 & \dfrac{n_i^{\mathrm{r}}}{n_{\mathrm{t}}} > \dfrac{2s_i^{\mathrm{r}}}{s_{\mathrm{t}}} \cup \dfrac{n_i^{\mathrm{r}}}{n_{\mathrm{t}}} < \dfrac{s_i^{\mathrm{r}}}{2s_{\mathrm{t}}} \\ 0 & \text{其他} \end{cases} \tag{15}$$

$$n_{\mathrm{t}}^{\mathrm{r}} = \sum_{i=1}^{n} f(n_i^{\mathrm{r}}, s_i^{\mathrm{r}}) n_i^{\mathrm{r}} \tag{16}$$

式中：n_i^{r}为第i个区域内匹配点的数量；s_i^{r}为第i个区域的面积。理想状态下，划分区域内匹配点数目与该区域图像面积大小成正比，同样将阈值设置为s_i^{r}与s_{t}的比值。

图4中，红色点表示当前帧的匹配点，如果n_i^{r}与n_{t}的比值大于阈值的2倍，则将这一区域判定为聚集区域，图中用绿色对角线标记；如果n_i^{r}与n_{t}的比值小于阈值的1/2，则将这一区域判定为分散区域，图中用蓝色对角线标记。受运动干扰造成的匹配点分布过度聚集和发散会显著影响整体匹配效果，故将上述两类区域内匹配点数目计入$n_{\mathrm{t}}^{\mathrm{r}}$，如已计入$n_{\mathrm{t}}^{\mathrm{b}}$则不再重复统计。反之，则对该区域进行下一次划分，直至理想状态下区域内匹配点数目小于2不再可分。

除去上述异常区域内的匹配点，最后剩余的有效匹配点数目n_{r}为

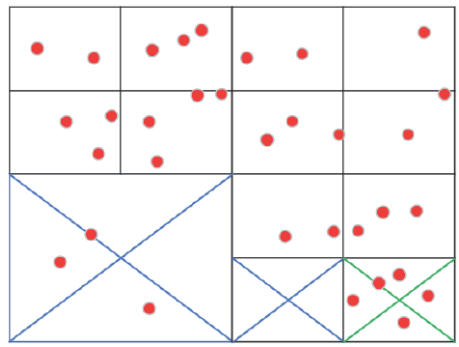


图4 四叉树策略划分图像区域

Fig. 4 Quadtree strategy for dividing image regions

$$n_{\mathrm{r}} = n_{\mathrm{t}} - n_{\mathrm{t}}^{\mathrm{b}} - n_{\mathrm{t}}^{\mathrm{r}} \tag{17}$$

定义当前帧的匹配精确度P，如下：

$$P = n_{\mathrm{r}}/n_{\mathrm{t}} \tag{18}$$

如果$P \geqslant 0.5$，则认为当前帧取得理想的特征匹配效果，场景中只存在轻微的运动干扰，标记当前帧为低动态帧，可以直接将GMS算法得到的匹配结果用于SLAM系统的地图初始化，最小化3D地图点和2D特征点的重投影误差：

$$\boldsymbol{T}_{\mathrm{cw}} = \arg\min_{\boldsymbol{T}} \frac{1}{2} \sum_{i=1}^{n} \| \boldsymbol{x}_i - \pi(\boldsymbol{T}_{\mathrm{cw}} \boldsymbol{p}_i) \|_2^2 \tag{19}$$

式中：

$$\pi\left(\begin{bmatrix} X \\ Y \\ Z \end{bmatrix}\right) = \begin{bmatrix} f_x X/Z + c_x \\ f_y Y/Z + c_y \end{bmatrix} \tag{20}$$

其中：$\boldsymbol{T}_{\mathrm{cw}}$为相机位姿，其李群表示为$\boldsymbol{T}$；$\boldsymbol{x}_i$为2D静态特征点；$\boldsymbol{p}_i$为与$\boldsymbol{x}_i$对应的3D地图点；$\pi(\cdot)$为相机的投影方程；$f_x$和$f_y$为$x$和$y$方向的相机焦距；$(c_x, c_y)$为相机光心坐标。

通过使用李代数，构建无约束的优化问题，利用高斯牛顿法进行迭代求得最优解，可获得准确的相机位姿。

若$P < 0.5$，则认为动态物体对特征匹配环节产生严重干扰，标记当前帧为高动态帧，后续将执行进一步检查。

1.3 引入卡方检验的运动一致性检测

针对筛选得到的高动态帧，采用与低动态帧不同的处理策略：先计算光流金字塔，获取当前帧中匹配的特征点，再利用对极几何约束检测物体与相机运动的一致性。

运动一致性检测的误差项是求解基础矩阵得到的匹配点到对应极线的距离，如果极线距离超过一定范围ε，就认为该点属于动态离群点。

然而，确定合理的约束条件存在难度。如果条件宽松，就不能有效检测出全部动态特征点；而条件严格，就会使原本可以保留的静态特征点被错误

删除。当前的主流方法在设定阈值时通常取 1 像素，但这种固定阈值缺乏灵活性，难以适应复杂多变的现实场景。为有效解决上述问题，本文算法选取当前帧中检测框外的背景点和上一帧的静态点作为样本，组成正态分布模型，并在此基础上引入卡方检验识别动态特征点，确保算法在实际应用中保持准确、高效，同时提升其对不同环境的适应性。

如图 5 所示，假设 O_1 和 O_2 是相机的光心，空间点 X 在图像帧 I_1 中有一个特征点 $\boldsymbol{x}_1$ 与之对应，并与当前帧 I_2 中的特征点 $\boldsymbol{x}_2$ 匹配，其的归一化坐标分别为

$$\begin{cases}\boldsymbol{x}_1=[u_1,v_1,1]\\ \boldsymbol{x}_2=[u_2,v_2,1]\end{cases} \tag{21}$$

式中：u、v 为像素平面的坐标。计算得到当前帧的极线 $\boldsymbol{l}_2$ 为

$$\boldsymbol{l}_2=\boldsymbol{F}\boldsymbol{x}_1=\boldsymbol{F}[u_1,v_1,1]=[\boldsymbol{a},\boldsymbol{b},\boldsymbol{c}] \tag{22}$$

其中：$\boldsymbol{F}$ 为基础矩阵；$\boldsymbol{a}$、$\boldsymbol{b}$、$\boldsymbol{c}$ 为列向量。理想状态下对极几何约束的表达式为

$$\boldsymbol{x}_2^{\mathrm{T}}\boldsymbol{F}\boldsymbol{x}_1=\boldsymbol{x}_2^{\mathrm{T}}\boldsymbol{l}_2=\boldsymbol{0} \tag{23}$$

图中空间点 X 运动至 X'，$\boldsymbol{x}_2'=[u_2',v_2',1]$ 到极线 $\boldsymbol{l}_2$ 距离 d 为

$$d=\frac{|au'_2+bv'_2+c|}{\sqrt{a^2+b^2}}>\varepsilon \tag{24}$$

当前待测点极线距离 d_{c} 和静态样本点极线距离 d_i^{s} 之间的误差项为

$$e_i=\left(d_{\mathrm{c}}-\frac{1}{n}\sum_{i=1}^{n}d_i^{\mathrm{s}}\right)/\sigma \tag{25}$$

式中：n 为样本中的静态点个数；σ 为归一化平面的标准差；误差 e_i 服从一维标准正态分布，根据卡方分布：

$$\mathrm{chsq}(x;k)=\begin{cases}\dfrac{x^{(k/2-1)}\mathrm{e}^{-x/2}}{2^{k/2}\Gamma(k/2)} & x>0\\ 0 & x\leqslant 0\end{cases} \tag{26}$$

式中：k 为卡方分布的自由度；函数 $\Gamma(v)$ 的定义为

$$\Gamma(v)=\int_0^{\infty}\mathrm{e}^{-t}t^{v-1}\mathrm{d}t\quad v>0 \tag{27}$$

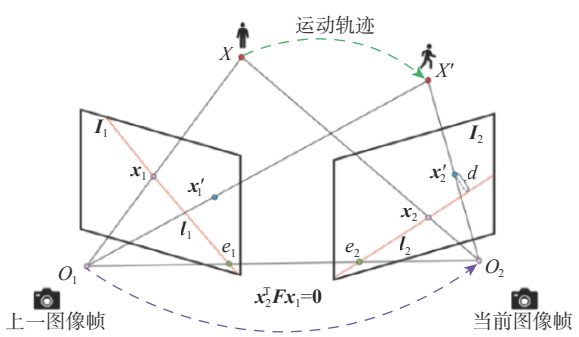


图 5　对极几何约束

Fig. 5　Epipolar geometry constraints

对匹配点对进行对称投影操作，得到 2 组对称极线距离，再计算单次估计结果：

$$\Delta_{\mathrm{d}}=\mathrm{chsq}\left((e_i)^2;2\right) \tag{28}$$

设置 $d_{\mathrm{th}}=\chi^2_{0.05}(2)$，即自由度为 2 的卡方分布在显著性水平为 0.05 时的临界阈值，超过临界阈值的特征点被认为是动态点，此过程计算复杂度较小，且得到的动态特征点相比原方法具有更高的可靠性。

1.4　动态特征剔除策略

经运动一致性检测得到动态特征点，再利用先前获取的语义信息对检测框内的特征点进行进一步处理。为避免直接删除检测框内全部特征点导致 SLAM 系统缺少关键数据而失效，提出一种动态特征剔除策略，最大限度地保留活跃的静态点用于相机位姿初始化。根据检测框内动态特征点的比例设置自适应阈值，可以有效识别不稳定的数据关联，提高系统在处理动态目标干扰时的鲁棒性。

本文算法考虑所有被检测到的目标都可能处于运动状态，如图 6 所示，第 1 行表示由语义模块检测到的检测框；第 2 行是运动一致性检测的结果，动态点被标记为蓝色，静态点被标记为绿色；第 3 行展示了结合语义信息与几何约束的动态特征剔除效果。

算法 1　动态特征剔除。

输入：人类检测框 B_n^{H}，其他类检测框 B_n^{O}，当前帧特征点集合 P_n，当前帧动态特征点集合 P_n^{d}。

输出：静态特征点集合 S_n。

1. $S_n\leftarrow P_n$
2. for each $B_n^{\mathrm{H}}(i)$ in B_n^{H} do
3. $s_h\leftarrow$特征点 P_n 总数 in $B_n^{\mathrm{H}}(i)$
4. $o_h\leftarrow$动态特征点 P_n^{d} 总数 in $B_n^{\mathrm{H}}(i)$
5. if $s_h>0.25o_h$ then
6. $S_n\leftarrow S_n\backslash B_n^{\mathrm{H}}(i)$
7. else
8. for each 特征点 (u_n,v_n) in $B_n^{\mathrm{H}}(i)$ do
9. for each 动态特征点 (du_n,dv_n) in $B_n^{\mathrm{H}}(i)$ do
10. if (u_n,v_n) in $B_n^{\mathrm{H}}(i)$ and(du_n,dv_n) in $B_n^{\mathrm{H}}(i)$ and $\sqrt{(u_n-du_n)^2+(v_n-dv_n)^2}\leqslant 15$ then
11. $S_n\leftarrow S_n\backslash(u_n,v_n)$
12. end if
13. end for
14. end for
15. end if
16. end for
17. for each $B_n^{\mathrm{O}}(i)$ in B_n^{O} do
18. $s\leftarrow$特征点 P_n 总数 in $B_n^{\mathrm{O}}(i)$



(a) 图像帧1 (b) 图像帧2 (c) 图像帧3 (d) 图像帧4 (e) 图像帧5 (f) 图像帧6 (g) 图像帧7

图 6 动态特征剔除结果

Fig. 6 Results of dynamic feature culling

19. $o \leftarrow$动态特征点P_n^{d}总数 in $B_n^{\mathrm{O}}(i)$

20. if $s > 0.3o$ then

21. $S_n \leftarrow S_n \backslash B_n^{\mathrm{O}}(i)$

22. end if

23. end for

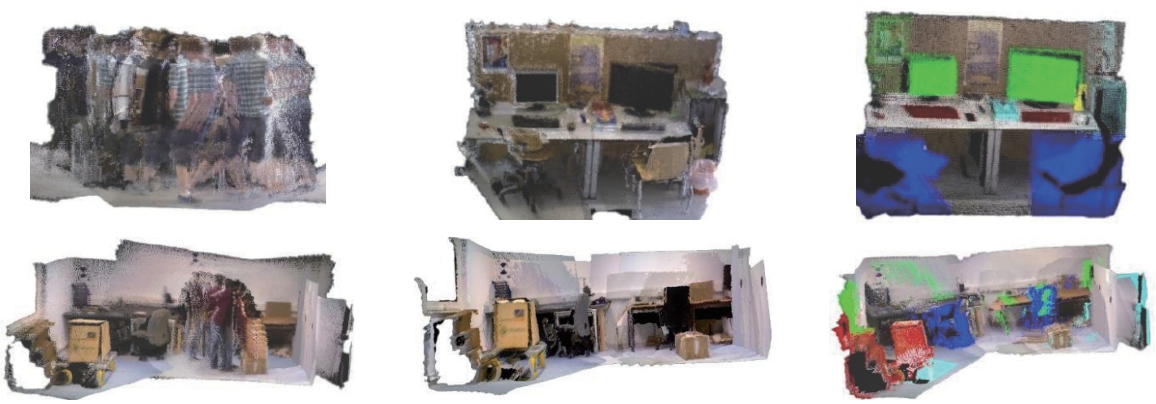
动态特征剔除流程如算法 1 所示，如果检测框内的动态特征点超过框内特征点总数的 30%，则标记检测框为动态，删除框内所有特征点。如图 6(a)～图 6(c) 所示，视角内动态人框内特征点被有效检测和移除。对于人类这类可以进行局部运动的非刚性物体，删除动态点和以其为中心，半径为 15 像素的圆域内的其他特征点，保留其余的静态点，若最初的动态点比例超过 25% 就舍弃整个检测框。本文算法只移除同时存在于静态框外和动态框内的特征点，从图 6(b)～图 6(e) 可以看出，当动态人框和静态显示器框出现重叠时，在保留显示器框内的特征点的基础上，再移除其余的动态点。此外，本文算法能够识别图 6(f)～图 6(g) 中视角内出现的不完整目标及其语义类别并准确去除动态离群点。

此策略不需要预先定义对象类的运动属性，对于不同的对象类具有一致的鲁棒性。设置百分比阈值允许算法根据不同的检测框自动调整可容忍的动态异常点个数，从而有效应对遮挡，提升动态框判别的准确性。

1.5 稠密重建

为获取详细的环境特征信息，帮助机器人更好地理解环境，本文算法在 ORB-SLAM3 基础上增设用于稠密重建的并行线程。与跟踪线程不同，在地图构建环节，移除关键帧中所有潜在动态目标检测框内的像素区域，再对局部点云进行变换和合并，以获得只包含场景静态信息的全局点云地图。此外，利用 YOLOX-s 获取关键帧中目标对象的语义标签和检测框位置信息，并将其投影至对应的点云空间，赋予三维点云二维图像的语义信息。通过附加的语义信息，机器人能够精确辨识环境中物体的类别，有助于其执行更复杂的任务规划和决策。

在 TUM 和 BONN 数据集中各选择一个图像序列验证地图重建效果如图 7 所示。如图 7(a) 所示，ORB-SLAM3获得的稠密地图中，移动的人产生大量的重影，覆盖大量其他场景信息，而本文算法能



(a) 初始点云 (b) 静态点云 (c) 语义点云

图 7 稠密点云重建结果

Fig. 7 Results of dense point cloud reconstruction

够获得清晰的静态点云 (见图 7(b)), 生成的语义地图 (见图 7(c)) 对场景中的静态物体进行标注, 可用于机器人后续执行物体识别、路径规划等高级任务。

2　本文算法

本文算法步骤如下:

步骤 1　初始化。选择相机模式, 输入 RGB 图像和深度图像。

步骤 2　目标检测获取语义先验, 并对目标检测缺失进行补偿。

1) 目标检测。将 RGB 图像输入 YOLOX-s 目标检测网络, 输出包含检测框的置信度、语义类别及坐标信息的当前帧中目标检测结果 $\boldsymbol{D}$。

2) 轨迹预测。输入 $\boldsymbol{D}$ 中潜在运动目标的检测结果 $\boldsymbol{D}_t$ 进行目标跟踪, 根据式 (1) 利用卡尔曼滤波器进行轨迹预测, 获得预测结果 $\boldsymbol{T}_{\mathrm{p}}$。

3) 检测缺失判定。根据式 (3) 计算检测框 D_i 与预测框 P_i 匹配相似度, 判断相似度是否小于设定阈值, 若是, 即认为出现检测缺失, 使用预测框作为当前帧的目标检测结果进行检测缺失补偿。

4) 数据关联。建立代价矩阵 $\boldsymbol{I}_{\mathrm{oU}}(\boldsymbol{D},\boldsymbol{P})$, 使用匈牙利算法进行 2 次数据关联, 使得当前帧总体匹配相似度最大, 输出有效匹配轨迹 $\boldsymbol{T}_{\mathrm{m}}^{1}$ 和 $\boldsymbol{T}_{\mathrm{m}}^{2}$。

5) 轨迹更新。输入有效匹配轨迹 $\boldsymbol{T}_{\mathrm{m}}^{1}$ 和 $\boldsymbol{T}_{\mathrm{m}}^{2}$, 根据式 (5) 利用卡尔曼滤波器进行轨迹更新, 输出全部跟踪轨迹 $\boldsymbol{T}_t$。

步骤 3　特征匹配筛选。依据式 (6)～式 (12) 由 GMS 算法快速筛选过滤粗匹配结果 $\boldsymbol{C}$, 获得有效匹配 $\boldsymbol{C}_{\mathrm{t}}$。

步骤 4　动态场景划分。结合步骤 2 获得的目标检测结果 $\boldsymbol{D}$ 与步骤 3 获得的特征匹配筛选结果 $\boldsymbol{C}_{\mathrm{t}}$ 计算特征匹配精度 P_r, 根据特征匹配精度 P_r 将图像帧划分为低动态帧和高动态帧。

1) 判断是否满足 $n_{\mathrm{t}} < 0.3n$, 若是, 则划分当前帧为高动态帧; 否则转至步骤 2)。

2) 判断是否满足 $\dfrac{n_i^{\mathrm{b}}}{n_{\mathrm{t}}} < \dfrac{s_i^{\mathrm{b}}}{2s_{\mathrm{t}}}$, 若是, 则对满足条件的 n_i^{b} 计数为 $n_{\mathrm{t}}^{\mathrm{b}}$, 转至步骤 3); 否则, 不进行计数, 转至步骤 3)。

3) 判断是否满足 $\dfrac{n_i^{\mathrm{r}}}{n_{\mathrm{t}}} > \dfrac{2s_i^{\mathrm{r}}}{s_{\mathrm{t}}} \cup \dfrac{n_i^{\mathrm{r}}}{n_{\mathrm{t}}} < \dfrac{s_i^{\mathrm{r}}}{2s_{\mathrm{t}}}$, 若是, 则对满足条件的 n_i^{r} 计数为 $n_{\mathrm{t}}^{\mathrm{r}}$, 转至步骤 4); 否则, 不进行计数, 转至步骤 4)。

4) 依据式 (17) 和式 (18), 获得匹配精度 P_r, 判断是否满足 $P_r \geqslant 0.5$, 若是, 则划分当前帧为低动态帧, 将有效匹配点 C_{t} 作为当前帧静态点集合 S_n; 否则, 划分当前帧为高动态帧。

步骤 5　运动一致性检测。将步骤 4 获得的高动态帧输入 LK 光流, 获得光流特征点, 依据式 (21)～式 (28) 利用引入卡方分布的对极几何约束判断光流特征点是否与相机运动具有一致性, 若是, 则判定该点为静态点; 否则, 判定该点为动态点。

步骤 6　动态特征剔除。对于高动态帧, 依据算法 1 输入步骤 2 获得检测框 B_n 和步骤 5 获得的动态点集合 P_n^{d}, 输出当前帧静态点集合 S_n。

步骤 7　稠密重建。输入步骤 4 和步骤 6 得到的静态点集合 S_n, 经跟踪线程、局部建图线程和稠密重建线程处理, 生成具有全局一致性的稠密点云地图。

3　实验测试

为全面评估本文 SLAM 算法的综合性能, 使用绝对轨迹误差 (absolute trajectory error, ATE) 和相对位姿误差 (relative pose error, RPE) 作为参考指标, 其的均方根误差 (root mean squared error, RMSE) 和标准差 (standard deviation, S.D.) 反映算法的精度和可靠性。

首先, 在广泛使用的 3 个公开数据集上测试跟踪精度; 随后, 进行消融实验, 验证基线算法外其他各单一模块的有效性; 最后, 进行运行时长分析, 并在包含动态对象的现实场景中评估所提出算法的实时性能。

本文算法的实验平台是一台运行环境为 Ubuntu 20.04 的笔记本电脑, CPU 型号为 Intel i9, GPU 型号为 Nvidia Geforce RTX 4060 Laptop, 运行内存 RAM 为 32 GB。

3.1　室内场景测试

为充分检验本文 SLAM 算法在室内动态场景中的表现, 在本项实验中, 使用 TUM RGB-D 数据集[19] 对比本文算法与 ORB-SLAM3[14] 及其他集成目标检测网络的先进动态 SLAM 算法, 包括 Crowd-SLAM[11]、SG-SLAM[12] 和 OVD-SLAM[13]。

TUM RGB-D 数据集由慕尼黑工业大学计算机视觉小组在不同的室内场景中使用 Microsoft Kinect 传感器记录的 39 个序列组成, 同时包含轨迹真值和相机参数信息。实验选用其中针对动态场景任务的 4 个高动态序列和 4 个低动态序列进行实验分析。其中, “walking” 属于高动态序列, 展示了 2 个人在办公桌周围行走的场景, 旨在评估视觉 SLAM 算法处理在场景中大量快速移动的动态对象的能力。“sitting” 属于低动态序列, 描述了 2 个人坐在办公桌前交谈的情形, 旨在评估视觉 SLAM 算法处理缓慢移动的动态对象的能力。“half, rpy,

static, xyz”则表示相机沿不同方向的运动。

为避免不同的实验设备对结果产生额外影响，所有实验数据均源自本文所搭建的实验平台，利用每个算法ATE的RMSE和S.D.以评估其全局一致性和稳定性，并利用平移和旋转RPE的RMSE和S.D.评估其局部定位精度和鲁棒性。

如表1～表3所示，本文算法在“sitting”低动态序列中平均定位精度最高，由于设计了区分场景动态程度的策略，更多的图像帧被分类为低动态场景，因此保留了更多有利于跟踪的特征点，仅在fr3/s/xyz中精度略低于ORB-SLAM3。在“walking”高动态序列中，动态对象的运动范围和幅度较大，本文算法有效地剔除了大量动态特征点，ATE和RPE均较ORB-SLAM3有明显下降，平均提升超过90%。本文算法在fr3/w/rpy序列的ATE和RPE高于OVD-SLAM，主要原因可能是相机视角转换较大造成特征匹配精度下降，同时场景中人的运动方向与极线方向相似，导致算法有不同程度的退化。但总体而言，本文算法的综合实验结果优于其他算法，所有序列的平均精度达到了最先进的水平。

表1 TUM数据集绝对轨迹误差结果

Table 1 Results of ATE on TUM dataset m

序列	RMSE					S.D.				
	ORB-SLAM3[14]	ORB-SLAM3[11]	ORB-SLAM3[12]	ORB-SLAM3[13]	本文算法	ORB-SLAM3[14]	ORB-SLAM3[11]	ORB-SLAM3[12]	ORB-SLAM3[13]	本文算法
fr3/s/half	0.032 5			0.022 6	**0.019 6**	0.012 9			0.011 7	**0.011 0**
fr3/s/rpy	0.022 8			0.035 5	**0.020 6**	0.014 6			0.025 9	**0.009 5**
fr3/s/static	0.007 9	0.008 5	0.008 0	0.006 5	**0.006 3**	0.003 9	0.004 6	0.004 0	0.002 9	**0.002 8**
fr3/s/xyz	**0.009 4**	0.016 4	0.012 9	0.012 8	0.011 6	**0.004 6**	0.008 9	0.006 7	0.008 8	0.007 2
fr3/w/half	0.191 5	0.023 7	0.022 7	0.019 2	0.018 9	0.069 2	0.011 3	0.012 6	**0.009 1**	0.009 9
fr3/w/rpy	0.562 7	0.060 9	0.046 0	**0.032 4**	**0.034 2**	0.211 0	0.042 1	0.030 1	**0.018 0**	0.019 0
fr3/w/static	0.027 8	0.007 4	0.007 6	0.006 6	**0.006 3**	0.022 1	0.003 5	0.004 1	0.003 1	**0.002 9**
fr3/w/xyz	0.395 7	0.017 3	0.015 0	0.014 5	**0.013 5**	0.151 8	0.009 6	0.008 3	**0.006 9**	**0.006 9**

注：每个序列的最优结果用粗体突出显示，次优结果用下划线突出显示。

表2 TUM数据集平移漂移结果

Table 2 Results of translational drifton TUM dataset m

序列	RMSE					S.D.				
	ORB-SLAM3[14]	ORB-SLAM3[11]	ORB-SLAM3[12]	ORB-SLAM3[13]	本文算法	ORB-SLAM3[14]	ORB-SLAM3[11]	ORB-SLAM3[12]	ORB-SLAM3[13]	本文算法
fr3/s/half	**0.007 8**			0.016 6	0.014 1	**0.004 2**			0.009 6	0.008 7
fr3/s/rpy	0.013 6			0.019 1	**0.009 7**	0.009 2			0.013 8	**0.005 5**
fr3/s/static	0.005 8	0.006 0	0.009 0	0.005 7	**0.004 9**	0.003 1	0.003 1	0.004 7	0.002 9	**0.002 5**
fr3/s/xyz	**0.008 4**	0.014 1	0.011 9	0.012 0	0.009 6	**0.004 3**	0.008 5	0.006 3	0.007 9	0.005 5
fr3/w/half	0.337 3	0.019 3	0.018 0	**0.013 8**	**0.013 8**	0.190 8	0.011 5	0.011 1	**0.007 4**	0.008 0
fr3/w/rpy	0.863 2	0.042 2	0.030 3	**0.020 1**	0.021 1	0.457 0	0.030 5	0.023 5	**0.012 0**	0.012 5
fr3/w/static	0.040 5	0.007 4	0.007 7	**0.005 6**	0.006 0	0.031 0	0.003 8	0.004 3	**0.002 7**	0.003 2
fr3/w/xyz	0.607 5	0.015 2	0.013 8	0.013 0	**0.012 2**	0.370 4	0.009 5	0.008 1	0.007 1	**0.006 7**

注：每个序列的最优结果用粗体突出显示，次优结果用下划线突出显示。

表3 TUM数据集旋转漂移结果

Table 3 Results of rotational drifton TUM dataset m

序列	RMSE					S.D.				
	ORB-SLAM3[14]	ORB-SLAM3[11]	ORB-SLAM3[12]	ORB-SLAM3[13]	本文算法	ORB-SLAM3[14]	ORB-SLAM3[11]	ORB-SLAM3[12]	ORB-SLAM3[13]	本文算法
fr3/s/half	**0.981 6**			1.034 6	1.001 4	**0.446 8**			0.493 4	0.499 7
fr3/s/rpy	0.955 2			1.046 8	**0.894 7**	0.451 1			0.533 9	**0.438 5**
fr3/s/static	0.384 6	0.351 8	0.327 7	0.335 3	**0.313 1**	0.167 5	0.161 9	**0.149 7**	0.157 6	0.153 3
fr3/s/xyz	0.606 8	0.694 1	0.628 2	0.668 1	**0.600 9**	0.311 5	0.322 6	0.320 1	0.349 8	**0.308 8**
fr3/w/half	6.930 9	1.223 4	1.019 0	0.926 2	**0.880 8**	4.138 8	0.652 8	0.540 3	**0.425 8**	0.455 7
fr3/w/rpy	15.564 7	2.077 1	1.342 6	**0.984 2**	1.066 3	9.287 3	1.246 7	0.748 2	**0.504 9**	0.564 9
fr3/w/static	0.658 0	0.312 2	0.308 6	0.279 8	**0.265 7**	0.431 1	0.138 0	0.139 1	**0.121 7**	0.122 3
fr3/w/xyz	9.083 1	0.659 0	0.663 2	0.631 8	**0.615 4**	6.001 5	0.333 1	0.348 5	0.325 6	**0.321 9**

注：每个序列的最优结果用粗体突出显示，次优结果用下划线突出显示。

图 8 展示了本文算法与 ORB-SLAM3 的轨迹估计结果和轨迹真值的对比。相较于 ORB-SLAM3, 在图 8(a)～图 8(d) 所示的低动态场景中, 本文算法跟踪精度有一定程度的提升。更为显著的是, 图 8(e)～图 8(h) 中可以直观地看出, 本文算法大幅降低了高动态场景下 ORB-SLAM3 的轨迹跟踪误差。

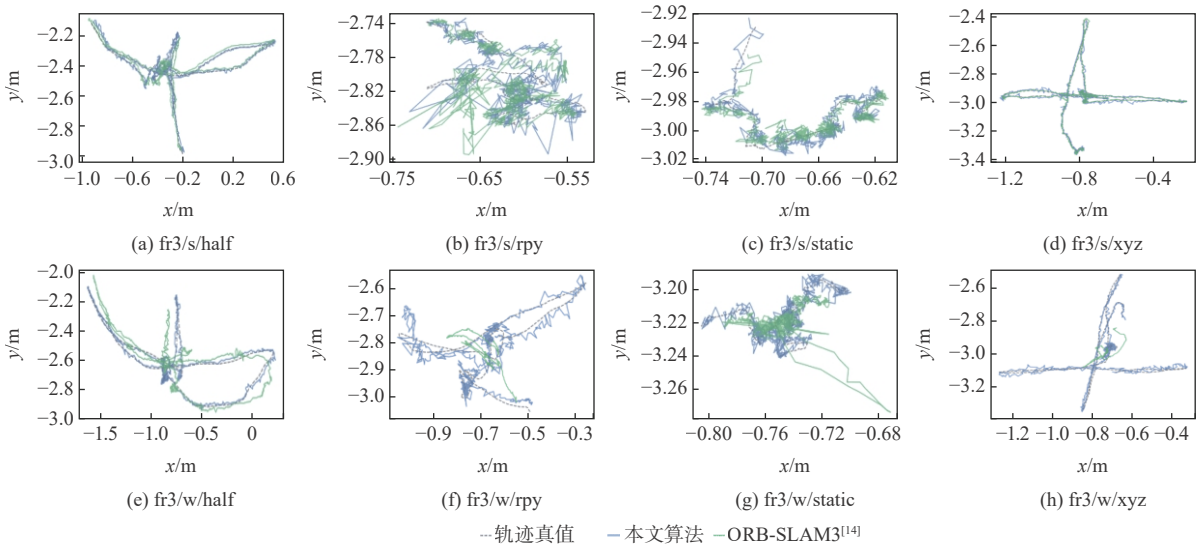


图 8　TUM 数据集轨迹对比

Fig. 8　Comparison of trajectories on TUM dataset

为进一步评估本文算法在包含大量动态物体的室内复杂环境中的性能, 使用 BONN RGB-D 数据集[20] 将本文算法同 ORB-SLAM3、Crowd-SLAM、SG-SLAM 和 OVD-SLAM 进行对比。

BONN RGB-D 数据集由波恩大学在 2019 年发布, 使用 ASUS Xtion Pro LIVE 相机获取图像, Optitrack Prime 13 运动捕捉系统记录轨迹真值, 其中包含 24 个高动态序列, 序列格式与 TUM RGB-D 数据集相同。与 TUM 数据集相比, BONN 数据集中的动态场景更具挑战性。选择其中具有代表性的 7 个序列进行测试, 其中“crowd”序列是 5 个人在房间里随机行走的场景。“moving no box”序列展示了 1 个人把 1 个盒子从地面搬到桌子上的过程。“person tracking”序列是摄像机追踪 1 个行走的人的场景。

表 4 记录了上述 SLAM 算法的 ATE, 结果表明, 本文算法在大多数测试序列中优于同类算法, 特别是在存在高密度动态物体的 3 个“crowd”序列中, 与 ORB-SLAM3 相比, 定位精度提升幅度超过 95% 展现出超过 95% 的显著提升。这不仅再次证明了本文算法在动态场景下达到了先进的精度, 还验证了其通用性。如图 9 所示, 在图 9(a)～图 9(c) 表示的“crowd”序列中, ORB-SLAM3 受到多个行走的人的干扰, 导致大量图像帧跟踪丢失; 在图 9(f)～图 9(g) 表示“person tracking”序列中, 相机视角跟随行走的人进行转换, 导致其位姿产生了连续的错误估计, 从而使得估计轨迹与真值相比存在明显误差和漂移。相比之下, 本文算法能够获得比 ORB-SLAM3更为准确的估计轨迹, 进一步证明了本文算法出色的场景泛化能力。

表 4　BONN 数据集绝对轨迹误差结果

Table 4　Results of ATE on BONN dataset　　m

序列	RMSE					S.D.				
	ORB-SLAM3[14]	ORB-SLAM3[11]	ORB-SLAM3[12]	ORB-SLAM3[13]	本文算法	ORB-SLAM3[14]	ORB-SLAM3[11]	ORB-SLAM3[12]	ORB-SLAM3[13]	本文算法
crowd	0.331 7	0.017 0	0.018 7	0.016 9	**0.015 3**	0.211 3	0.008 6	0.008 6	0.008 0	**0.006 5**
crowd2	1.488 5	0.033 3	0.032 2	0.025 9	**0.019 4**	0.595 8	0.019 9	0.021 1	0.019 2	**0.009 4**
crowd3	0.459 3	0.039 8	0.028 9	0.021 8	**0.020 2**	0.221 9	0.022 0	0.017 9	0.012 0	**0.010 5**
move_no_box	0.325 6	**0.012 8**	0.017 7	0.013 7	0.013 8	0.154 0	**0.006 0**	0.012 5	0.006 8	0.006 4
move_no_box2	0.038 2	0.024 0	**0.019 0**	0.023 0	0.021 5	0.016 9	0.011 1	0.008 5	0.008 5	**0.008 2**
person_tracking	0.561 1	0.034 3	0.031 1	0.036 0	**0.026 4**	0.229 9	0.020 4	0.014 9	0.014 9	**0.013 0**
person_tracking2	0.753 8	0.034 6	0.034 3	0.034 9	**0.032 0**	0.416 9	**0.011 7**	0.012 2	0.013 0	0.012 4

注: 每个序列的最优结果用粗体突出显示, 次优结果用下划线突出显示。

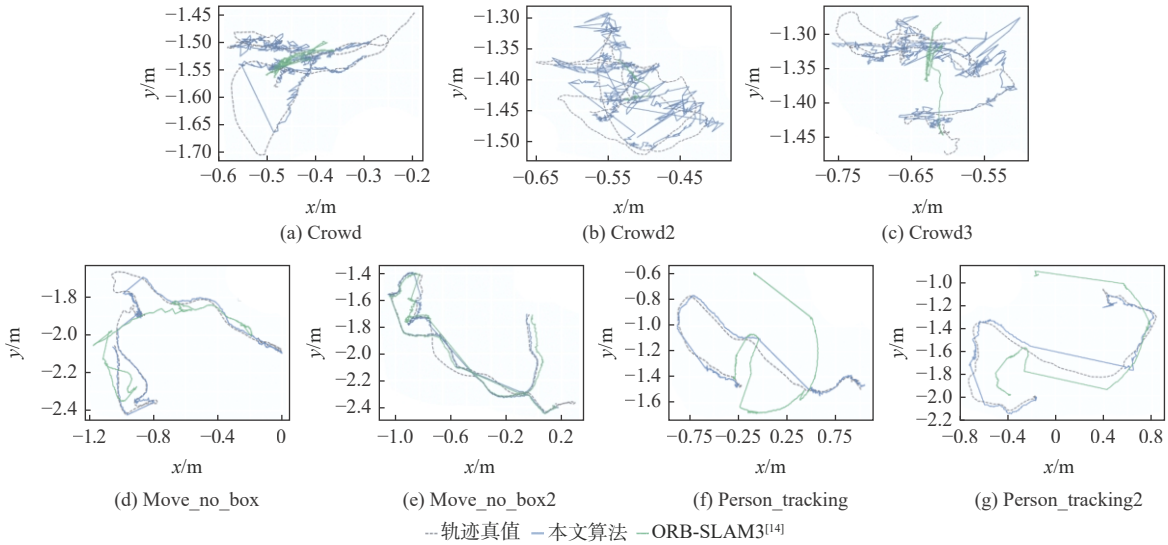


图 9 BONN 数据集轨迹对比

Fig. 9 Comparison of trajectories on BONN dataset

3.2 室外场景测试

为充分检验本文 SLAM 算法室外动态场景中的表现，将其同先进的室外双目 SLAM 算法 DynaSLAM[7]、DOT-SLAM[21]、DynaSLAM Ⅱ[22] 进行对比，使用 KITTI 数据集[23] 中包含地面轨迹真值的双目图像序列 00-10 进行测试。

KITTI 数据集是一个广泛用于移动机器人和自动驾驶研究的基准测试集，由卡尔斯鲁厄理工学院和丰田汽车北美信息中心联合开发。其收录了多种真实世界的驾驶场景，包括城市、乡村和高速公路环境，提供了丰富的场景变化，可用于完成各种挑战性任务。

表 5 列出了各种算法 ATE 的 RMSE，本文算法在其中 7 个序列中表现为最优或次优，相比 ORB-SLAM3，本文算法在大多数序列表现更为出色，结果验证了本文算法能够有效提升室外动态场景下 SLAM 算法的跟踪精度，各序列的绝对轨迹误差减小 15%～25%。同时，在同 DynaSLAM、DOT-SLAM、DynaSLAM Ⅱ 的比较中发现，在图像序列 01、02 和 08 中，由于受到深度阴影和光照不均的影响，特征提取与匹配质量不佳，导致本文算法竞争力不足，除此之外，都能获得比较优秀的结果。

表 5 KITTI 数据集绝对轨迹误差的均方根误差结果

Table 5 Results of RMSE for ATE on KITTI dataset

m

序列	ORB-SLAM3[14]	DynaSLAM[7]	DOT-SLAM[21]	DynaSLAM Ⅱ[22]	本文算法
00	**0.96**	1.4	1.18	1.29	**0.96**
01	11.89	9.4	**1.33**	2.31	7.50
02	4.81	6.7	1.04	**0.91**	3.56
03	**0.29**	0.6	1.00	0.69	0.38
04	0.18	0.2	1.00	1.42	**0.15**
05	**0.39**	0.8	1.14	1.34	0.46
06	0.71	0.8	1.07	**0.19**	0.37
07	0.43	0.5	1.00	3.10	**0.41**
08	3.08	3.5	**1.24**	1.68	2.73
09	1.62	1.6	3.89	5.02	**1.06**
10	1.11	1.2	**1.02**	1.30	1.23

注：每个序列的最优结果用粗体突出显示。

3.3 消融实验

为系统评估各个模块对算法整体性能的影响，逐一去掉或修改 SLAM 算法中新增的模块，运行 TUM 数据集进行测试对比。其中，W/O-GMS 表示不区分场景的动态程度，全部视作高动态场景；W/O-MCC 表示室内高动态环境下，预先定义人类为唯一动态类，直接剔除动态框内的所有特征点；W/O-DAT 表示不进行目标检测和跟踪，在没有语

义先验的情况下, 只使用对极几何约束处理动态特征。

表 6 记录了上述 4 组不同配置下运行 TUM 数据集得到的 ATE 结果, 分析实验结果可知: W/O-GMS 对环境中物体的轻微运动容忍度不高, 将图像序列中所有帧视作高动态进行处理, 导致在低动态序列误差较大。W/O-MCC 对大部分的测试序列产生消极影响, 由于无法识别除人外的其他运动对象, 算法直接剔除人框内的全部特征点, 与人框重叠的其他框内点也被消除, 舍弃过多特征点使算法缺乏足够的特征点进行有效跟踪。W/O-DAT 在低动态场景表现优秀, 与之相反的是, 在高动态场景中, 由于对极几何约束通常基于场景中的大部分特征点为静态的假设, 缺少语义信息划分潜在动态区域, 无法有效区分所有动态特征点, 导致应对复杂的高动态场景的性能欠佳。

表 6　不同配置的绝对轨迹误差结果

Table 6　Results of ATE with different configurations　　m

序列	RMSE				S.D.			
	本文算法	W/O-GMS	W/O-MCC	W/O-DAT	本文算法	W/O-GMS	W/O-MCC	W/O-MCC
fr3/s/half	0.0196	0.056 5	0.031 6	**0.019 1**	0.0110	0.042 3	0.016 8	**0.008 7**
fr3/s/rpy	**0.020 6**	0.030 8	0.033 9	0.0212	**0.009 5**	0.020 9	0.025 0	0.0133
fr3/s/static	**0.006 3**	0.007 7	0.007 4	0.0068	**0.002 8**	0.004 0	0.003 4	0.0034
fr3/s/xyz	0.011 6	0.013 0	**0.009 3**	0.0104	0.007 2	0.006 7	**0.005 2**	0.0054
fr3/w/half	**0.018 9**	0.024 2	0.0234	0.027 9	**0.009 9**	0.014 0	0.0125	0.012 7
fr3/w/rpy	**0.034 2**	0.0415	0.044 9	0.054 6	**0.019 0**	0.0232	0.027 0	0.034 2
fr3/w/static	**0.006 3**	0.0082	0.008 3	0.014 7	**0.002 9**	0.0039	0.003 9	0.007 2
fr3/w/xyz	0.0135	**0.013 3**	0.014 2	0.019 2	0.0069	**0.006 8**	0.006 8	0.009 5

注: 每个序列的最优结果用粗体突出显示, 次优结果用下划线突出显示。

3.4　运行效率测试

除算法跟踪精度外, 算法的运行速度也至关重要, 为确保算法能即时响应场景变化, 从而满足实时运行的应用需求, 需要对算法运行效率进行测试。不同算法运行 TUM 数据集的每帧平均跟踪时间和所用硬件平台如表 7 所示, DynaSLAM 和 DS-SLAM 采用语义分割网络, 高计算成本使得跟踪时间较长。相比较而言, 本文算法基于 TensorRT 部署目标检测和跟踪算法, 保持模型精度的同时大幅提升了运行效率。与同样使用单阶段目标检测算法的 Crowd-SLAM、SG-SLAM 和 OVD-SLAM 相比, 本文算法提出了更为全面的动态特征抑制策略且进行目标检测缺失补偿, 由于算法复杂度有所增加, 时间成本略有增加。与 W/O-GMS 相比, 本文算法引入双类别动态场景处理策略, 快速过滤低动态帧中的误匹配, 有效提升低动态场景下算法整体运行效率。与原算法 ORB-SLAM3 相比, 本文算法增设了语义线程和稠密建图线程, 平均每帧要增加约 13 ms 的运行时间, 但仍然可以满足机器人的实时性需求。

表 7　不同算法的运行时间比较

Table 7　Runtime comparison of different systems

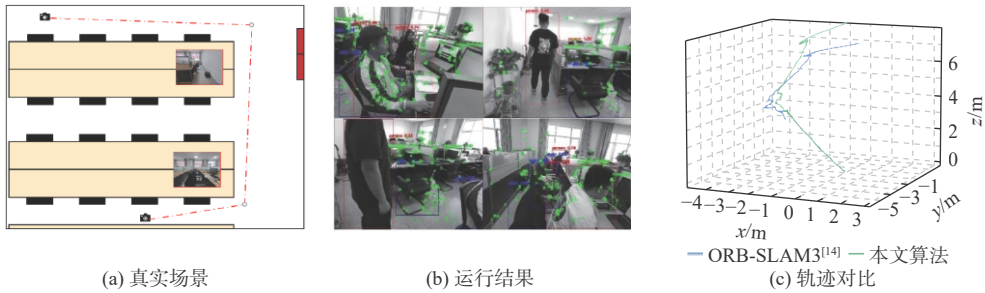
算法	每帧跟踪时间/ms	实验平台
本文算法	28.20～29.96	Intel i9, Nvidia RTX 4060 laptop
DynaSLAM	>350	CPU, Nvidia Tesla M40 GPU
DS-SLAM	59.4	Intel i7, P4000 GPU
ORB-SLAM3	20.24～22.79	Intel i9, Nvidia RTX 4060 laptop
ORB-SLAM3	27.61～29.77	Intel i9, Nvidia RTX 4060 laptop
ORB-SLAM3	20.68～23.35	Intel i9, Nvidia RTX 4060 laptop
W/O-GMS	30.22～32.67	Intel i9, Nvidia RTX 4060 laptop
ORB-SLAM3	14.32～17.58	Intel i9

3.5　真实场景测试

为进一步评估本文 SLAM 算法的实时性能, 在一个真实的实验室场景中设计一个包含不同动态程度的实时测试。实验室面积约为 8 m×6 m。手持 Intel RealSense D455 相机以分辨率为 640×480 和帧率为 30 帧/s 获取输入数据。

在实验过程中, 手动旋转并移动相机, 在房间里手持相机行走。图 10(a) 为步行路线俯视图, 红色虚线表示相机的运动轨迹。图 10(b) 可以观察到有人在镜头前行走, 其身上的动态特征点被精确识别并剔除。还有人坐在椅子上交谈, 做着随机的动作, 其中处于静止状态的人身上的特征点得以有效保留。运行结果表明, 本文 SLAM 算法根据实时输入快速响应, 准确判定物体的运动状态, 并对存在的动态特征进行针对性处理, 相机轨迹跟踪稳定, 在真实场景下具有良好的实时性。

图 10(c) 中 ORB-SLAM3 的估计轨迹在高动态



(a) 真实场景 (b) 运行结果 (c) 轨迹对比

图 10 真实场景实验

Fig. 10 Real scene experiment

场景中出现了明显的漂移，而本文算法的估计轨迹与真实轨迹更为相似，这一结果证明本文算法能够提升相机位姿估计精度，有效应对动态环境带来的挑战。

4 结 论

1）本文提出一种面向动态场景实时视觉SLAM算法，在室内和室外环境均可有效运行，适配单目、双目、RGB-D多种相机，能够有效处理一般性场景中有限的动态物体。

2）本文算法利用多目标跟踪算法对YOLOX-s获取的语义信息进行缺漏检补偿，实现目标检测算法效率与精度的平衡。

3）本文算法基于图像帧间特征匹配精度划分场景的动态程度，增强其在复杂动态场景下的适应能力。在低动态场景中，利用GMS算法快速筛选并剔除误匹配，节约大量计算成本；在高动态场景中，引入卡方检验进行运动一致性检测，不依赖语义先验识别动态异常点，设置自适应阈值判定检测框运动属性，有效剔除动态特征点，同时最大限度地保留静态特征点，以增加稳定特征点的数量，实现鲁棒的高精度跟踪。

4）本文算法使用公开数据集TUM、BONN及KITTI进行性能评估，实验结果表明，本文算法在动态环境中的综合性能优于大多数现有其他算法。此外，真实场景测试进一步证明本文算法在现实环境中的有效性和实时性。

参考文献（References）

[1] Davison A J, Reid I D, Molton N D, et al. MonoSLAM: real-time single camera SLAM[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(6): 1052-1067.

[2] Mur-Artal R, Tardós J D. ORB-SLAM2: an open-source SLAM system for monocular, stereo, and RGB-D cameras[J]. IEEE Transactions on Robotics, 2017, 33(5): 1255-1262.

[3] Klein G, Murray D. Parallel tracking and mapping for small AR workspaces[C]//Proceedings of the 2007 6th IEEE and ACM International Symposium on Mixed and Augmented Reality. Piscataway: IEEE Press, 2007: 225-234.

[4] Cheng J Y, Wang C Q, Meng M Q H. Robust visual localization in dynamic environments based on sparse motion removal[J]. IEEE Transactions on Automation Science and Engineering, 2020, 17(2): 658-669.

[5] Dai W C, Zhang Y, Li P, et al. RGB-D SLAM in dynamic environments using point correlations[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(1): 373-389.

[6] Du Z J, Huang S S, Mu T J, et al. Accurate dynamic SLAM using CRF-based long-term consistency[J]. IEEE Transactions on Visualization and Computer Graphics, 2022, 28(4): 1745-1757.

[7] Bescos B, Fácil J M, Civera J, et al. DynaSLAM: tracking, mapping, and inpainting in dynamic scenes[J]. IEEE Robotics and Automation Letters, 2018, 3(4): 4076-4083.

[8] Yu C, Liu Z X , Liu X J, et al. DS-SLAM: a semantic visual SLAM towards dynamic environments[C]//Proceedings of the 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems. Piscataway: IEEE Press, 2018: 1168-1174.

[9] 王浩, 卢德玖, 方宝富. 动态环境下基于增强分割的RGB-D SLAM方法[J]. 机器人, 2022, 44(4): 418-430.
Wang H, Lu D J, Fang B F. RGB-D SLAM method based on enhanced segmentation in dynamic environment[J]. Robot, 2022, 44(4): 418-430 (in Chinese).

[10] 齐浩, 付悦欣, 胡祝华, 等. 基于自适应阈值和速度优化的轻量化语义VSLAM方法[J]. 北京航空航天大学学报, 2025, 51(7): 2562-2572.
Qi H, Fu Y X, Hu Z H, et al. A lightweight semantic VSLAM approach based on adaptive thresholding and speed optimization[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(7): 2562-2572(in Chinese).

[11] Soares J C V, Gattass M, Meggiolaro M A. Crowd-SLAM: visual SLAM towards crowded environments using object detection[J]. Journal of Intelligent & Robotic Systems, 2021, 102(2): 50.

[12] Cheng S H, Sun C H, Zhang S J, et al. SG-SLAM: a real-time RGB-D visual SLAM toward dynamic scenes with semantic and geometric information[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 7501012.

[13] He J M, Li M R, Wang Y Y, et al. OVD-SLAM: an online visual SLAM for dynamic environments[J]. IEEE Sensors Journal, 2023, 23(12): 13210-13219.

[14] Campos C, Elvira R, Rodriguez J J G, et al. ORB-SLAM3: an accurate open-source library for visual, visual-inertial, and multimap SLAM[J]. IEEE Transactions on Robotics, 2021, 37(6): 1874-1890.

[15] Ge Z, Liu S T, Wang F, et al. YOLOX: exceeding YOLO series in 2021[EB/OL]. V2. arXiv (2021-08-06)[2021-08-06]. https://doi.org/10.48550/arXiv.2107.08430.

[16] Aharon N, Orfaig R, Bobrovsky B Z. BoT-SORT: robust associations multi-pedestrian tracking[EB/OL]. (2022-07-07)[2022-07-26]. https://doi.org/10.48550/arXiv.2206.14651.

[17] Bian J W, Lin W Y, Liu Y, et al. GMS: grid-based motion statistics for fast, ultra-robust feature correspondence[J]. International Journal of Computer Vision, 2020, 128(6): 1580-1593.

[18] Liu G H, Zeng W L, Feng B, et al. DMS-SLAM: a general visual SLAM system for dynamic scenes with multiple sensors[J]. Sensors, 2019, 19(17): 3714.

[19] Sturm J, Engelhard N, Endres F, et al. A benchmark for the evaluation of RGB-D SLAM systems[C]//Proceedings of the 2012 IEEE/RSJ International Conference on Intelligent Robots and Systems. Piscataway: IEEE Press, 2012: 573-580.

[20] Palazzolo E, Behley J, Lottes P, et al. ReFusion: 3D reconstruction in dynamic environments for RGB-D cameras exploiting residuals [C]//Proceedings of the 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems. Piscataway: IEEE Press, 2019: 7855-7862.

[21] Ballester I, Fontán A, Civera J, et al. DOT: dynamic object tracking for visual SLAM[C]//Proceedings of the 2021 IEEE International Conference on Robotics and Automation. Piscataway: IEEE Press, 2021: 11705-11711.

[22] Bescos B, Campos C, Tardós J D, et al. DynaSLAM II: tightly-coupled multi-object tracking and SLAM[J]. IEEE Robotics and Automation Letters, 2021, 6(3): 5191-5198.

[23] Geiger A, Lenz P, Urtasun R. Are we ready for autonomous driving? The KITTI vision benchmark suite[C]//Proceedings of the 2012 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2012: 3354-3361.

A real-time visual SLAM algorithm for complex dynamic scenarios

ZHAO Boting[1]，LIU Jun[1,*]，CHAI Hongxu[2]，ZHANG Jianye[1]，WU Ruibin[1]

(1. School of Mechanical and Electrical Engineering，Lanzhou University of Technology，Lanzhou 730050，China；
2. Gansu Province Special Equipment Inspection and Testing Institute，Lanzhou 730050，China)

Abstract：Simultaneous localization and mapping (SLAM) systems frequently have a number of issues in general or sophisticated dynamic scenarios with dynamic objects, including strong assumptions, inadequate positioning precision, or even failure. To solve these problems, a real-time visual SLAM algorithm for complex dynamic scenarios is proposed, which is built on ORB-SLAM3. The algorithm deploys YOLOX-s based on accelerated model inference to obtain semantic prior information to process dynamic objects, and the Kalman filter and Hungarian algorithm are combined to compensate for missing object detection. A two-category dynamic scenario processing strategy is proposed based on the grid-based motion statistics (GMS) feature matching algorithm to rapidly screen reliable matching points, which separates the scenarios into two categories based on the image matching accuracy, in order to enhance the positioning accuracy and generalization ability of the algorithm. For low dynamic frames, the GMS algorithm is used to quickly filter out dynamic features, so as to avoid a large number of matrix operations and improve operational efficiency. For high dynamic frames, the Chi-square test is utilized to identify motion outliers, and a dynamic feature culling strategy is proposed to cull dynamic points according to the adaptive threshold and keep the tracking stability. The experimental results on standard datasets and real scenarios show that the algorithm effectively addresses the real-time localization challenges, demonstrating its superior accuracy, robustness and real-time performance in complex indoor and outdoor dynamic scenarios.

Keywords：visual SLAM; dynamic object; deep learning; object detection; scenario classification

Received：2024-09-05；**Accepted**：2024-11-07；**Published Online**：2024-12-03 12：14

URL：link.cnki.net/urlid/11.2625.V.20241203.0904.002

Foundation items：National Natural Science Foundation of China (71861025); Independent Research and Development Project of Gansu Provincial Department of Science and Technology (22YF11GA315)；Science and Technology Support Project of Lanzhou (2024-8-46)

* **Corresponding author**. E-mail：lzhjliu@126.com

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0635

基于支持向量机的飞行任务识别和动作划分

李博雯[1,2]，雷小永[1,2,*]

(1. 北京航空航天大学 虚拟现实技术与系统全国重点实验室，北京 100191；
2. 北京航空航天大学 自动化科学与电气工程学院，北京 100191)

摘 要：民航飞行训练质量评估逐渐向定量化、智能化方向发展。为满足其对飞行任务识别提出的新需求，提出一种基于支持向量机(SVM)的民航飞行任务识别和动作划分方法。对民航飞行参数进行收集与预处理，用于后续飞行任务识别与动作划分；使用支持向量机模型对民航飞行任务进行识别。传统方法通过航迹图像进行识别，但由于缺少时序特征，起飞和降落识别准确率较低。为解决这一问题，将*xyz*坐标转化为RGB图像，引入时间序列特征，并加入数值通路以反映数据绝对值。对比传统航迹图像识别、RGB图像识别、RGB图像与数值通路结合识别的实验结果，发现使用RGB图像与数值通路结合的方法，识别准确率提升了43%，能够有效提高绕地标转弯和矩形航线识别准确率。此外，根据飞行任务识别结果，将各项任务划分为起飞、降落、爬升、下降、巡航、爬升转弯、下降转弯、巡航转弯、盘旋9类飞行动作，为后续的飞行训练质量评估研究提供了支持。

关 键 词：支持向量机；飞行任务识别；飞行动作划分；飞行训练质量评估；数据预处理
中图分类号：TP391.7
文献标志码：A **文章编号**：1001-5965(2026)11-4090-08

近年来，中国航空工业不断发展，对飞行员的需求量逐渐增加，传统飞行学院训练质量的评估由飞行教官给出，该评价方法主观性强，极易出现评价错误[1]。随着人工智能的发展，使用机器辅助甚至代替飞行教官进行飞行训练评价成为飞行训练的发展方向，而飞行任务的识别是飞行训练质量评估的重要基础，飞行任务识别的准确率关乎后续评价的正确与否。通过飞参数据进行飞行动作识别是目前较为常用的方法，由于飞参数据复杂庞大，传统基于飞行规则的方法依靠飞行规则进行飞行任务的划分，所需时间长且难以做到模型的泛化。近年来，机器学习在识别和分类领域取得了巨大成就，使用机器学习进行飞行任务识别成为未来发展的方向[2-3]。

目前针对飞行器的任务识别主要集中在战机机动动作识别方面，主要有人工识别、基于专家经验库的识别[4]、支持向量机(support vector machine, SVM)、随机森林模型[5]、动态贝叶斯网络[6]、逻辑回归[7]等方法。

麻省理工学院的研究员[8]使用简单统计度量、随机森林模型、套袋树、简单决策树、支持向量机、逻辑回归和卷积神经网络，对飞行数据进行了初步“好”和“坏”的分类，数据分类准确率达到97.8%，但该方法只对飞行数据进行初步好坏筛选，无法进行飞行任务准确识别。张夏阳等[9]根据法向过载数据的趋势从飞行数据中提取机动片段，并用迭代自组织数据分析技术(iterative self-organizing data analysis techniques, ISO-DATA)聚类将机动片段分

收稿日期：2024-09-02；**录用日期**：2024-10-30；**网络出版时间**：2024-11-04 17:29
网络出版地址：link.cnki.net/urlid/11.2625.V.20241104.1537.002
基金项目：国家重点研发计划(2018AAA0102902)
*通信作者. E-mail：leixy@buaa.edu.cn

引用格式：李博雯，雷小永. 基于支持向量机的飞行任务识别和动作划分[J]. 北京航空航天大学学报，2026，52(11)：4090-4097.
Li B W，Lei X Y. Flight task recognition and action segmentation based on SVM[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52(11)：4090-4097 (in Chinese).

类, 对不同大小的飞行数据进行实验, 该方法识别准确率达到 89% 以上。孟光磊等[10] 使用基于动态贝叶斯网路的方法, 先对飞参数据特征进行归纳, 建立由决策层、速度层、航向层和高度层构成的动态贝叶斯网络模型, 能够实现飞行动作在线识别, 但该方法需要大量样本训练, 且模型参数需由人工给定。针对飞行训练数据中飞行训练识别完备性不高的问题, Lu 等[11] 提出了一种基于欧氏距离的多变量子序列搜索双窗口算法(multivariate subsequence search with double windows, MSDW), 该算法能够成功识别单个飞行训练科目, 与传统基于增量时间规整的流式模式匹配算法 (streaming pattern recognition using incremental time warpinG, SPRING) 相比, 在识别飞行训练科目上的完备性更高, 可以满足工程应用的需求。

SVM 是基于统计学原理的小样本分类器, 在飞行任务识别方面具有良好的表现。杨俊等[12] 使用模糊支持向量机的方法对飞行动作进行了识别, 各项飞行任务识别准确率在 27%～100%。Feng 等[13] 将状态匹配与 SVM 方法相结合, 在进行识别前对飞行数据进行状态匹配, 加快了 SVM 识别的速度。为了解决 SVM 方法在大样本条件下计算速度慢、无法实时识别的问题, 徐西蒙等[14] 提出了一种基于运动分解和层次支持向量机 (hierarchical support vector machine, H-SVM) 的机动识别方法, 利用 v-SVM 二分类器构造 H-SVM 多分类器, 结合运动分解思想, 提出从不同方向对目标机动动作进行分解识别的方法。

目前针对民航飞行的任务识别及动作划分研究较少, 相较于军用战机, 民用飞行器动作变化较平缓, 用于识别的飞参数据特征不够明确, 其动作识别算法要求更为精细。本文针对民航飞行的特点, 选取起飞、降落、绕地标转弯、矩形航线 4 类飞行任务进行识别及动作划分。首先, 对获取的飞参数据进行预处理, 保证其能够用于后续计算。然后, 通过支持向量机模型对飞行任务进行识别分类。最后, 根据民航飞行特点, 将飞行任务细分为 9 类飞行动作。

1　飞参数据获取及预处理

CCAR-61 部对飞机类别飞行技能共提出 14 条要求[15], 综合考虑《飞机飞行指南》对飞行科目的要求[16], 选取正常起飞、降落、矩形起落航线、绕地标转弯 4 类飞行任务进行识别。使用 X-Plane 飞行模拟器, 对波音 737-800 飞机进行飞行模拟。从飞机进入地面跑道起飞端开始至任务结束, 每 0.5 s 记录一组数据, 包括: 时间、xyz 这 3 个方向的位移, 用于初步评估飞行任务类别; 速度、俯仰、滚转、偏航角度、油门、襟翼指令、起落架、副翼、方向舵, 用于后续飞行训练质量评估。

1.1　飞行坐标系转换

从飞行模拟器中获取飞机 x,y,z 三轴坐标数值是在某固定惯性坐标系下产生的绝对值, 会受到机场环境、起飞跑道等环境位置影响, 因此, 需要对飞行坐标系进行转换, 使不同任务飞机起始点均为原点, x 轴方向均为起飞跑道所在方向。

从飞行模拟器中获得数据: 飞机在初始地轴系任意时刻的位置坐标 x_i,y_i,z_i,其中, x_0,y_0,z_0 为飞机初始位置, 飞机初始航迹偏角 χ(即飞机起飞跑道与原始坐标系的 x_k 轴之间的夹角)。由于不同机场条件不同, 为统一飞机航迹坐标系, 将原始航迹坐标系 $Ox_ky_kz_k$ 原点平移至 (x_0,y_0,z_0), 并绕 Oz_k 轴顺时针旋转 χ 角(从 z_k 轴正向看), 得到归一化后的航迹坐标系 $O'x'_ky'_kz_k$, 如图 1 所示。其公式如下[17]:

$$\begin{cases} x_k = x_i - x_0 \\ y_k = y_i - y_0 \\ z_k = z_i - z_0 \end{cases} \tag{1}$$

$$\begin{cases} x'_k = x_k\cos\chi + y_k\sin\chi \\ y'_k = x_k\sin\chi - y_k\cos\chi \end{cases} \tag{2}$$

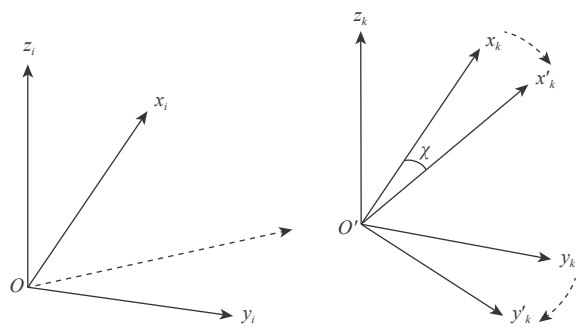


图 1　坐标系转换示意

Fig. 1　Coordinate system conversion diagram

1.2　飞行数据重采样

飞机执行各种任务的时间存在差异, 而从飞行模拟器中获取的数据为固定时间间隔, 因此得到的数据长度并不统一, 为满足后续使用支持向量机进行任务识别, 需要对数据进行重采样, 使其长度一致。给定重采样后飞行数据长度为 l_s, 实际得到飞行数据长度为 l_t, 通过比较 l_s 和 l_t 的大小, 当实际数据长度小于需要长度时, 进行上采样, 在固定间隔内使用线性插值法增加数据; 当实际间隔长度大于需要长度时, 进行下采样, 间隔几个数值取一次样本, 并在固定间隔内删除数据。

每 0.5 s 采集一次数据, 起飞、降落、矩形航线、

绕地标转弯4类飞行任务数据长度在200～1 000，选定重采样的目标长度为800，即$l_s=800$。比较实际数据x_k'的长度l_t和l_s，当$l_t>l_s$时，两者相除计算商q和余数r，即$l_t=l_sq+r$，并将实际长度与上述余数相除，即$m=l_t/r$，每间隔$q-1$取一次数据，每间隔$m-1$剔除一组会取到的数据，也就是在将原始数据长度减小到原来的$1/q$的同时，均匀剔除r组数据，最终得到数据长度即为l_s；当$l_t<l_s$时，将剔除改为加入前后两组数据均值即可。重采样后数据尺的长度可能为l_s,l_s+1,l_s-1这3种情况，因此，需要在最后进行检查，若为l_s+1，则去掉最后一组数据；若为l_s-1则复制最后一组数据添加至末尾。重采样算法流程如图2所示，其中，i,j为循环次数，初始值均为0，t为重采样控制量，用于判断相应数据点的保留或舍弃，D为新坐标系下的三维坐标数据。

对重采样前后误差进行定量定性分析。计算采样前后各项误差如表1所示，可见采样前后数据误差保持在2位数以内，而飞参数据数量级保持在4～5位，该重采样方法的误差与原始数据相比占比不超过2%，不影响后续飞行任务识别。

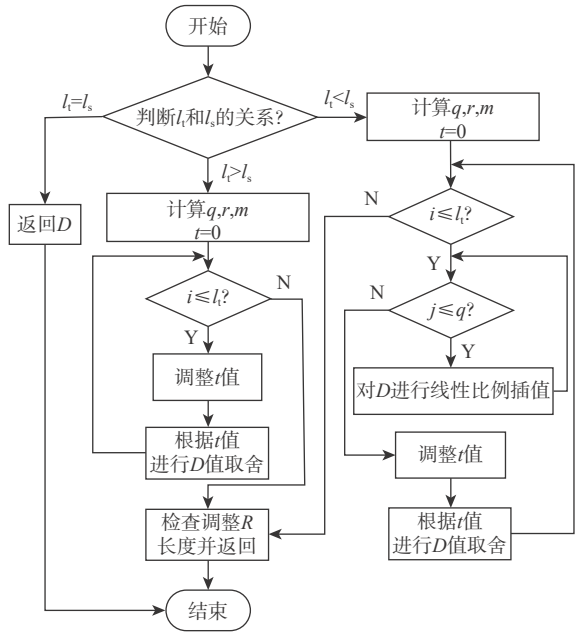


图2 飞行数据重采样流程

Fig. 2 Flowchart of flight data resampling

表1 各项飞行任务下的重采样误差

Table 1 Resampling error of each flight mission

飞行任务	平均绝对误差	均方根误差	最大绝对误差
矩形航线	0.737	3.558	22.996
绕地标转弯	1.797	5.440	22.006
起飞	1.421	3.730	11.678
降落	3.625	12.576	45.320

对比重采样前后数据绘制三维飞行航迹，如图3所示，可见重采样前后飞机航迹图像基本重合，该重采样方法不会导致飞行航迹任务出现改变，不影响飞行任务识别。但该方法可能会导致飞机航迹在特定拐点或起降端点的数据丢失，导致飞行动作界限的区分不准确，因此，重采样后的数据仅用于飞行任务识别。后续研究中对飞行动作的划分需要使用原始数据进行，以保证划分结果的准确。

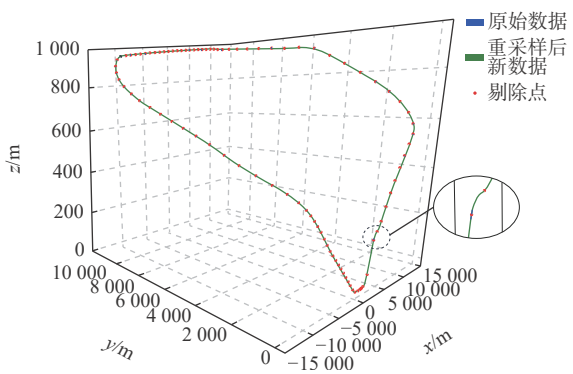


图3 重采样前后飞行航迹对比

Fig. 3 Comparison of flight trajectories before and after resampling

1.3 均值模糊处理

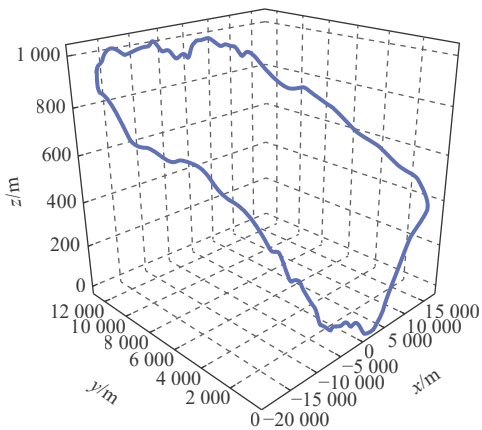
由于飞行过程中会出现风切变等干扰，飞行数据会有较小的波动，而这种波动会导致动作划分的不准确，因此，可以使用均值模糊的方法对数据进行处理，在保证数据整体趋势不变的条件下，去除较小的波动值。为了保证飞参数据在全过程中变化平缓稳定，滤除小波动，需要取一个时间段，对这个时间段内全部飞参数据计算平均值。同时，为保证数据量充足，需要根据数据量大小，选取合适间隔，每间隔固定长度计算一次均值，计算式如下：

$$p'=\frac{1}{n}\left(\sum_{i=m}^{m+n}p_i\right)\qquad m=1,1+c,1+2c,\cdots \tag{3}$$

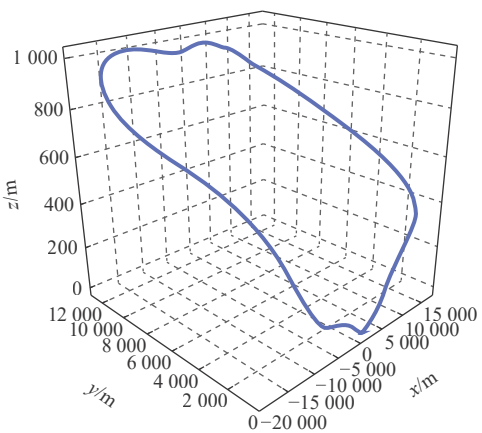
式中：p_i为处理前飞参数据；p'为处理后的飞参数据；n为所选时间段内的数据长度；c为间隔长度。

所用时间段内数据长度n及间隔长度c可以根据采集间隔时间确定，本文取$n=50,c=5$，即每间隔5组数据，取其后面50组数据的平均值组成一组新数据。使用新的数据进行动作划分，可以在保证数据量的基础上避免因数据波动产生的划分错

误, 所用具体间隔数据及平均数据可以根据采集间隔时间确定, 处理前后数据对比如图 4 所示。



(a) 均值模糊处理前矩形航线任务航迹



(b) 均值模糊处理后矩形航线航迹

图 4　均值模糊处理前后对比

Fig. 4　Comparison of mean values before and after mean fuzzy processing

2　飞行任务识别

2.1　支持向量机模型

SVM 模型是机器学习领域中计算简单、应用较为广泛的方法, 依据监督学习的基本策略, 使学习机追求结构化风险最小, 提高了泛化能力, 同时达成了置信范围和经验风险最小化[18], 因此, SVM 方法不需要很多样本, 就可以得到较好的统计规律, 常用于解决样本容量较小、非线性、数据维度较高的问题[19]。本文需要根据飞机 *xyz* 三轴坐标识别飞机所执行的任务, 并且数据样本容量较小, 因此, SVM 模型在识别飞行任务方面优势较大。

SVM 方法的原理是通过核函数 $K(\boldsymbol{s}_i,\boldsymbol{s}_j)$将样本从高维非线性空间映射到低维线性空间, 进而寻找合适的超平面对映射后的样本进行分类。

对于给定样本 $\boldsymbol{s}$, 有超平面:

$$g(\boldsymbol{s})=\boldsymbol{w}^{\mathrm{T}}\boldsymbol{s}+b=0 \tag{4}$$

式中: $\boldsymbol{w}$ 为系数; b 为截距。通过式 (4) 可以计算出每个点到达分类超平面的距离, 假设数据集中的一个点 $O(x_1,x_2,\cdots,x_i,\cdots,x_n)$, x_i为第 i 个变量, n 为维度。距离计算式如下:

$$d=\frac{|\boldsymbol{w}^{\mathrm{T}}\boldsymbol{S}+b|}{\|\boldsymbol{w}\|} \tag{5}$$

式中: $\boldsymbol{S}=[x_1,x_2,\cdots,x_i,\cdots,x_n]^{\mathrm{T}}$; $\|\boldsymbol{w}\|$为超平面范数。

搜寻所有支持向量计算距离, 并对所有符合条件的超平面对应距离进行比较, 保留最大距离对应的超平面, 即 $\frac{2}{\|\boldsymbol{w}\|}$最大时的 $\boldsymbol{s}$ 和 b。目标函数如下:

$$\arg\max\left\{\min\left(y\left(\boldsymbol{w}^{\mathrm{T}}\boldsymbol{s}+b\right)\right)\frac{1}{\|\boldsymbol{w}\|}\right\} \tag{6}$$

其中, y 可以取 1 或−1, 为数据点的标签。当样本点相对于平面在正方向, y 取 1, 样本点相对于平面在负方向, y 取−1, 可以保证计算结果“几何距离”的正数性, 即通过 y 取值正负保证分类正确性。

通过计算最终得到最优分类函数为

$$f(\boldsymbol{s})=\mathrm{sgn}(\boldsymbol{w}^{*}\boldsymbol{s}+b^{*})=\mathrm{sgn}\sum_{i=1}^{n}[\alpha_i^{*}y_i(\boldsymbol{s}_i\cdot\boldsymbol{s})+b^{*}] \tag{7}$$

式中: $\alpha_i>0$为拉格朗日乘子, α_i^{*}为最优解; b^{*}为分类阈值。

由式 (7) 可见, 对于待预测样本, 只需计算其与支持向量的内积$(\boldsymbol{s}_i\cdot\boldsymbol{s})$即可。

对于非线性空间样本, 若$\boldsymbol{\phi}(\boldsymbol{s})$是通过非线性映射后, 样本 $\boldsymbol{s}$ 在新的空间中的特征向量。对于上述内积$(\boldsymbol{s}_i\cdot\boldsymbol{s})$的计算就转变为新空间中的内积, 即 $\boldsymbol{\phi}(\boldsymbol{s}_i)^{\mathrm{T}}\boldsymbol{\phi}(\boldsymbol{s}_j)$。引入核函数:

$$K(\boldsymbol{s}_i,\boldsymbol{s}_j)=\boldsymbol{\phi}(\boldsymbol{s}_i)^{\mathrm{T}}\boldsymbol{\phi}(\boldsymbol{s}_j) \tag{8}$$

即通过在原始空间中计算$K(\boldsymbol{s}_i,\boldsymbol{s}_j)$的值, 就能得到新空间中的内积, 最终分类函数为

$$f(\boldsymbol{s})=\mathrm{sgn}(\boldsymbol{w}^{*}\boldsymbol{s}+b^{*})=\mathrm{sgn}\sum_{i=1}^{n}[\alpha_i^{*}y_iK(\boldsymbol{s}_i\cdot\boldsymbol{s})+b^{*}] \tag{9}$$

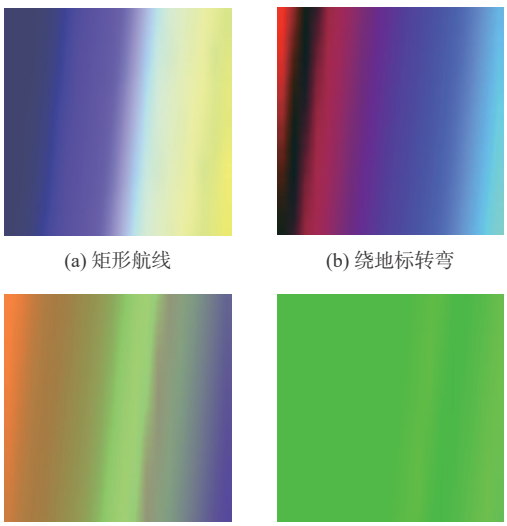
核函数对样本数据集实现了由低维到高维的映射过程, 并在未经过任何变换的低维空间中通过计算函数值得到样本在映射后复杂空间中的内积, 从而能通过式 (9) 进一步找出理想中的分类面, 可见核函数的选择对于非线性支持向量机的构建非常重要。尤其对于实际场景中那些表现出非线性的分类任务, 通过核函数的引入便能够解决这类问题, 从而使模型的泛化能力得到极大提升。目前常用的核函数主要有线性核、多项式核 (d 为多项式的阶数)、高斯核、拉普拉斯核、Sigmoid 核 5 种。

2.2　飞行任务识别

传统飞行任务识别中使用飞行航线图像作为样本进行识别训练, 但该方法在图像上无法反映数据的时序特征, 导致分类识别的准确率并不高。利

用飞行坐标三维特性，将不同时刻3个方向坐标分别作为不同像素点的RGB值绘制图像，并将绘制的图像作为样本输入，该方法可以在保存坐标数据完整性的前提下提高识别效率。

图像RGB数据范围为0～255，而飞行数据从零开始但最大值不确定，因此，可以将飞行数据最大值缩放为255，并将其他数据均按比例进行缩放，保证所有飞行数据范围在0～255。根据重采样后的长度l_s绘制$m\cdot n$图像，对m,n的具体数值不做要求，只需满足$m\cdot n=l_s$。本文取$l_s=800$，在此处可取$m=40,n=20$，构造RGB图像如图5所示。



(a) 矩形航线　(b) 绕地标转弯　(c) 起飞　(d) 降落

图5　不同飞行任务RGB图像

Fig. 5　RGB images of different flight tasks

由于在坐标向RGB图像转化过程中对坐标进行了放缩，坐标绝对值数据会丢失。为解决这一问题，在基础SVM分类上加入数值通路，将坐标数据绝对值的最值、方差、平均值作为新特征，输入SVM分类器中，最后将2个SVM分类器结果进行综合得到最终分类结果，如图6所示。

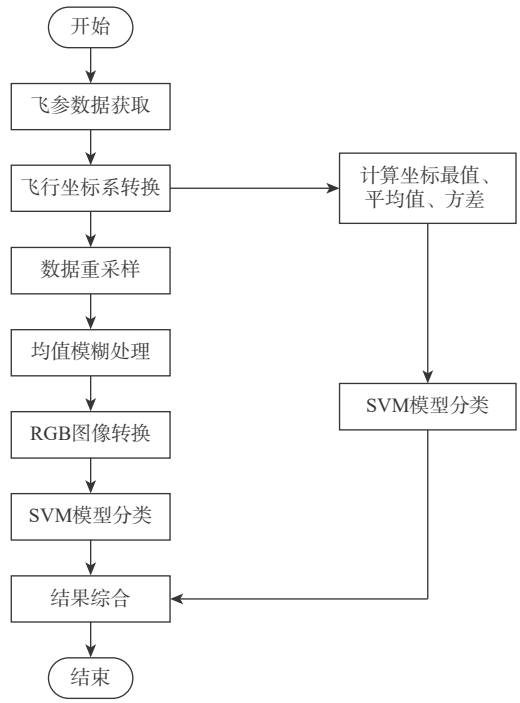


图6　飞行任务识别算法流程

Fig. 6　Algorithm flowchart of flight task identification

2.3　实验结果及分析

实验运行环境基于windows10 64位操作系统，Python 3.10.9实现。

为了验证本文方法的有效性，将传统未处理的航迹图像分类、预处理后的RGB图像分类、加入数值通路的RGB图像分类3种方法进行对比，将全部样本的80%作为训练集，20%作为测试集，得到结果如表2所示。可见，使用RGB图像并加入数值通路的方法识别准确率提升了0.43。

表2　分类结果对比

Table 2　Comparison of classification results

分类方法	飞行任务	精确率	召回率	F1值	准确率
传统航迹图像	绕地标转弯	0.14	1.00	0.25	0.48
	矩形航线	1.00	0.90	0.95	
	降落	0	0	0	
	起飞	0	0	0	
RGB图像	绕地标转弯	0.23	1.00	0.38	0.71
	矩形航线	1.00	0.78	0.88	
	降落	1.00	0.50	0.67	
	起飞	1.00	0.60	0.75	
RGB图像+数值通路	绕地标转弯	0.50	0.33	0.40	0.91
	矩形航线	1.00	1.00	1.00	
	降落	1.00	0.88	0.93	
	起飞	0.71	1.00	0.83	

由表 2 可见, 传统方法识别准确率极低, 由于传统航迹图像无法反映时间特征, 只能识别飞机航迹, 而起飞、降落在航迹图像中表现相似, 无法有效识别, 这 2 类飞行任务识别的精确率、召回率及 F1 值均为 0; 对于绕地标转弯的识别精确率极低, 主要原因是三维航迹图像中无法很好地反映航迹矩形特征, 与绕地标转弯识别存在一定的混淆。通过调整样本数据类型可以发现, 使用航迹图像进行识别时, 随着样本量的增大, 识别准确率有所增加。使用文献 [8] 中提供的飞行任务航迹图像样本进行识别, 结果表明, 在大样本条件下, 航迹图像识别准确率可以达到 0.60 以上。但由于该方法缺少时序特征、丢失部分坐标特征, 识别准确率无法得到更大提升。

使用处理后的 RGB 图像进行识别, 该方法相对于航迹图像识别准确率有极大提升。由于 RGB 像素点的位置可以在一定程度上反映时间特征, 因此, 对于起飞、降落任务的识别效果有所提升, 识别精确率达到 1, 但召回率不高; 对于绕地标转弯和矩形航向的识别效果与航迹图像相比相差不大, 在精确率上略有提升。该方法引入了部分时间特征, 因此, 在识别时间序列影响较大的降落与起飞时有较大提升, 但 RGB 数据范围在 0～255, 导致数据预处理时进行放缩, 丢失了三维坐标准确值, 识别收到一定限制。

使用加入数值通路的 RGB 图像进行识别时效果较好, 准确率达到 1。针对上述 2 种方法存在的绕地标转弯识别精确率不高的问题, 本文方法的精确率有较大提升。

SVM 分类器分类效果受核函数及惩罚参数的影响较大, 对加入数值通路的 RGB 图像方法进行核函数及惩罚参数的调整, 得到结果如图 7 所示, 0、1、2、3 标签分别为绕地转弯、矩形航线、降落、起飞 4 个飞行动作。

由图 7 可见, 线性核函数分类准确率最高, 在本文所用样本集条件下, 准确率能够达到 100%。而其他核函数均在绕地标转弯和矩形航线分类方面存在一定的错误, 但整体准确率在 90% 以上。由于绕地标转弯和矩形航线 2 种飞行任务航迹均为完整环形, 本文所用样本数据量不大, 在使用非线性核函数时, 训练程度不足, 无法做到完全收敛, 在对样本数量进行逐渐增加的过程中, 发现随着样本数量增加非线性核函数分类准确率也在增加。可见, 在小样本情况下, 使用线性或非线性核函数均能达到较好的分类效果, 本文所用 RGB 图像与数值通路结合的方法, 能够有效用于飞行任务识别。

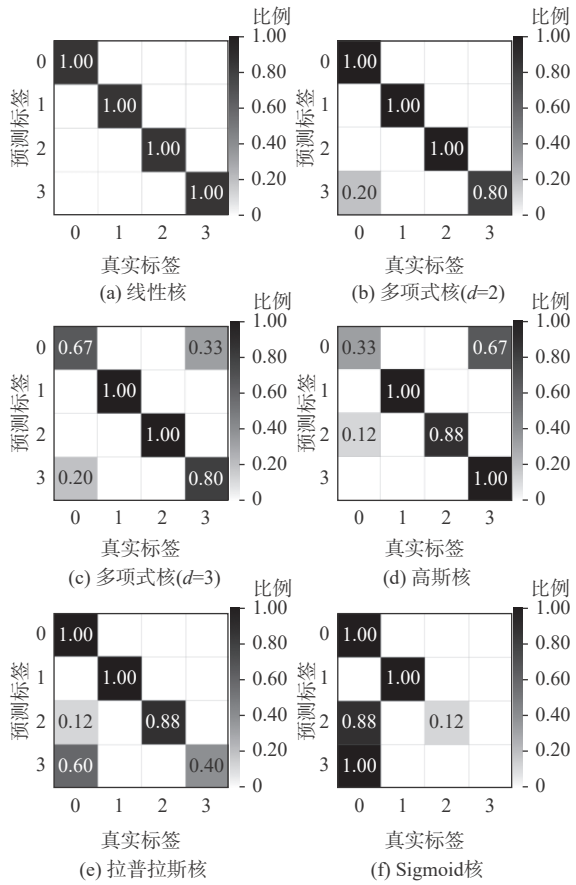


图 7　不同核函数分类结果

Fig. 7　Classification results of different kernel functions

3　飞行动作划分

由于一项飞行任务可能会包括一个或多个飞行动作, 在进行飞行训练评估之前, 需要将分类后的飞行任务进行动作划分。针对民航飞行任务, 其飞行动作可以分为起飞、爬升、巡航、下降、降落、巡航转弯、下降转弯、爬升转弯、盘旋 9 种类别, 民航飞行基本的训练内容均可由上述 9 种动作组成, 后续可以根据每种飞行动作提出不同的评价标准。一种飞行任务包含上述 9 种飞行动作的一个或几种, 如将矩形航线划分为: 起飞、爬升、爬升转弯、巡航、下降转弯、下降、降落 7 种动作。

飞行动作分割由高度划分和横航向划分组成, 首先, 根据飞行高度变化划分为起飞、爬升、巡航、下降、降落 5 种动作, 其次, 根据飞机横航向变化划分为转弯、盘旋、直飞 3 种动作, 最后, 将上述 2 种划分结果进行组合得到最终结果, 如图 8 所示。当第 1 步高度划分结果为起飞、降落时, 可不进行第 2 步划分直接得到最终结果。

在高度划分方面, 起飞、爬升和下降、降落以高度具体数值作为区分, 以波音 737-800 飞机为例, 当飞机高度大于 10.7 m 时, 认为飞机完成起飞, 进

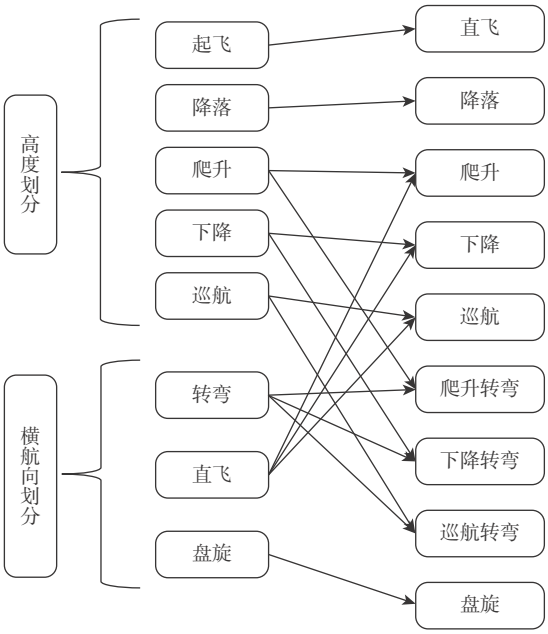


图 8 飞行动作划分示意

Fig. 8 Schematic diagram of flight action segmentation

入爬升状态；下降和降落区分同理，划分所用高度具体数值可查看飞行手册；当飞机高度保持基本不变时认为飞机进入巡航状态。在横航向划分方面，综合考虑 x,y 轴坐标变化，并结合飞机航向角，确定飞机所执行的横航向动作动作。最后，综合高度划分和横航向划分，得到最终动作划分结果，如图 9 所示。

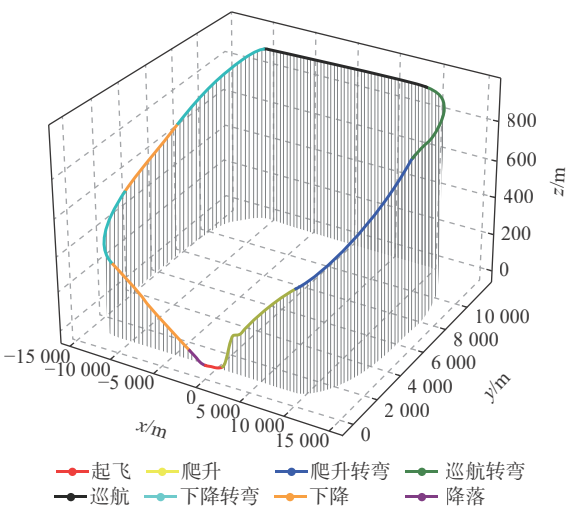


图 9 矩形航线任务飞行动作划分结果

Fig. 9 Flight action division result of rectangular route task

4 结 论

本文针对民航飞行训练评价中对飞行任务识别提出的要求，进行了飞行任务识别和动作划分方法研究。

1）本文提出针对飞行参数的数据预处理方法，包括坐标系转换、重采样、均值模糊处理 3 部分，保证飞参数据可用于后续研究。

2）在传统航迹图像识别的基础上，本文提出基于支持向量机模型的 RGB 图像识别方法，并加入数据识别通路，飞行任务识别准确率可以达到 1。

3）本文提出能够用于飞行训练评价的动作划分方法，将民航飞行过程中的各项任务细分为起飞、爬升、巡航、下降、降落、巡航转弯、下降转弯、爬升转弯、盘旋共 9 种飞行动作。

参考文献（References）

[1] Yin D W. Design of flight training evaluation system based on flight parameters data[C]// Proceedings of the 2022 IEEE 8th International Conference on Computer and Communications. Piscataway: IEEE Press, 2022: 2405-2409.

[2] Yang S Q, Yu K, Lammers T, et al. Artificial intelligence in pilot training and education-towards a machine learning aided instructor assistant for flight simulators[C]// Proceedings of the HCI International 2021 - Posters. Cham: Springer International Publishing, 2021: 581-587.

[3] Paces P, Insaurralde C C. Artificially intelligent assistance for pilot performance assessment[C]// Proceedings of the 2021 IEEE/AIAA 40th Digital Avionics Systems Conference. Piscataway: IEEE Press, 2021: 1-7.

[4] 倪世宏, 史忠科, 谢川, 等. 军用战机机动飞行动作识别知识库的建立[J]. 计算机仿真, 2005, 22(4): 23-26.
Ni S H, Shi Z Ke, Xie C, et al. Establishment of avion inflight maneuver action recognizing knowledge base[J]. Computer Simulation, 2005, 22(4): 23-26(in Chinese).

[5] 贾镇泽, 樊晓光, 薛明浩, 等. 基于机动动作元的敌机战术机动在线识别方法[J]. 北京理工大学学报, 2018, 38(8): 820-827.
Jia Z Z, Fan X G, Xue M H, et al. Online identification method for tactical maneuver of target based on air combat maneuver element[J]. Transactions of Beijing Institute of Technology, 2018, 38(8): 820-827(in Chinese).

[6] 刘浩, 王昊, 孟光磊, 等. 基于动态贝叶斯网络和模糊灰度理论的飞行训练评估[J]. 航空学报, 2021, 42(8): 243-254.
Liu H, Wang H, Meng G L, et al. Flight training evaluation based on dynamic Bayesian network and fuzzy gray theory[J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(8): 243-254(in Chinese).

[7] Palladino A, Duff M, Bock A, et al. AI-augmented human performance evaluation for automated training decision support[C]// Proceedings of the Intelligent Human Systems Integration 2021. Cham: Springer International Publishing, 2021: 469-475.

[8] Samuel K, Larosa M, Mcalpin K, et al. AI enabled maneuver identification via the maneuver identification challenge[PP/OL]. arXiv (2022-11-28)[2024-07-08].https://doi.org/10.48550/arXiv.2211.15552.

[9] 张夏阳, 殷之平, 刘飞, 等. 飞机机动划分的数据挖掘方法[J]. 西北工业大学学报, 2016, 34(1): 33-40.
Zhang X Y, Yin Z P, Liu F, et al. An aircraft maneuver partition method based on data mining[J]. Journal of Northwestern Polytechnical University, 2016, 34(1): 33-40(in Chinese).

[10] 孟光磊, 张慧敏, 朴海音, 等. 自动化飞行训练评估中的战机机动

动作识别[J]. 北京航空航天大学学报, 2020, 46(7): 1267-1274.
Meng G L, Zhang H M, Piao H Y, et al. Recognition of fighter maneuver in automatic flight training evaluation[J]. Journal of Beijing University of Aeronautics and Astronautics, 2020, 46(7): 1267-1274(in Chinese).

[11] Lu J, Deng J L, Ren Z, et al. Flight training subject identification method based on multivariate subsequence search with double windows[J]. IEEE Access, 2023, 11: 3221-3231.

[12] 杨俊, 谢寿生. 基于模糊支持向量机的飞机飞行动作识别[J]. 航空学报, 2005, 26(6): 738-742.
Yang J, Xie S S. Fuzzy support vector machines based recognition for aeroplane flight action[J]. Acta Aeronautica et Astronautica Sinica, 2005, 26(6): 738-742(in Chinese).

[13] Feng S, Magana A J, Kao D. A systematic review of literature on the effectiveness of intelligent tutoring systems in STEM[C]// Proceedings of the 2021 IEEE Frontiers in Education Conference. Piscataway: IEEE Press, 2021: 1-9.

[14] 徐西蒙, 杨任农, 于洋, 等. 基于运动分解和 H-SVM 的空战目标机动识别[J]. 控制与决策, 2020, 35(5): 1265-1272.
Xu X M, Yang R N, Yu Y, et al. Target maneuver recognition in air combat based on motion decomposition and H-SVM[J]. Control and Decision, 2020, 35(5): 1265-1272(in Chinese).

[15] 中国民用航空局. 民用航空器驾驶员合格审定规则: CCAR-61-R5[S]. 北京: 中华人民共和国交通运输部, 2018: 87-89.
Civil Aviation Administration of China. Certification Rules for Civil Aircraft Pilots: CCAR-61-R5[S]. Beijing: Ministry of Transport of the People's Republic of China, 2018: 87-89(in Chinese).

[16] 欧阳霆. 飞机飞行指南[M]. 2 版. 成都: 西南交通大学出版社, 2018: 72-124.
OUYANG T. Aircraft flight guide[M]. 2nd ed. Chengdu: Southwest Jiaotong University Press, 2018: 72-124(in Chinese).

[17] 刘世前. 现代飞机飞行动力学与控制[M]. 2 版. 上海: 上海交通大学出版社, 2018: 41-45.
Liu S Q. Flight dynamics and control of modern aircrafts[M]. 2nd ed. Shanghai: Shanghai Jiao Tong University Press, 2018: 41-45(in Chinese).

[18] Goddard H, Shamir L. SVMnet: non-parametric image classification based on convolutional ensembles of support vector machines for small training sets[J]. IEEE Access, 2022, 10: 24029-24038.

[19] Nalepa J, Kawulok M. Selecting training sets for support vector machines: a review[J]. Artificial Intelligence Review, 2019, 52(2): 857-900.

Flight task recognition and action segmentation based on SVM

LI Bowen[1, 2], LEI Xiaoyong[1, 2, *]

(1. State Key Laboratory of Virtual Reality Technology and Systems, Beihang University, Beijing 100191, China;
2. School of Automation Science and Electrical Engineering, Beihang University, Beijing 100191, China)

Abstract: The quality assessment of civil aviation flight training is gradually developing in the direction of quantification and intelligence. A support vector machine (SVM)-based approach for civil aviation flight task recognition and action division is suggested in order to satisfy the new requirement of flight task recognition. Firstly, civil aviation flight parameters are collected and preprocessed for subsequent flight task identification and action division. Then, the support vector machine model is used to identify the civil aviation flight tasks. The traditional method uses a flight track image for recognition, but the accuracy of take-off and landing recognition is low due to the lack of time sequence features. This issue is resolved by converting *xyz* coordinates to RGB pictures, adding numerical channels to represent the data's absolute value, and introducing time series characteristics. Compared with the experimental results of traditional track image recognition, RGB image recognition, and the combination of RGB image and numerical channel recognition, it is found that the recognition accuracy is increased by 43% by using the method of combining RGB image and numerical channel, which can effectively improve the recognition accuracy of turning around landmarks and rectangular routes. In addition, according to the flight task identification results, each task is divided into nine types of flight actions: take-off, landing, climb, descent, cruise, climb turn, descent turn, cruise turn and hover, which provides support for the subsequent flight training quality assessment research.

Keywords: support vector machine; flight task identification; flight action division; flight training quality assessment; data preprocessing

Received: 2024-09-02; **Accepted**: 2024-10-30; **Published Online**: 2024-11-04 17:29
URL: link.cnki.net/urlid/11.2625.V.20241104.1537.002
Foundation item: National Key Research Plan - Science and Technology Innovation 2030- "New Generation of Artificial Intelligence" Major Project (2018AAA0102902)

* **Corresponding author**. E-mail: leixy@buaa.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2024.0623

基于 IGWO-STCKF 的目标跟踪算法

王威[1]，宫淑丽[1,*]，李晓明[2]

(1. 南京航空航天大学 民航学院，南京 210016；2. 航天时代飞鸿技术有限公司，北京 100094)

摘 要：针对容积卡尔曼滤波 (CKF) 算法滤波噪声先验确定且目标机动时跟踪精度下降2个问题，提出一种结合改进灰狼优化和强跟踪滤波的容积卡尔曼滤波 (IGWO-STCKF) 算法。分析了 CKF 计算流程；利用灰狼优化实现过程噪声协方差的自适应，针对灰狼优化 (GWO) 算法易得到局部最优及搜索慢的缺点，提出采用佳点集理论初始化种群，嵌入调节参数非线性调整策略，越界处理策略和动态权重调整策略形成改进的灰狼优化算法 (IGWO)；借鉴强跟踪滤波 (STF)，引入双渐消因子调整 CKF 算法量测更新时的协方差矩阵，实时调整滤波增益，最终形成 IGWO-STCKF 算法。将 IGWO-STCKF 和 IGWO-CKF、STCKF、IMM-CKF 和 CKF 算法运用到具有动态噪声的二维机动目标跟踪仿真实验中，对跟踪轨迹图、算法运行时间、位置和速度均方根误差曲线和累计均方根误差值进行分析。结果表明：IGWO-STCKF 算法跟踪精度和稳定性更优。

关 键 词：容积卡尔曼滤波；灰狼优化；强跟踪滤波；渐消因子；目标跟踪
中图分类号：V249.4
文献标志码：A **文章编号**：1001-5965(2026)11-4098-09

目标跟踪旨在利用计算机和相关导航设备结合算法实时预测与估计目标运动状态[1]。实际应用中，目标状态转移模型或量测方程多具有非线性特征，非线性滤波问题的难点在于估计状态的后验概率密度函数 (probability density function, PDF)[2]。常用的最优估计方法，如粒子滤波器 (particle filter, PF)，滤波精度好，但计算量大，实时性差[3]。高斯近似滤波法一般假设 PDF 为高斯分布，通过非线性函数近似或概率密度函数近似计算非线性函数的均值和方差[4]，目前已经发展出不敏卡尔曼滤波 (unscented Kalman filter, UKF)[5]、高斯-埃米特卡尔曼滤波 (Gauss-Hermite Kalman filter, GHKF)[6] 和容积卡尔曼滤波 (cubature Kalman filter, CKF)[7] 等算法。UKF 引入不敏变换 (unscented transform, UT)，利用$2n+1$个 (n为状态维数) 采样点计算状态向量概率分布，具有三阶精度，但对于高维系统滤波稳定性不佳[5]。GHKF 基于高斯-厄米特准则求解高斯积分，滤波精度高，但易发生维数灾难[6]。CKF 算法基于三阶球面-径向求积准则，较 UKF 滤波稳定性好，在目标跟踪中得到了广泛的应用。但在目标发生机动时，滤波精度和鲁棒性仍有待提升；此外，CKF 中滤波噪声一般根据前人经验或试错法设置为固定值，耗费实验精力且有悖于实际。针对上述两方面问题，目前的研究主要有：罗亚伦利用渐消因子增强 CKF 算法的鲁棒性并结合交互多模型实现对高超目标的跟踪[8]；Sahl 等利用 M 估计增强 CKF 算法的鲁棒性实现了在测量值缺失情况下的目标跟踪[9]；Lu 等利用最大相关熵准则处理在过程噪声或者量测噪声未知时 CKF 算法[10]；Li 等提出迭代正交单纯型容积卡尔曼滤波，依据球面单纯型径向容积准则和二阶高斯拉盖尔求积公式计算新的容积点并应用于目标跟踪，但计算过程繁琐[11]；杨

收稿日期：2024-08-27；**录用日期**：2024-10-18；**网络出版时间**：2024-11-06 14:00
网络出版地址：link.cnki.net/urlid/11.2625.V.20241106.1035.003
基金项目：国家自然科学基金 (U2033201)；南京航空航天大学研究生科研与实践创新项目 (xcxjh20230717)
* **通信作者**. E-mail：gong_shuli@nuaa.edu.cn

引用格式：王威，宫淑丽，李晓明. 基于 IGWO-STCKF 的目标跟踪算法 [J]. 北京航空航天大学学报，2026，52（11）：4098-4106.
Wang W，Gong S L，Li X M. Target tracking algorithm based on IGWO-STCKF[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：4098-4106（in Chinese）.

永建等基于最小化新息准则推导调整系数得到修正平方根容积卡尔曼滤波[12]; 杜坤引入非线性收敛因子改进灰狼算法, 实现滤波噪声的动态自适应调整[13]; 游航航等利用灰狼算法实时更新滤波参数[14]; 宋春宁等采用郊狼算法对状态误差协方差阵及滤波噪声进行寻优[15]。

本文分析了 CKF 的计算流程, 采用奇异值分解代替乔姆斯基分解以提高 CKF 数值迭代的稳定性; 利用灰狼优化 (grey wolf optimizer, GWO) 算法对 CKF 的过程噪声进行自适应调整, 同时为改善灰狼优化易陷入局部最优及收敛慢等缺点, 使用佳点集理论初始化灰狼保证种群分布的均匀性; 对越界的灰狼个体设计处理策略提高算法迭代时个体分布的多样性; 引入非线性收敛因子和动态权重调整策略改善算法收敛速度; 为提高 CKF 算法在目标机动时的鲁棒性, 在量测更新阶段的协方差矩阵计算中嵌入渐消因子; 最终形成改进灰狼优化的强跟踪容积卡尔曼滤波算法 (improved grey-wolf optimization algorithm-strong tracking CKF, IGWO-STCKF)。最后设计仿真实验, 将本文算法应用于二维机动目标跟踪以验证该算法的有效性。

1　容积卡尔曼滤波

对于具有加性噪声非线性离散时间跟踪系统, 状态空间方程表示为

$$\begin{cases} \boldsymbol{x}_k &= f(\boldsymbol{x}_{k-1})+\boldsymbol{w}_{k-1} \\ \boldsymbol{z}_k &= h(\boldsymbol{x}_k)+\boldsymbol{v}_k \end{cases} \tag{1}$$

式中: $\boldsymbol{x}_k$为k时刻状态向量; $\boldsymbol{z}_k$为k时刻量测向量; $\boldsymbol{w}_{k-1}$为方差为$\boldsymbol{Q}_{k-1}$的过程高斯白噪声; $\boldsymbol{v}_k$为方差为$\boldsymbol{R}_k$的测量高斯白噪声; $f(\cdot)$和$h(\cdot)$分别为状态转移函数和量测函数。

非线性滤波的核心任务是利用具有噪声的量测值得到系统状态的最小方差估计[16], 关键问题在于求解如下形式的积分:

$$I(f)=\int f(\boldsymbol{x})\exp(-\boldsymbol{x}^{\mathrm{T}}\boldsymbol{x})\mathrm{d}\boldsymbol{x} \tag{2}$$

CKF 的核心是利用三阶球面-相径容积准则选取容积点。具体分析如下:

令$\boldsymbol{x}=r\boldsymbol{y}$, $\boldsymbol{y}$为n维单位方向矢量, 式 (3) 在球面-径向坐标系中划分为n维球面积分$S(r)$和一维径向积分$R(r)$:

$$I(f)=\int_0^{\infty}\int_{U_n} f(r\boldsymbol{y})r^{n-1}\exp(-r^2)\mathrm{d}\sigma(\boldsymbol{y})\mathrm{d}r = \int_0^{\infty} r^{n-1}\exp(-r^2)\mathrm{d}r\int_{U_n} f(r\boldsymbol{y})\mathrm{d}\sigma(\boldsymbol{y}) \tag{3}$$

$$S(r)=\int_{U_n} f(r\boldsymbol{y})\mathrm{d}\sigma(\boldsymbol{y})\approx\sum_{i=1}^{N_y} w_{y,i}f(r\boldsymbol{y}_i) \tag{4}$$

$$R(r)=\int_0^{\infty} S(r)r^{n-1}\mathrm{e}^{-r^2}\mathrm{d}r\approx\sum_{j=1}^{N_r} w_{r,j}S(r_j) \tag{5}$$

式中: $U_n=\{\boldsymbol{y}\in R^n|\boldsymbol{y}^{\mathrm{T}}\boldsymbol{y}=1\}$, $\mathrm{d}\sigma(\boldsymbol{y})$表示球面$U_n$微元; 式 (4) 中球面积分权重$w_f(\boldsymbol{y})=1$, 径向积分权重$w_f(r)=r^{n-1}\mathrm{e}^{-r^2}$; $\boldsymbol{y}_i$和$w_{y,i}$为球面积分求积点及权重; r_j和$w_{r,j}$为径向积分求积点及权重。式 (4) 可表示为

$$I(f)\approx\sum_{i=1}^{N_y}\sum_{j=1}^{N_r} w_{y,i}w_{r,j}f(r_j\boldsymbol{y}_i) \tag{6}$$

将式 (7) 应用于高斯加权积分, 可得

$$\int g(x)N(x;0,I)\mathrm{d}x=\frac{1}{\sqrt{\pi^n}}\sum_{i=1}^{N_y}\sum_{j=1}^{N_r} w_{y,i}w_{r,j}g(\sqrt{2}r_j\boldsymbol{y}_i) \tag{7}$$

综上, 三阶球面-相径容积准则写为

$$I(g)=\int g(\boldsymbol{x})\exp(-\boldsymbol{x}^{\mathrm{T}}\boldsymbol{x})\mathrm{d}\boldsymbol{x}\approx \frac{\sqrt{\pi^n}}{2n}\sum_{i=1}^{2n} g\left(\sqrt{\frac{n}{2}}[\boldsymbol{B}]_i\right)=\sum_{i=1}^{2n}\theta_i g(\boldsymbol{\xi}_i) \tag{8}$$

式中: n为状态维数; $\boldsymbol{B}$ 为全 1 向量。

$$\begin{cases} \boldsymbol{\xi}_i=\sqrt{n}\left[\begin{pmatrix}1\\0\\\vdots\\0\end{pmatrix}\cdots\begin{pmatrix}0\\0\\\vdots\\1\end{pmatrix}\begin{pmatrix}-1\\0\\\vdots\\0\end{pmatrix}\cdots\begin{pmatrix}0\\0\\\vdots\\-1\end{pmatrix}\right] \\ \theta_i=\dfrac{1}{2n} \end{cases} \tag{9}$$

基于上述三阶球面-相径容积准则, $\boldsymbol{x}_k\sim N(\hat{\boldsymbol{x}}_k,\boldsymbol{P}_k)$的 CKF 计算流程如图 1 所示。

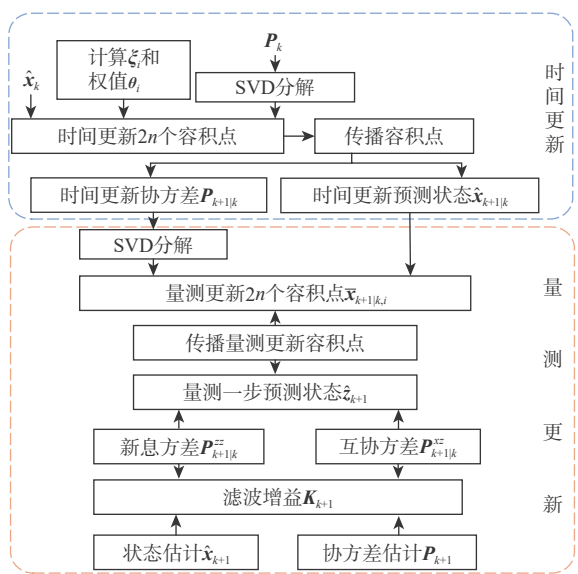


图 1　CKF 计算流程

Fig. 1　CKF algorithm flow

1) 滤波初始化

初始时刻的状态向量$\hat{\boldsymbol{x}}_0$和误差协方差$\boldsymbol{P}_0$为

$$\begin{cases}\hat{\boldsymbol{x}}_0 = E(\boldsymbol{x}_0)\\ \boldsymbol{P}_0 = E\left[(\boldsymbol{x}_0-\hat{\boldsymbol{x}}_0)(\boldsymbol{x}_0-\hat{\boldsymbol{x}}_0)^{\mathrm{T}}\right]\end{cases} \tag{10}$$

2）时间更新

① 计算容积点。用奇异值分解 (singular value decomposition, SVD) 代替 Chol 分解[17]，提高滤波的稳定性和鲁棒性。

$$\boldsymbol{P}_{k|k} = \boldsymbol{U}_k\boldsymbol{S}_k\boldsymbol{V}_k^{\mathrm{T}} \tag{11}$$

式中：$\boldsymbol{U}_k$和$\boldsymbol{V}_k^{\mathrm{T}}$为奇异值分解的正交矩阵；$\boldsymbol{S}_k$为奇异值分解的对角矩阵。

$$\boldsymbol{x}_{k,i} = \hat{\boldsymbol{x}}_k + \boldsymbol{U}_k\sqrt{\boldsymbol{S}_k}\boldsymbol{\xi}_i \tag{12}$$

②传播容积点：

$$\boldsymbol{x}_{k+1|k,i} = f(\boldsymbol{x}_{k,i}) \tag{13}$$

③计算状态一步预测值$\hat{\boldsymbol{x}}_{k+1|k}$：

$$\hat{\boldsymbol{x}}_{k+1|k} = \sum_{i=1}^{2n}\theta_i\boldsymbol{x}_{k+1|k,i} \tag{14}$$

$$\boldsymbol{P}_{k+1|k} = \sum_{i=1}^{2n}\theta_i(\boldsymbol{x}_{k+1|k,i}-\hat{\boldsymbol{x}}_{k+1|k})(\boldsymbol{x}_{k+1|k,i}-\hat{\boldsymbol{x}}_{k+1|k})^{\mathrm{T}}+\boldsymbol{Q}_k \tag{15}$$

式中：$\boldsymbol{Q}_k$为过程噪声协方差矩阵。

3）量测更新

①计算容积点：

$$\begin{cases}\boldsymbol{P}_{k+1|k} = \boldsymbol{U}_{k+1|k}\boldsymbol{S}_{k+1|k}\boldsymbol{V}_{k+1|k}^{\mathrm{T}}\\ \bar{\boldsymbol{x}}_{k+1|k,i} = \hat{\boldsymbol{x}}_{k+1|k}+\boldsymbol{U}_{k+1|k}\sqrt{\boldsymbol{S}_{k+1|k}}\boldsymbol{\xi}_i\end{cases} \tag{16}$$

②容积点传播：

$$\boldsymbol{z}_{k+1,i} = h(\bar{\boldsymbol{x}}_{k+1|k,i}) \tag{17}$$

③量测一步预测：

$$\hat{\boldsymbol{z}}_{k+1} = \sum_{i=1}^{2n}\theta_i\boldsymbol{z}_{k+1,i} \tag{18}$$

④计算误差协方差$\boldsymbol{P}_{k+1|k}^{zz}$和互协方差$\boldsymbol{P}_{k+1|k}^{xz}$：

$$\boldsymbol{P}_{k+1|k}^{zz} = \sum_{i=1}^{2n}\theta_i(\boldsymbol{z}_{k+1,i}-\hat{\boldsymbol{z}}_{k+1})(\boldsymbol{z}_{k+1,i}-\hat{\boldsymbol{z}}_{k+1})^{\mathrm{T}}+\boldsymbol{R}_{k+1} \tag{19}$$

$$\boldsymbol{P}_{k+1|k}^{xz} = \sum_{i=1}^{2n}\theta_i(\bar{\boldsymbol{x}}_{k+1|k,i}-\hat{\boldsymbol{x}}_{k+1|k})(\boldsymbol{z}_{k+1,i}-\hat{\boldsymbol{z}}_{k+1})^{\mathrm{T}} \tag{20}$$

⑤计算增益矩阵$\boldsymbol{K}_{k+1}$：

$$\boldsymbol{K}_{k+1} = \boldsymbol{P}_{k+1|k}^{xz}\left(\boldsymbol{P}_{k+1|k}^{zz}\right)^{-1} \tag{21}$$

⑥计算$k+1$时刻的状态估计：

$$\begin{cases}\hat{\boldsymbol{x}}_{k+1} = \hat{\boldsymbol{x}}_{k+1|k}+\boldsymbol{K}_{k+1}(\boldsymbol{z}_{k+1}-\hat{\boldsymbol{z}}_{k+1})\\ \boldsymbol{P}_{k+1} = \boldsymbol{P}_{k+1|k}-\boldsymbol{K}_{k+1}\boldsymbol{P}_{k+1}^{zz}\boldsymbol{K}_{k+1}^{\mathrm{T}}\end{cases} \tag{22}$$

2 IGWO-CKF 算法

过程噪声和量测噪声作为 CKF 算法的滤波输入参数，是影响目标跟踪精度的重要因素之一。量测噪声源于量测设备，其值可依据量测设备参数确定；过程噪声则会在目标运动过程动态变化。为提高 CKF 算法的滤波精度，可以利用灰狼优化对过程噪声协方差进行动态调整。

2.1 灰狼优化算法

GWO 算法通过模拟灰狼群社会等级制度和狩猎行为完成对最优解的搜索[18]，算法中每个灰狼的位置对应一个可行解，依靠灰狼的适应度值完成种群的金字塔式社会分级如图 2 所示。α、β和δ对应适应度值前三的灰狼个体，负责追踪猎物和引导狼群，其他设置为ε狼，负责围捕猎物。

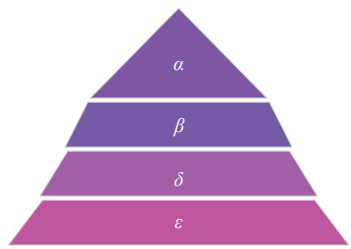


图 2 灰狼社会等级制度

Fig. 2 Social hierarchy of grey wolves

灰狼的搜索行为描述为

$$\begin{cases}\boldsymbol{X}(t+1) = \boldsymbol{X}_{\mathrm{p}}(t)-\boldsymbol{A}\boldsymbol{D}\\ \boldsymbol{D} = \left|\boldsymbol{C}\boldsymbol{X}_{\mathrm{p}}-\boldsymbol{X}(t)\right|\end{cases} \tag{23}$$

式中：t为当前迭代的次数；$\boldsymbol{X}_p(t)$为当前猎物的位置，即当前最优灰狼位置；$\boldsymbol{X}(t)$为当前灰狼位置；扰动因子$\boldsymbol{A}$和$\boldsymbol{C}$的计算式如下：

$$\boldsymbol{A} = 2\boldsymbol{a}\boldsymbol{r}_1-\boldsymbol{a} \tag{24}$$

$$\boldsymbol{C} = 2\boldsymbol{r}_2 \tag{25}$$

$$\boldsymbol{a} = 2(1-t/t_{\max}) \tag{26}$$

式中：$\boldsymbol{r}_1$和$\boldsymbol{r}_2$为[0,1]中的随机向量；$t_{\max}$为最大迭代次数。

在寻找最佳解决方案 (猎物的位置) 过程中，α狼带领β狼和δ狼逐渐逼近猎物，对于ε狼而言，越靠近 3 头精英狼，离猎物的位置就越近，采用式 (27) 计算灰狼个体最终移动的方向和距离。灰狼的位置更新机制如图 3 所示。

$$\begin{cases}\boldsymbol{D}_\alpha = |\boldsymbol{C}_1\boldsymbol{X}_\alpha(t)-\boldsymbol{X}(t)|\\ \boldsymbol{D}_\beta = \left|\boldsymbol{C}_2\boldsymbol{X}_\beta(t)-\boldsymbol{X}(t)\right|\\ \boldsymbol{D}_\delta = |\boldsymbol{C}_3\boldsymbol{X}_\delta(t)-\boldsymbol{X}(t)|\\ \boldsymbol{X}_1 = \boldsymbol{X}_\alpha-\boldsymbol{A}_1\boldsymbol{D}_\alpha\\ \boldsymbol{X}_2 = \boldsymbol{X}_\beta-\boldsymbol{A}_2\boldsymbol{D}_\beta\\ \boldsymbol{X}_3 = \boldsymbol{X}_\delta-\boldsymbol{A}_3\boldsymbol{D}_\delta\\ \boldsymbol{X}(t+1) = (\boldsymbol{X}_1+\boldsymbol{X}_2+\boldsymbol{X}_3)/3\end{cases} \tag{27}$$

式中：$\boldsymbol{X}_\alpha$、$\boldsymbol{X}_\beta$和$\boldsymbol{X}_\delta$表示当前α、β和δ狼的位置；$\boldsymbol{D}_\alpha$、$\boldsymbol{D}_\beta$和$\boldsymbol{D}_\delta$表示α、β和δ狼与狼之间的距离ε。

每次更新后，再次计算各灰狼适应度值并筛选

新的 3 头精英狼进行下一次迭代。迭代结束后, 最终α狼的位置就是问题的最优解。

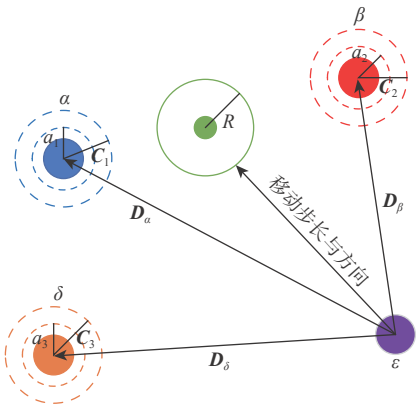


图 3　GWO 位置更新机制

Fig. 3　Positions updating of grey in GWO

2.2　多策略改进灰狼优化算法

GWO 算法因为结构简单, 输入参数少、易实现等优点, 广泛应用于路径规划、经济调度和最优控制等领域。许多学者也对 GWO 算法做出改进, 综合来看: 目前对于灰狼优化的改进主要集中在初始种群生成、搜索机制及算法参数的改进 3 个部分[18]。本文基于前人的研究, 以提高搜索速度和得到全局最优为目标, 对这 3 个部分均提出了相应的改进方法。

2.2.1　佳点集初始化策略

GWO 算法中, 初始灰狼种群个体位置表示为

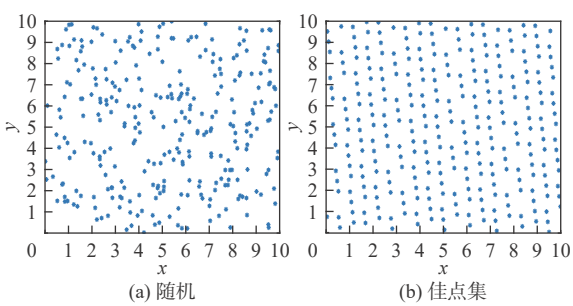
$$\boldsymbol{X}_i=\boldsymbol{G}_{\mathrm{lb}}+\mathrm{rand}(\boldsymbol{G}_{\mathrm{ub}}-\boldsymbol{G}_{\mathrm{lb}}) \tag{28}$$

式中: $\boldsymbol{G}_{\mathrm{ub}}$、$\boldsymbol{G}_{\mathrm{lb}}$为灰狼的上下限。

以二维灰狼种群为例, 在 [0,10] 内生成 300 个灰狼个体。图 4(a) 为采用式 (28) 进行初始化的灰狼群, 此时种群在整个解空间分布不均匀, 多样性欠佳, GWO 算法对整个搜索空间的利用率不高且易陷入局部最优。对此, 引入佳点集理论初始化灰狼种群[19]。新的初始化策略为

$$\boldsymbol{X}_i=\boldsymbol{G}_{\mathrm{lb}}+\{\boldsymbol{P}_n(k)\}(\boldsymbol{G}_{\mathrm{ub}}-\boldsymbol{G}_{\mathrm{lb}}) \tag{29}$$

式中: $\boldsymbol{P}_n(k)$为佳点集。



(a) 随机　　(b) 佳点集

图 4　初始化灰狼种群

Fig. 4　Initialization of grey wolves population

图 4(b) 为运用佳点集理论生成的初始化灰狼种群, 此时灰狼个体均匀分布在整个搜索空间, 初始种群质量和稳定性提高, 有利于算法摆脱局部最优, 获得全局最优解。

2.2.2　越界处理策略

GWO 算法在迭代计算过程中一般令越界个体与限值相等, 若越界个体较多, 则灰狼位置趋同, 破坏了种群多样性, 搜索易陷入局部最优[20]。为维持种群个体多样性, 对越界灰狼的位置二次更新表达式如下:

$$\boldsymbol{X}_{i,\mathrm{new}}=\begin{cases}\boldsymbol{G}_{\mathrm{lb}} & \mu>1-\sigma,\quad \boldsymbol{X}<\boldsymbol{G}_{\mathrm{lb}}\\ \boldsymbol{G}_{\mathrm{lb}}+\mu(\boldsymbol{G}_{\mathrm{ub}}-\boldsymbol{G}_{\mathrm{lb}}) & \mu<\sigma,\quad \boldsymbol{X}<\boldsymbol{G}_{\mathrm{lb}}\\ \boldsymbol{G}_{\mathrm{lb}}+\mu(\boldsymbol{G}_{\mathrm{ub}}-\boldsymbol{G}_{\mathrm{lb}}) & \mu<\sigma,\quad \boldsymbol{X}>\boldsymbol{G}_{\mathrm{ub}}\\ \boldsymbol{G}_{\mathrm{ub}} & \mu>1-\sigma,\quad \boldsymbol{X}>\boldsymbol{G}_{\mathrm{ub}}\end{cases} \tag{30}$$

式中: μ为 [0,1] 之间均匀分布随机数; σ为越界处理参数, 本文取 0.5。

2.2.3　非线性收敛因子策略

为平衡算法前期探索和后期开采的能力, GWO 算法中收敛因子a在 [0,2] 之间线性递减, 此时算法易陷入局部最优。综合现有针对收敛因子的改进策略可以看出: 在迭代开始阶段, a应缓慢减小以提高算法的勘探性, 在迭代后期, a的减小速度应减缓以提高算法的开采性[21]。因此, 利用指数函数来衰减:

$$a=a_{\min}-(a_{\max}-a_{\min})\mathrm{e}^{-\left(\frac{2t}{t_{\max}}\right)^4} \tag{31}$$

2.2.4　动态权重调整策略

GWO 算法中灰狼位置更新采用灰狼朝向 3 头精英狼前进步长的算术平均值, 未体现 3 头精英狼在位置变更和引导过程的优先等级, 与灰狼进行等级划分策略不一致, 且收敛速度有待提高。为此, 以各精英狼的适应度值作为分配权重的判断依据, 利用加权平均值作为灰狼的位置更新[22]。改进后灰狼的位置更新计算为

$$\begin{cases}\boldsymbol{X}(t+1)=\dfrac{1}{3}\displaystyle\sum_{i=1,2,3}\theta_i\boldsymbol{X}_i(t+1)\\ \theta_i=\dfrac{f(\boldsymbol{X}_i(t+1))}{\displaystyle\sum_{i=1,2,3}f(\boldsymbol{X}_i(t+1))}\end{cases} \tag{32}$$

式中: $f(\boldsymbol{X}_i)(i=1,2,3)$表示$\alpha$、$\beta$和$\delta$狼的适应度值; θ_i表示各精英狼在位置更新中的权重。

2.3　基于改进灰狼优化的滤波噪声自适应

运用 IGWO 算法对 CKF 算法中的过程噪声协方差矩阵$\boldsymbol{Q}$进行优化, 实现算法的自适应调参。$\boldsymbol{Q}$为对角矩阵, 将 IGWO 算法中的灰狼位置设置为$\boldsymbol{Q}$的对角元素, 进行迭代计算, 具体过程如下:

步骤 1　初始化种群规模N, 最大迭代次数$t_{\max}$, 收敛因子a, $\boldsymbol{A}$, $\boldsymbol{C}$。

步骤 2　采用佳点集理论初始化种群位置, 使灰狼个体均匀分布在搜索空间, 灰狼种群位置记为

$\{\boldsymbol{X}_1,\boldsymbol{X}_2,\cdots,\boldsymbol{X}_N\}$。

步骤 3 选取滤波新息的实际方差为适应度函数，如式 (33) 所示，并计算各灰狼适应度值，筛选出 3 头精英狼，对应位置为$\boldsymbol{X}_\alpha$、$\boldsymbol{X}_\beta$和$\boldsymbol{X}_\delta$。

步骤 4 依据式 (31) 更新非线性收敛因子并计算干扰因子$\boldsymbol{A}$和$\boldsymbol{C}$。

步骤 5 依据式 (27) 和式 (32) 更新灰狼个体位置$\boldsymbol{X}_k$，并处理越界个体，重新计算各灰狼的适应度值$f(\boldsymbol{X}_k)$。

步骤 6 更新α、β和δ的位置和适应度。

步骤 7 判断迭代是否达到要求，未达到则返回步骤 4；达到则返回最优解$\boldsymbol{X}_\alpha(t)=[q_1,q_2,q_3,q_4,q_5]$，这 5 个元素作为优化后的$\boldsymbol{Q}$的对角元素，优化后的$\boldsymbol{Q}$作为下一时刻的输入。

利用 IGWO 算法对滤波噪声寻优的过程中，设计恰当的适应度函数可以指导灰狼种群的总体移动方向，同时也可作为迭代终止的有效条件。滤波新息作为量测实际值与预测值的差，其方差与$\boldsymbol{Q}$关系密切，所以将适应度函数设置为新息的实际方差，函数值越小，目标跟踪精度越高[23]：

$$l=\min((\boldsymbol{z}_{k+1}-\hat{\boldsymbol{z}}_{k+1})(\boldsymbol{z}_{k+1}-\hat{\boldsymbol{z}}_{k+1})') \tag{33}$$

式中：l为新息的实际方差；$\boldsymbol{z}_{k+1}$和$\hat{\boldsymbol{z}}_{k+1}$为对应时刻的量测值和量测预测值。

3 IGWO-STCKF 算法

当系统模型不准确或目标机动时，CKF 的目标跟踪精度会迅速下降。为提高 CKF 的鲁棒性，将强跟踪滤波 (strong tracking filter, STF) 中的渐消因子引入量测更新的协方差中，设计强跟踪容积卡尔曼滤波 (strong tracking CKF, STCKF) 算法。

3.1 强跟踪滤波

STF 基于衰减记忆滤波，利用渐消因子调整$\boldsymbol{P}_{k+1|k}$，迫使残差序列正交，以期全部提取残差序列的信息，保证滤波在模型不准确或状态发生突变时的鲁棒性[24]。

标准 STF 以扩展卡尔曼滤波为基础，对系统函数和量测函数具有连续可微的要求且计算涉及雅可比矩阵，计算繁琐。为在 CKF 中嵌入渐消因子，需要建立非线性系统下的 STF 算法[25]。算法核心仍是计算残差：

$$\begin{cases}\hat{\boldsymbol{x}}_{k+1}=\hat{\boldsymbol{x}}_{k+1|k}+\boldsymbol{K}_{k+1}\boldsymbol{e}_{k+1}\\ \boldsymbol{e}_{k+1}=\boldsymbol{z}_{k+1}-\boldsymbol{h}(\hat{\boldsymbol{x}}_{k+1|k})\end{cases} \tag{34}$$

式中：$\hat{\boldsymbol{x}}_{k+1}$为$k+1$时刻的状态估计值；$\boldsymbol{e}_{k+1}$表示滤波残差；$\boldsymbol{K}_{k+1}$为$k+1$时刻的滤波增益。渐消因子$\lambda_{k+1}$计算如下：

$$\begin{cases}\lambda_{k+1}=\max\left(1,\dfrac{\mathrm{tr}(\boldsymbol{N}_{k+1})}{\mathrm{tr}(\boldsymbol{M}_{k+1})}\right)\\ \boldsymbol{N}_{k+1}=\boldsymbol{V}_{0,k+1}-\boldsymbol{H}_{k+1}\boldsymbol{Q}_k\boldsymbol{H}_{k+1}^{\mathrm{T}}-\kappa\boldsymbol{R}_{k+1}\\ \boldsymbol{M}_{k+1}=\boldsymbol{H}_{k+1}\boldsymbol{P}_{k+1|k}^{x}\boldsymbol{H}_{k+1}^{\mathrm{T}}\\ \boldsymbol{H}_{k+1}=\boldsymbol{P}_{k+1|k}^{xz,l}(\boldsymbol{P}_{k+1|k}^{l})^{-1}\\ \boldsymbol{P}_{k+1|k}^{xz,l}=\sum_{i=1}^{2n}\theta_i(\boldsymbol{\chi}_{k+1|k,i}^{l}-\hat{\boldsymbol{x}}_{k+1|k})(\boldsymbol{h}(\boldsymbol{\chi}_{k+1|k,i}^{l})-\hat{\boldsymbol{z}}_{k+1}^{l})\end{cases} \tag{35}$$

式中：$\boldsymbol{P}_{k+1|k}^{x}$为未考虑渐消因子及过程噪声协方差的状态预测误差协方差阵；$\boldsymbol{P}_{k+1|k}^{l}$为含有$\boldsymbol{Q}_k$的状态预测误差方差阵，即$\boldsymbol{P}_{k+1|k}^{l}=\boldsymbol{P}_{k+1|k}^{x}+\boldsymbol{Q}_k$；$\kappa\geqslant 1$为弱化因子，本文取 4；$\boldsymbol{P}_{k+1|k}^{xz,l}$为未引入渐消因子的互相关协方差阵；$\boldsymbol{\chi}_{k+1|k,i}^{l}$为在未引入强跟踪滤波时对于状态向量的预测值；$k+1$时刻实际残差协方差阵$\boldsymbol{V}_{k+1}$的估算公式为

$$\boldsymbol{V}_{0,k+1}=\begin{cases}\boldsymbol{e}_1\boldsymbol{e}_1^{\mathrm{T}} & k=0\\ \dfrac{\rho\boldsymbol{V}_{0,k}+\boldsymbol{e}_{k+1}\boldsymbol{e}_{k+1}^{\mathrm{T}}}{1+\rho} & k>0\end{cases} \tag{36}$$

式中：$\rho\in[0.95,0.995]$表示遗忘因子，一般取$\rho=0.95$。

3.2 强跟踪容积卡尔曼滤波

基于 CKF 的计算框架，在量测更新中量测误差协方差阵和互协方差阵中分别嵌入渐消因子，形成 STCKF，即在式 (22) 和式 (23) 的基础上得到：

$$\begin{cases}\boldsymbol{P}_{k+1|k}^{zz,\lambda}=\lambda_{k+1}\left(\sum_{i=1}^{2n}\theta_i(\boldsymbol{z}_{k+1,i}-\hat{\boldsymbol{z}}_{k+1})(\boldsymbol{z}_{k+1,i}-\hat{\boldsymbol{z}}_{k+1})^{\mathrm{T}}\right)+\boldsymbol{R}_{k+1}\\ \boldsymbol{P}_{k+1|k}^{xz,\lambda}=\lambda_{k+1}\left(\sum_{i=1}^{2n}\theta_i(\bar{\boldsymbol{x}}_{k+1|k,i}-\hat{\boldsymbol{x}}_{k+1|k})(\boldsymbol{z}_{k+1,i}-\hat{\boldsymbol{z}}_{k+1})^{\mathrm{T}}\right)\end{cases} \tag{37}$$

式中：$\boldsymbol{P}_{k+1|k}^{zz,\lambda}$和$\boldsymbol{P}_{k+1|k}^{xz,\lambda}$分别为引入渐消因子后的新息协方差和互协方差。

利用$\boldsymbol{P}_{k+1|k}^{zz,\lambda}$和$\boldsymbol{P}_{k+1|k}^{xz,\lambda}$重新计算得到滤波增益$\boldsymbol{K}_{k+1}$和最终的状态估计$\hat{\boldsymbol{x}}_{k+1}$和误差协方差$\boldsymbol{P}_{k+1}$。

结合 2.3 节所述 IGWO-CKF 和 STCKF 算法形成 IGWO-STCKF 算法，IGWO-STCKT 算法流程如图 5 所示。

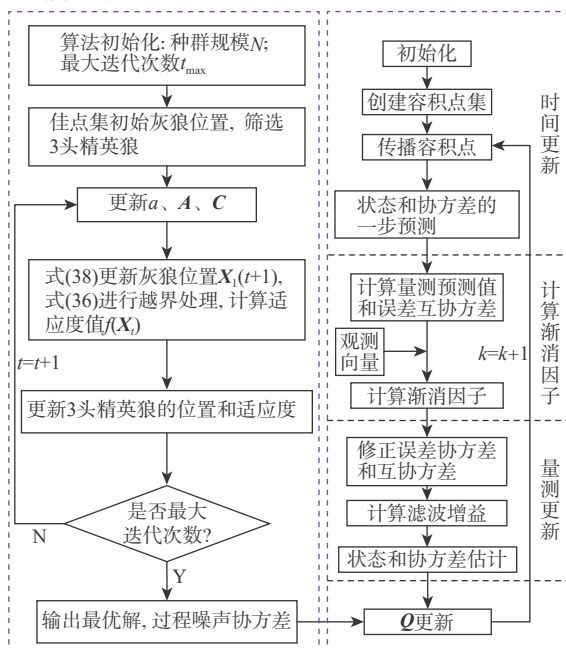


图 5 IGWO-STCKF 算法流程

Fig. 5 Flowchart of IGWO-STCKF algorithm

4 仿真验证

为检验 IGWO-STCKF 的有效性，以二维机动目

标为例, 蒙特卡罗仿真实验 100 次, 并选取 IGWO-STCKF、IGWO-CKF、STCKF、IMM-CKF 和 CKF 算法对仿真结果进行对比分析。利用仿真结果包括跟踪轨迹图、位置及速度均方根误差 (root mean square error, RMSE) 曲线、累计均方根误差 (accumulated root mean square error, ARMSE)、算法的平均运行时间及渐消因子的响应曲线:

$$\begin{cases} R_{\mathrm{RMSEpos}} = \sqrt{\dfrac{1}{N}\displaystyle\sum_{i=1}^{N}\left[(x_k^i-\hat{x}_k^i)^2+(y_k^i-\hat{y}_k^i)^2\right]} \\ A_{\mathrm{RMSEpos}} = \sqrt{\dfrac{1}{N}\displaystyle\sum_{n=1}^{N}\dfrac{1}{K}\sum_{k=1}^{K}[(x_k^i-\hat{x}_k^i)^2+(y_k^i-\hat{y}_k^i)^2]} \end{cases} \tag{38}$$

式中: (x_k^i, y_k^i)和$(\hat{x}_k^i, \hat{y}_k^i)$分别为第$i$次仿真实验中$k$时刻目标真实位置和估计位置, 同理可得速度的均方根误差和累计均方根误差。

目标状态向量 $\boldsymbol{X}_k=[x,\dot{x},y,\dot{y},\omega]^{\mathrm{T}}$, x,y表示位置, $\dot{x},\dot{y}$表示对应方向速度, ω表示角速度。$\boldsymbol{X}_0=[1\,000\ \mathrm{m}, 200\ \mathrm{m/s}, 1\,000\ \mathrm{m}, 0\ \mathrm{m/s}, 2(°)/\mathrm{s}]$, 仿真时长 100 s, 采样周期 $T=1$ s。交互式多模型 (interacting multiple model, IMM) 中的子模型包括匀速运动模型和协调转弯运动模型, 模型初始化概率$\boldsymbol{\mu}_0=[0.1,0.9]^{\mathrm{T}}$, 模型自转移概率为 0.9, 互转移概率设置为 0.1。目标运动状态转移模型为

$$\begin{aligned} \boldsymbol{X}_k &= f(\boldsymbol{X}_{k-1})+\boldsymbol{w}_{k-1}+\boldsymbol{u}_{k-1} = \\ &\begin{bmatrix} 1 & \dfrac{\sin(\omega T)}{\omega} & 0 & \dfrac{\cos(\omega T)-1}{\omega} & 0 \\ 0 & \cos(\omega T) & 0 & -\sin(\omega T) & 0 \\ 0 & \dfrac{1-\cos(\omega T)}{\omega} & 1 & \dfrac{\sin(\omega T)}{\omega} & 0 \\ 0 & \sin(\omega T) & 0 & \cos(\omega T) & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}\cdot \\ &\boldsymbol{X}_{k-1}+\boldsymbol{w}_{k-1}+\boldsymbol{u}_{k-1} \end{aligned} \tag{39}$$

式中: $\boldsymbol{u}_{k-1}$表示系统机动输入, 设定目标在$t=40$ s和$t=60$ s发生机动, 持续时间为 5 s, 机动输入为

$$\begin{cases} \boldsymbol{u}_{t=40\,\mathrm{s}} = \begin{bmatrix} 0\ \mathrm{m} & -20\ \mathrm{m/s} & 0\ \mathrm{m} & 20\ \mathrm{m/s} & 1(°)/\mathrm{s} \end{bmatrix}^{\mathrm{T}} \\ \boldsymbol{u}_{t=60\,\mathrm{s}} = \begin{bmatrix} 0\ \mathrm{m} & 20\ \mathrm{m/s} & 0\ \mathrm{m} & -20\ \mathrm{m/s} & -1(°)/\mathrm{s} \end{bmatrix}^{\mathrm{T}} \end{cases} \tag{40}$$

其中: $\boldsymbol{w}_{k-1}$表示协方差为$\boldsymbol{Q}_{k-1}$的过程噪声。$\boldsymbol{Q}_0=\mathrm{diag}(1\ 1\ 1\ 1\ 1)$, 10～20 s 时, $\boldsymbol{Q}_t=2\boldsymbol{Q}_0$; 50～60 s 时, $\boldsymbol{Q}_t=3\boldsymbol{Q}_0$; 80～90 s 时, $\boldsymbol{Q}_t=4\boldsymbol{Q}_0$。量测噪声协方差为 $\boldsymbol{R}=\mathrm{diag}(100,100)$。仿真在 Intel(R)i9-14900K、64 位 Windows10 环境中 MATLAB R2021b 中进行。

图 6 为某次仿真实验中本文算法的跟踪轨迹、量测值及目标的真实运动轨迹; 图 7 为 IGWO-STCKF 与 STCKG、IGWO-CKF 和 CKF 算法在x和y方向的位置和速度 RMSE 曲线; 图 8 为渐消因子λ的响应曲线。

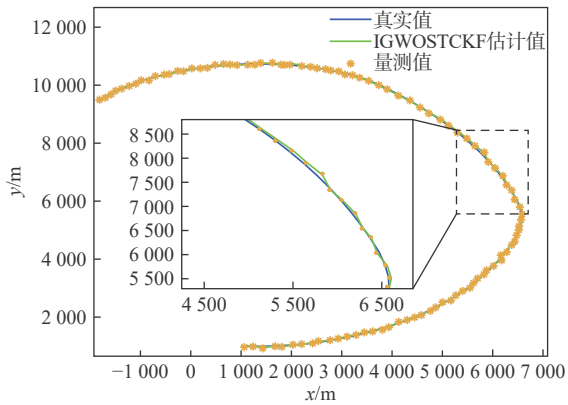


图 6　目标运动轨迹

Fig. 6　Target moving trajectory

仿真结果表明: 5 种算法均未出现滤波发散, 目标跟踪效果较好。由位置和速度均方根误差曲线可以看出, 在目标未机动且过程噪声发生变化时, IGWO-STCKF 和 IGWO-CKF 算法通过对过程噪声协方差的实时调整, 得到了比 STCKF 和 CKF 算法更高的跟踪精度; 目标机动时, STCKF 和 IGWO-STCKF 算法对目标位置和速度的跟踪误差相比于 CKF 和 IGWO-CKF 算法明显下降; IMM-CKF 算法使用 2 个子模型描述目标的运动状态以期贴近目标的真实运动情况, 目标非机动时不可避免地会引入不匹配模型状态估计带来的误差且认为过程噪声固定, 所以 IGWO-STCKF 算法较 IMM-CKF 算法滤波精度更高; 在出现未知状态的突变时, 模型的切换具有滞后性且模型集覆盖不完备导致 IMM-CKF 算法的误差仍然较 IGWO-STCKF 算法更大。从自适应渐消因子响应曲线分析: 目标机动时, 自适应渐消因子迅速增大, 随后又减小至 1, 保证 STCKF 和 IGWO-STCKF 算法对目标状态的强跟踪能力, 也可避免滤波增益过调节。在整个仿真周期中, IGWO-STCKF 算法均能保持较优的跟踪精度。

表 1 对比了 5 种滤波方法对目标位置和速度的累计均方根误差值和算法的平均运行时间, 由表可知: IGWO-CKF 算法的估计精度优于 CKF 算法, 表明 IGWO 算法在过程噪声变化的环境中, 实现了对过程噪声协方差的自适应调整; 相比于 IGWO-CKF 和 STCKF 算法, IGWO-STCKF 算法的滤波精度更优, 表明对存在状态突变的机动目标跟踪时, 引入渐消因子可以提高算法的鲁棒性, 保证较好的跟踪效果; IMM-CKF 算法设置过程噪声固定且无法准确识别未知机动, 因而速度和位置均方根误差仅较 CKF 算法略优; IGWO-STCKF 相比于 CKF 算法, 其位置和速度累计均方根误差分别减小了 71.5% 和 17.7%。从算法平均运行时间分析, IGWO-STCKF

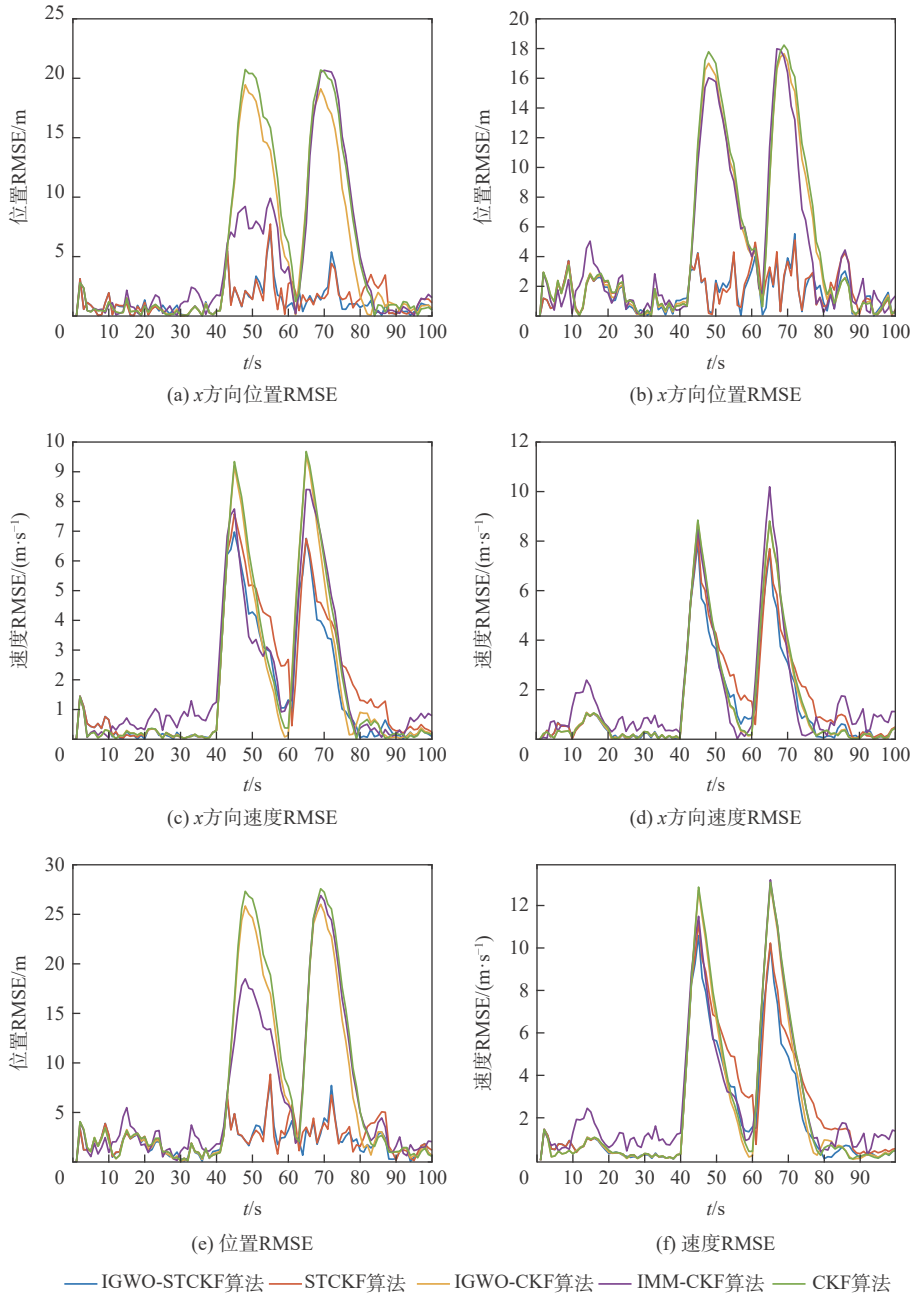


图 7 目标跟踪均方根误差曲线

Fig. 7 RMSE curve of target tracking

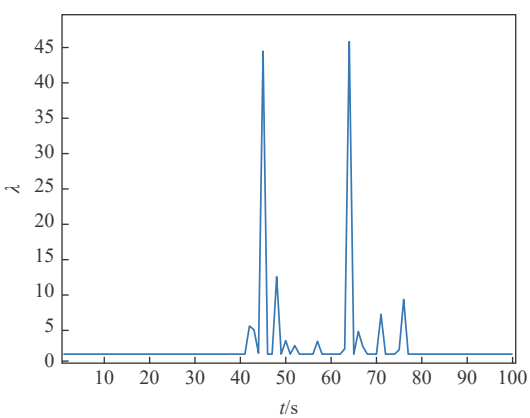


图 8 渐消因子响应曲线

Fig. 8 Response curve of fading factors

表 1 5 种算法 ARMSE 对比

Table 1 Comparison of ARMSE the ARMSE for five algorithm

算法	位置ARMSE/m	速度ARMSE/(m·s⁻¹)	运行时间/s
IGWO-STCKF	2.116 7	2.061 9	0.656 9
STCKF	2.332 1	2.524 5	0.565 6
IGWO-CKF	6.764 7	2.394 2	0.620 8
IMM-CKF	6.631 0	2.575 2	0.553 2
CKF	7.428 9	2.605 5	0.522 9

和 IGWO-CKF 算法在每次滤波估计时，都需要利用 IGWO 算法进行多次迭代计算，对过程噪声进行实时调整，算法的计算量和复杂度均增加，实时性

较 STCKF 和 CKF 算法下降; 此外, 与 IGWO-CKF 算法相比, IGWO-STCKF 算法设计渐消因子的计算, 所以实时性较差。但总的看来, 4 种算法的运行时间相差不大, 后续研究将在本文基础上针对降低 IGWO-STCKF 算法的计算量, 提高算法实时性进行研究。

5　结　论

1) 本文利用 IGWO 算法实现 CKF 中的过程噪声协方差的自适应调整; 嵌入自适应渐消因子保证算法的强跟踪能力, 提升了 CKF 的滤波精度和鲁棒性。

2) 通过仿真实验证明本文 IGWO-STCKF 算法相比于 CKF 算法, 位置 ARMSE 减小 71.5%, 速度 ARMSE 减小 17.7%, 表明本文算法具有更好的跟踪精度和稳定性, 在目标跟踪领域具有一定的应用价值。

参考文献（References）

[1] 张文杰, 王世元, 冯亚丽, 等. 基于 Huber 的高阶容积卡尔曼跟踪算法[J]. 物理学报, 2016, 65(8): 088401.
Zhang W J, Wang S Y, Feng Y L, et al. Huber-based high-degree cubature Kalman tracking algorithm[J]. Acta Physica Sinica, 2016, 65(8): 088401(in Chinese).

[2] Ito K, Xiong K. Gaussian filters for nonlinear filtering problems[J]. IEEE Transactions on Automatic Control, 2000, 45(5): 910-927.

[3] 韩博, 徐红丽, 邱少雄, 等. 基于边界约束粒子滤波的多 UUV 纯方位协同目标跟踪[J]. 水下无人系统学报, 2024, 32(2): 250-259.
Han B, Xu H L, Qiu Shaoxiong, et al. Multi-UUV collaborative bearing-only target tracking based on boundary constrained particle filter[J]. Journal of Unmanned Undersea Systems, 2024, 32(2): 250-259(in Chinese).

[4] 崔乃刚, 张龙, 王小刚, 等. 自适应高阶容积卡尔曼滤波在目标跟踪中的应用[J]. 航空学报, 2015, 36(12): 3885-3895.
Cui N G, Zhang L, Wang X G, et al. Application of adaptive high-degree cubature Kalman filter in target tracking[J]. Acta Aeronautica et Astronautica Sinica, 2015, 36(12): 3885-3895(in Chinese).

[5] Julier S, Uhlmann J, Durrant-whyte H F. A new method for the nonlinear transformation of means and covariances in filters and estimators[J]. IEEE Transactions on Automatic Control, 2000, 45(3): 477-482.

[6] Arasaratnam I, Haykin S, Elliott R J. Discrete-time nonlinear filtering algorithms using Gauss-Hermite quadrature[J]. Proceedings of the IEEE, 2007, 95(5): 953-977.

[7] Arasaratnam I, Haykin S. Cubature Kalman filters[J]. IEEE Transactions on Automatic Control, 2009, 54(6): 1254-1269.

[8] 罗亚伦, 廖育荣, 李兆铭, 等. 高超目标强跟踪 CKF 自适应交互多模型跟踪算法[J/OL]. 北京航空航天大学学报. (2022-09-28)[2024-06-03]. https://doi.org/10.13700/j.bh.1001-5965.2022.0587.
Luo Y L, Liao Y R, Li Z M, et al. Strong tracking CKF adaptive interacting multiple-model algorithm based on maneuvering hypersonic-target tracking[J/OL]. Journal of Beijing University of Aeronautics and Astronautics. (2022-09-28)[2024-06-03]. https://doi.org/10.13700/j.bh.1001-5965.2022.0587(in Chinese).

[9] Sahl S, Song E B, Niu D B. Robust cubature Kalman filter for moving-target tracking with missing measurements[J]. Sensors, 2024, 24(2): 392.

[10] Lu T, Zhou W D, Tong S. Improved maximum correntropy cubature Kalman and information filters with application to target tracking under non-Gaussian noise[J]. International Journal of Adaptive Control and Signal Processing, 2024, 38(4): 1199-1221.

[11] Li Z M, Yang X Y, Li L, et al. Iterated orthogonal simplex cubature Kalman filter and its applications in target tracking[J]. Applied Sciences, 2024, 14(1): 392.

[12] 杨永建, 甘轶, 李春辉, 等. 基于最小化新息协方差的修正 SRCKF 算法[J]. 北京航空航天大学学报, 2023, 49(1): 138-144.
Yang Y J, Gan Y, Li C H, et al. Amended SRCKF algorithm based on minimum variance of innovation[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(1): 138-144(in Chinese).

[13] 杜坤. 变电站在线监测系统设计及关键技术研究[D]. 杭州: 杭州电子科技大学, 2021: 29-43.
Du K. Design of substation online monitoring system and research on key technologies[D]. Hangzhou: Hangzhou Dianzi University, 2021: 29-43(in Chinese).

[14] 游航航, 余敏建, 吕艳, 等. 基于改进灰狼算法优化的 UKF 在空战轨迹预测中的应用[J]. 战术导弹技术, 2020(1): 91-98.
You H H, Yu M J, Lyu Y, et al. Application of UKF optimized by improved gray wolf algorithm in air combat trajectory prediction[J]. Tactical Missile Technology, 2020(1): 91-98(in Chinese).

[15] 宋春宁, 苏有平, 莫伟县, 等. 基于 COA-ASRCKF 的单液流锌镍电池 SOC 估计[J]. 电池, 2021, 51(4): 351-355.
Song C N, Su Y P, Mo W X, et al. SOC estimation of single-flow zinc-nickel battery based on COA-ASRCKF[J]. Battery Bimonthly, 2021, 51(4): 351-355(in Chinese).

[16] 秦康, 董新民, 陈勇. 基于 Huber 的鲁棒高阶容积卡尔曼滤波算法[J]. 计算机工程与应用, 2017, 53(7): 21-29.
Qin K, Dong X M, Chen Y. Huber-based robust high-degree cubature Kalman filter algrithm[J]. Computer Engineering and Applications, 2017, 53(7): 21-29(in Chinese).

[17] 成怡, 刘铭阳, 徐国伟. 高机动目标的改进强跟踪 CKF 自适应 IMM 算法[J]. 中国惯性技术学报, 2024, 32(7): 715-723.
Cheng Y, Liu M Y, Xu G W. Improved strong tracking CKF adaptive IMM algorithm for high maneuvering targets[J]. Journal of Chinese Inertial Technology, 2024, 32(7): 715-723(in Chinese).

[18] 张晓凤, 王秀英. 灰狼优化算法研究综述[J]. 计算机科学, 2019, 46(3): 30-38.
Zhang X F, Wang X Y. Comprehensive review of grey wolf optimization algorithm[J]. Computer Science, 2019, 46(3): 30-38(in Chinese).

[19] 闫少强, 杨萍, 朱东林, 等. 基于佳点集的改进麻雀搜索算法[J]. 北京航空航天大学学报, 2023, 49(10): 2790-2798.
Yan S Q, Yang P, Zhu D L, et al. Improved sparrow search algorithm based on good point set[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(10): 2790-2798(in Chinese).

[20] 王振东, 汪嘉宝, 李大海. 一种增强型麻雀搜索算法的无线传感器网络覆盖优化研究[J]. 传感技术学报, 2021, 34(6): 818-828.
Wang Z D, Wang J B, Li D H. Study on WSN optimization coverage of an enhanced sparrow search algorithm[J]. Chinese Journal of Sensors and Actuators, 2021, 34(6): 818-828(in Chinese).

[21] 丁瑞成, 周玉成. 引入莱维飞行与动态权重的改进灰狼算法[J]. 计算机工程与应用, 2022, 58(23): 74-82.
Ding R C, Zhou Y C. Improved grey wolf optimization algorithm based on levy flight and dynamic weight strategy[J]. Computer Engineering and Applications, 2022, 58(23): 74-82(in Chinese).

[22] 游航航, 韩其松, 余敏建, 等. 基于 AIGWO-IMMUKF 的目标跟踪算法[J]. 北京航空航天大学学报, 2020, 46(10): 1826-1833.
You H H, Han Q S, Yu M J, et al. Target tracking algorithm based on AIGWO-IMMUKF[J]. Journal of Beijing University of Aeronautics and Astronautics, 2020, 46(10): 1826-1833(in Chinese).

[23] 齐美彬, 伍坤江, 赵谦, 等. SRCKF-GM-PHD 多目标跟踪算法的优化[J]. 现代雷达, 2023, 45(4): 31-39.
Qi M B, Wu K J, Zhao Q, et al. Optimization of SRCKF-GM-PHD multi-target tracking algorithm[J]. Modern Radar, 2023, 45(4): 31-39(in Chinese).

[24] Zhang H W, Xie J W, Ge J A, et al. Strong tracking SCKF based on adaptive CS model for manoeuvring aircraft tracking[J]. IET Radar, Sonar & Navigation, 2018, 12(7): 742-749.

[25] Zhang A, Bao S D, Gao F, et al. A novel strong tracking cubature Kalman filter and its application in maneuvering target tracking[J]. Chinese Journal of Aeronautics, 2019, 32(11): 2489-2502.

Target tracking algorithm based on IGWO-STCKF

WANG Wei[1], GONG Shuli[1,*], LI Xiaoming[2]

(1. College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;
2. Aerospace Times FeiHong Technology Company Limited, Beijing 100094, China)

Abstract: Aiming at the problems the cubature Kalman filter(CKF) algorithm needs to predetermine the filtering noise and that the tracking accuracy decreases when the target is maneuvering, a strong tracking cubature Kalman filter algorithm based on improved grey wolf optimization (IGWO-STCKF) is proposed. Firstly, the process of CKF is introduced. Secondly, the grey wolf optimization is used to achieve the adaptability of the process noise covariance. The good point set theory is used to obtain the initial population, embedding the nonlinear adjustment strategy of control parameters, the out-of-bounds processing strategy, and the dynamic weight adjustment strategy, in order to address the shortcomings of the grey wolf optimization (GWO) algorithm, which include its slow search speed and ease of achieving a local optimum. Meanwhile, the fading factor, which takes reference from a strong tracking filter (STF), is used to adjust the covariance matrix during the measurement update period and adjust the filtering gain in real time. Finally, IGWO-STCKF algorithm is formed. IGWO-STCKF, IGWO-CKF, STCKF, IMM-CKF and CKF algorithms are applied to a two-dimensional maneuvering target tracking simulation experiment with dynamic noise, and the tracking trajectory diagram, algorithm execution time, the root mean square error curves of position and velocity, and cumulative root mean square error are analyzed. The results show that IGWO-STCKF algorithm has high filtering accuracy, strong robustness, and better tracking effect.

Keywords: cubature Kalman filter; grey wolf optimizer; strong tracking filter; fading factor; maneuvering target tracking

Received: 2024-08-27; **Accepted**: 2024-10-18; **Published Online**: 2024-11-06 14:00
URL: link.cnki.net/urlid/11.2625.V.20241106.1035.003
Foundation items: National Natural Science Foundation of China (U2033201); Postgraduate Research and Practical Innovation Projects of Nanjing University of Aeronautics and Astronautics (xcxjh20230717)

* **Corresponding author**. E-mail: gong_shuli@nuaa.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2025.0288

多源数据驱动的城市低空出行公共航路网络双层规划方法

王炜文[1]，包杰[1,*]，陈方骁[1]，周君[1]，羊钊[2]

(1. 南京航空航天大学 民航学院，南京 211106；2. 南京航空航天大学 通用航空与飞行学院，溧阳 213300)

摘 要：城市低空出行是低空经济高质量发展的核心，也是形成低空赋能和经济辐射的重要纽带。因此，提出多源数据驱动的城市低空出行公共航路网络双层规划方法，构建航路网络规划与低空需求分配的互馈优化机制，提出面向低空出行的航段路阻函数标定方法，设计多目标模拟退火-遗传算法 (MOSA-GA) 混合进化搜索求解算法；以典型大都市为例，提取空域、建筑物、用地、人流及噪声分布等多源城市数据，对比验证所提双层规划方法。实验结果表明：所提 MOSA-GA 算法有效平衡了解集的分布广度和目标函数优度，显著提升了低空出行公共航路网络运行效率；求解结果可以在帕累托前沿得到多个相互非支配的最优解，多目标之间存在显著的制约关系，并对交通流量分配产生影响；通过敏感性实验发现，安全间隔和最短航段长度显著影响网络优化结果。研究成果有助于指导城市低空出行公共航路网络的部署，提升低空出行服务水平。

关 键 词：城市空中交通；低空公共航路网络；双层规划模型；交通分配；多目标优化

中图分类号：V355

文献标志码：A **文章编号**：1001-5965(2026)11-4107-15

城市化进程的不断加剧，陆用资源日趋饱和，导致城市交通拥堵和交通安全问题日益严重，亟需开发城市空中可用空间，发展垂直式立体交通。《“十四五”通用航空发展专项规划》明确提出发展无人驾驶新型航空器，带动城市空中出行快速推进，构建未来城市综合交通系统。城市低空出行是指在城市低空空域内主要利用垂直起降或短距起降航空器及相关系统设施实现载人载货空中运输的活动[1]。城市低空出行是低空经济高质量发展的核心，也是形成低空赋能和经济辐射的重要纽带。推进城市低空出行对升级我国空域系统、打造空中出行-地面出行的一体化新型城市综合交通体系、缓解城市交通拥堵、建设交通强国具有重要意义[2]。

城市低空出行的高效和安全开展依托公共航路网络的规划和设计。低空出行公共航路规划是指在低空空域内，综合考虑低空地理属性约束、低空空域环境、航空器性能特性及用户出行需求等因素，为保障多航空器安全高效运行而划设公共空中通道[1-2]。近年来，国内外学者围绕低空出行的起降点选址优化、航路网络规划、交通需求分配等展开了一系列研究。在起降点选址优化方面，钱欣悦等[3]建立了基于遗传算法(genetic algorithm, GA)的规划模型，对末端配送物流无人机起降点进行选址；Rajendran 等[4]采用迭代约束聚类方法，通过预测出行需求确定潜在基础设施布局；Rath 等[5]将起降点选址建模为 p 枢纽中位数问题，分析了不同成本约束下的选址方案；Wu 等[6]建立了基于 p-中值枢纽-辐射网络的数学模型，结合地理信息系统(geographic information system, GIS)信息优化起降点布

收稿日期：2025-05-12；**录用日期**：2025-05-30；**网络出版时间**：2025-06-10 15:59
网络出版地址：link.cnki.net/urlid/11.2625.V.20250610.1349.001
基金项目：国家重点研发计划 (2022YFB4300905)；国家自然科学基金 (52572356,52172328)；中央高校基本科研业务费 (NS2024042)
* **通信作者**. E-mail：jiebao@nuaa.edu.cn

引用格式：王炜文，包杰，陈方骁，等. 多源数据驱动的城市低空出行公共航路网络双层规划方法 [J]. 北京航空航天大学学报，2026，52（11）：4107-4121. Wang W W，Bao J，Chen F X，et al. A bi-level programming method for urban low-altitude travel public air route network driven by multi-source data [J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：4107-4121（in Chinese）.

局。在航路网络规划方面，Wang等[7]通过对比分析枢纽辐射网络与传统航空网络的差异，建立了大都市圈城市空中交通网络优化模型；Li等[8]采用双层规划方法，结合多目标模拟退火（multi-objective simulated annealing, MOSA）算法，实现低空物流运输网络布局与流量分配的协同优化；Willey等[9]将子图同构方法与单分配p-中心选址问题相结合，构建了结构化航路网络。低空飞行需求的日益增长离不开高效的交通流量分配技术。唐志星等[10]考虑飞行任务效益和空域利用率，提出以最小化时间调整量为目标的空中交通流量分配模型；王兴隆等[11]基于复杂网络理论构建机场-航路-管制扇区相依网络模型，以网络总流量熵最小为目标，提出降低网络功能脆弱性的流量分配策略；张兆宁等[12]基于容流匹配，构建了机场群流量分配模型，通过多目标规划方法优化机场群内各机场的流量分配，减少航班延误，提高机场群容量利用率。

尽管面向低空出行的公共航路网络规划设计取得了一定进展，但现有研究仍存在以下4个方面不足：①现有低空出行公共航路网络规划大多聚焦网络拓扑结构、起降点选址的宏观规划与设计，侧重建设成本、区域可达性、可持续性等多重目标，缺乏对个体出行者的理性选择考量，忽略了面向用户均衡的交通网络配流，无法形成“网络供给”与“出行需求”的有效互馈机制，导致航路网络的鲁棒性不足；②现有研究大多基于用例数据或仿真数据进行网络优化模型的验证，对低空运行环境的刻画粒度不够精细，未考虑城市环境中实际的人流分布特征、建筑物高度特征与城市用地属性及无人机的坠地风险和噪声影响等，导致现有优化方案的适用性较差；③面向城市低空出行的低空航段路阻函数尚不清楚，无法明晰低空出行公共航路飞行时间与网络流量的相互影响关系，部分研究尝试沿用地面交通的路阻函数，忽略了地面载具与低空飞行器的运动特性差异，导致交通网络的配流方案无法适配低空出行用户的出行需求分布特征；④安全间隔、最短航段长度等网络结构参数对低空出行公共航路网络优化设计影响显著，其与低空网络结构及交通需求分配的关联机理仍需进一步探究。

鉴于此，本文提出多源数据驱动的城市低空出行公共航路网络双层规划方法，研究构建航路网络规划与低空需求分配的互馈优化机制，提出面向低空出行的航段路阻函数标定方法，设计混合进化搜索求解算法；在此基础上，面向典型大都市，提取空域、建筑物、用地、人流及噪声分布等多源城市数据，建立面向低空出行公共航路网络规划的多层风险态势图；基于提出的双层规划方法，对比算法性能，分析优化网络的拓扑特性与流量分布特征，结合敏感性实验，讨论安全间隔、最短航段长度对低空出行公共航路网络优化的作用机理。

1 模型构建

1.1 问题描述与假设

本文聚焦城市低空出行公共航路网络优化设计问题，主要涉及低空运营主管和个体用户两大利益相关方。低空运营主管单位通过设计低空出行公共航路网络，力求通行效率和服务水平最优；个体用户希望出行时间和费用最少，以期自身效用最大化。具体而言，运营决策者通过调整低空出行公共航路网络结构，结合路阻函数直接影响用户出行需求分配结果，如流量分配、路径选择等；对于用户而言，当网络结构确定时，依据用户均衡原则，用户基于效用最大化自适应路径选择，直至网络交通流量分配达到平衡状态，出行需求分配到低空出行公共航路网络中，形成的流量结果反作用于网络性能，如拥堵程度、出行成本等，进而触发低空出行公共航路网络结构调整。两者目标差异显著，且决策行为存在高度耦合影响，形成双层博弈关系。

低空出行公共航路网络设计和交通需求分配相互影响，增加了低空出行公共航路网络规划问题的复杂性。为有效刻画多主体之间的博弈关系，并降低整体模型的计算复杂度、提升求解效率，本文将低空出行公共航路网络设计建模为双层规划问题 (bi-level programming problem, BLPP)。上层问题聚焦低空出行公共航路网络的结构设计，以降低航路网络的非直线系数、网络长度和通行延误率为目标；将低空出行交通需求分配作为下层问题，以出行效用最大化为目标，通过交通流量在不同网络结构下的分配作为上下层的联系变量，以此形成城市低空出行公共航路网络的双层优化模型，如图1所示。

城市低空出行是面向未来的新型空中交通方式，尚未形成规模化落地应用，服务低空出行的公共航路网络设计相对复杂，影响因素繁多，包含出行交通需求的估算、无人驾驶航空器的性能特性、空域可用性及地面交通的换乘连通性等多个方面。故在低空出行公共航路网络优化建模时，做出如下前提假设：①仅考虑单一高度层的低空出行公共航路网络设计，未涉及多高度层的网络立体结构设计；②借鉴起降点选址研究中的空中出行需求转化方法[5]，为简化模型并降低计算复杂度，将地面出行

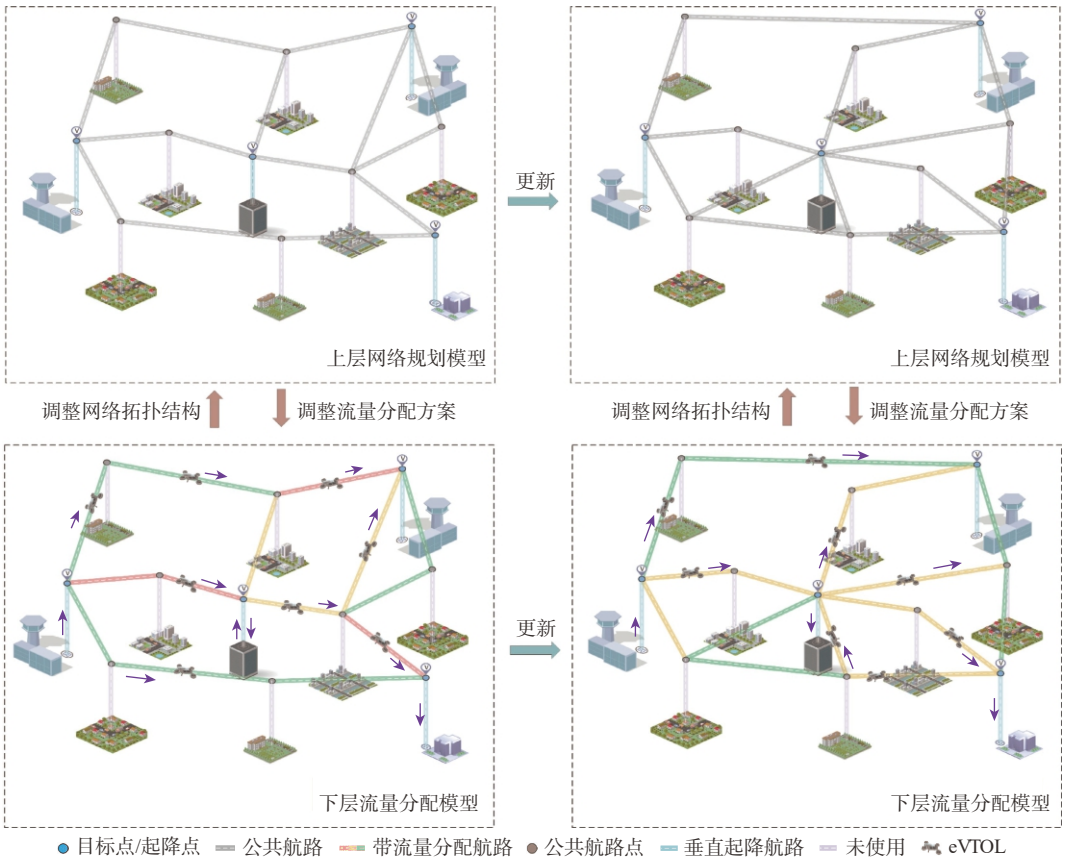


图 1　基于双层规划的低空出行公共航路网络规划示意图

Fig. 1　Schematic diagram of low-altitude travel public air route network planning based on bi-level programming

需求按固定比例转化为低空出行需求; ③低空航空器在公共航路网络中保持匀速飞行, 且保持固定的安全间隔; ④起降点上方空域无限制, 可自由接入低空出行公共航路网络; ⑤不考虑气象条件、通信条件等因素对低空飞行器产生的影响。

1.2　上层网络规划模型

从低空运营主体角度出发, 上层网络规划模型通过调整网络拓扑结构, 实现交通流量的重新分配, 实现通行效率最优。假设低空出行公共航路网络 $G=(N,E)$。其中, $N=\{1,2,\cdots,n\}$为候选航路点集合, 在低空出行公共航路网络规划中, 通过对空域进行栅格化处理, 并进行栅格单元的风险评估分析[13], 选取低于风险阈值的栅格单元中心作为候选航路点; $E=\{e_{ij}|x_{ij}=1, i,j\in N, i\neq j\}$, x_{ij} 为 0-1 决策变量, 用于表征点 i 和点 j 之间是否存在边 e_{ij}, 存在取 1, 不存在取 0, 因此, 上层网络规划模型中, 决策变量 x_{ij} 用于表征任意 2 个候选点之间是否存在航路连接。

在此基础上定义上层网络规划模型, 如式(1)和式(2a)～式(2h)所示。其中, 式(1)表示目标函数, 早期航路网络规划研究中, 常用流量熵、网络长度 L_G 和非直线系数 D_G[8]。

$$\min(C_G, D_G, L_G) \tag{1}$$

$$\text{s.t.}\begin{cases} y_i = 1 \qquad \forall i \in (R \cup S) & (2a)\\ y_i \leqslant \sum\limits_{i,j\in N} x_{ij} \leqslant 8y_i & (2b)\\ y_i \leqslant \sum\limits_{i,j\in N} x_{ji} \leqslant 8y_i & (2c)\\ y_i \leqslant \sum\limits_{j\in N} x_{ij}y_j \qquad \forall i \in N & (2d)\\ \sum\limits_{i\in N} x_{ii} = 0 & (2e)\\ x_{ij}d_{ij} \leqslant d_{\max} = \sqrt{2}d \qquad \forall i,j \in N & (2f)\\ y_i \in \{0,1\} \qquad \forall i \in N & (2g)\\ x_{ij} \in \{0,1\} \qquad \forall i,j \in N & (2h) \end{cases}$$

式中: C_G 为低空出行公共航路网络 G 的平均延误指数; y_i 为 0-1 决策变量, 表示点 i 是否被选入网络 G 中; d_{ij} 为候选航路点 i 与 j 之间的距离; $d_{\max}$ 为网络中航段长度的阈值; d 为离散化空域栅格单元长度; R 和 S 分别为起点集合和讫点集合。

考虑到流量熵在刻画网络流量分布均匀性时, 仅对流量集中的关键路径敏感, 导致网络较为脆弱, 因此, 本文选取网络平均延误指数 C_G 刻画网络流量分配的拥堵状况, 其计算方式为

$$C_G = \frac{1}{|E|}\sum_{e\in E}\frac{t_e}{t_e^0} \tag{3}$$

式中: $|E|$为网络中边的数量; t_e 和 t_e^0 分别为航段 e 的行程时间和畅通行程时间。

除此之外，还选取非直线系数 D_G 及网络长度 L_G 作为上层网络规划模型的优化目标函数。具体而言，D_G 表示低空出行公共航路网络 G 的非直线系数，用于刻画航路网络的几何效率和路径绕行程度，计算方式为

$$D_G = \frac{1}{|R||S|}\sum_{r\in R,s\in S}\frac{l_{rs}}{d_{rs}} \tag{4}$$

式中：$|R|$和$|S|$分别为起点和讫点的数量；l_{rs} 和 d_{rs} 分别为从起点 r 到讫点 s 的网络中最短路径距离和平面欧氏距离。

低空出行公共航路网络 G 的总长度 L_G 与占用的空域资源呈正相关：

$$L_G = \sum_{e\in E} d_e \tag{5}$$

式中：d_e 为边 e 的长度。

进一步地，式 (2a)～式 (2f) 表示上层低空出行公共航路网络规划设计需满足的约束条件。其中，约束（2a）为起讫点（origin-destination, OD）约束，用于确保起降点一定在路径中；约束（2b）和约束（2c）为节点度约束，确保当点 i 在网络中时，其出度和入度不为 0，点 i 不在网络中时，其出度和入度均为 0；约束（2d）确保选择的点相邻；约束（2e）确保不存在自环；约束（2f）确保存在连边的 2 个点距离不大于阈值；约束（2g）表示 y_i 为 0-1 决策变量，表示点 i 是否在网络 G 中。

1.3 下层流量分配模型

从低空出行用户角度出发，下层流量分配模型根据上层网络规划模型输出的网络拓扑结构，考虑用户路径选择行为，对用户出行需求进行交通流量分配，实现低空出行公共航路网络交通流量分配。在下层流量分配模型中，决策变量 x_e 为非负连续变量，表征边 e 上分配的交通流量。

下层流量分配模型表达式为

$$Z = \min\sum_{e\in E}\int_0^{x_e} t_e(x)\mathrm{d}x \tag{6}$$

$$\text{s.t.}\begin{cases} q^{rs} = \sum_{k\in K_{rs}} f_k^{rs} & \forall r,s \quad (7a)\\ x_e = \sum_{r\in R}\sum_{s\in S}\sum_{k\in K_{rs}} f_k^{rs}\delta_{ek}^{rs} & e\in E \quad (7b)\\ x_e \geqslant 0 & e\in E \quad (7c)\\ f_k^{rs} \geqslant 0 & \forall r,s,k \quad (7d)\end{cases}$$

式中：$t_e(x)$ 为航段 e 的行程时间，其大小与边 e 的交通流量相关，采用路阻函数计算得出；K_{rs} 为低空出行公共航路网络 G 中连接起点 r 与讫点 s 的全部可行路径构成的集合；q^{rs} 为从起点 r 到讫点 s 的出行需求；f_k^{rs} 为分配在 OD 对（r,s）间第 k 条路径的流量；δ_{ek}^{rs} 为 0-1 指示变量，当且仅当边 e 位于 OD 对（r, s）的第 k 条路径时，其值为 1，否则为 0。

针对低空出行公共航路网络设计问题，目前尚缺乏成熟的经验路阻函数，本文在 1.4 节对其进行专门阐述。

式 (7a)～式 (7d) 为下层流量分配模型的约束条件。约束（7a）表征路径-路段流量守恒关系；约束（7b）表征多条路径流量与边 e 流量的映射关系，以确保边 e 的流量 x_e 等于所有 OD 对经过该边的路径流量总和；约束（7c）和约束（7d）为非负流量约束，确保网络各边流量和路径分配流量均满足非负条件。

1.4 低空出行公共航路航段路阻函数设计

路阻函数（也称为阻抗函数或成本函数）是交通网络分析中的核心工具，用于量化出行者在不同路径上的广义出行成本（如时间、距离、能耗、风险等），因此，路阻函数的设计直接影响用户路径选择的行为和下层低空交通需求分配的结果。现有研究和工程实际中，较为常用的路阻函数包括美国联邦公路局（Bureau of Public Roads, BPR）函数和 Davidson 函数。本文以 BPR 函数作为参考依据，建立基于航路时段流量的低空出行公共航路航段路阻函数模型，将航段路阻函数定义为

$$t_e = t_e^0\left[1+\alpha\left(\frac{q_e}{c_e}\right)^{\beta}\right] \tag{8}$$

式中：q_e 为交通流量；c_e 为路段交通承载能力；α 和 β 为阻滞系数，在地面路网中，其通常分别为 0.15 和 4。

考虑到地面出行和低空出行的特性不同，交通流的运行机理和影响因素存在差异，因此，需要进一步分析低空交通流特性，对阻尼参数进行标定。

在低空出行公共航路网络运行中，飞行器间需要保持一定的安全间距，与民航中采用的固定安全间隔不同，低空无人航空器可以悬停，速度随交通流量变化的调整反馈更为及时，其运动特性与地面车辆跟驰行为更为接近。故本文假设低空航空器之间的安全间距 l_{safe} 为制动距离 l_{brake} 的 $2n$ 倍（考虑对向冲突可能性），即 $l_{\text{safe}}=2nl_{\text{brake}}$，相应地，安全时距 t_{safe} 为制动时间 t_{brake} 的 $2n$ 倍，即 $t_{\text{safe}}=2nt_{\text{brake}}$。因此，在长度为 l_e 的航段 e 上，最大可容纳的低空飞行器数量为 l_e/l_{safe}，则在时间窗 T 内，航段 e 可以安全通过的流量 q_{safe} 为 T/t_{safe}。

根据航空器的物理运动特性可知，其制动距离 l_{brake} 与制动时间 t_{brake} 均与航空器平均飞行速度 v_e 和制动加速度 a 存在如下关系：

$$l_{\text{brake}} = \frac{v_e^2}{2a} = \frac{(at_{\text{brake}})^2}{2a} = \frac{at_{\text{brake}}^2}{2} \tag{9}$$

在航段上, 航空器并非总能以自由流速度飞行。当航段在时间窗内的流量超过一定阈值时, 航空器必须降低平均飞行速度以保证安全间隔, 该阈值表示在时间窗 T 内, 航空器平均飞行速度 v_e 为自由流速度 v_0 时, 航段所能承载的最大容量 $q^*_{\text{safe}}=T/t^*_{\text{safe}}$, 其中, t^*_{safe} 为航空器以自由流速度 v_0 运行时, 为满足安全要求所需保持的最小安全时间间隔(安全时距)。

因此, 当时段流量 q_e 小于或等于阈值 q^*_{safe} 时, 航段 e 处于自由流运行状态, 此时, 航空器通过该航段的平均时间 t_e 为 l_e/v_0; 而当 q_e 大于阈值 q^*_{safe} 时, 航空器通过航段平均时间 t_e 为 $2nq_el_e/(aT)$。

综上, 航段通过平均时间 t_e 计算公式可表示为

$$t_e=\begin{cases} l_e/v_0 & q_e\leqslant q^*_{\text{safe}} \\ 2nq_el_e/(aT) & q_e>q^*_{\text{safe}} \end{cases} \tag{10}$$

基于式(10), 通过数值模拟仿真进行 BPR 函数的参数标定。考虑不同的飞行性能参数对安全间隔的影响, 模型中的电动垂直起降飞行器(electric vertical take-off and landing, eVTOL)参数设置参考亿航智能 EH216-S 和 Archer Aviation 的 Midnight, 并综合城市空中交通运行条件、乘客出行舒适度等因素, 将 eVTOL 巡航速度和最大制动加速度分别设置为 45 m/s 和 10 m/s^2。自由流速度 v_0=45 m/s、制动加速度 a=10 m/s^2、时间窗 T=3 600 s 时的标定结果如表 1 所示。不难发现, 随着航段长度增加, 时间窗内航段饱和容量与自由流状态航段行程时间均呈现上升趋势, 阻滞系数在一定范围内呈小幅波动, 决定系数 R^2 整体维持在较高水平, 进一步验证了本文构建的航段路阻函数模型的合理性。此外, 低空出行公共航路网络的路阻函数中, α 和 β 取值分别为 0.25 和 5.13, 与地面交通阻尼系数相比, α 和 β 的值较大, 表明航路在拥堵时的通过时间增长更为显著, 且通过时间的增长对流量变化更加敏感。

表 1　参数标定结果

Table 1　Parameter calibration results

航段长度/m	时间窗内航段饱和容量/(架·h^{-1})	自由流状态航段行程时间/s	阻滞系数α	阻滞系数β	决定系数R^2
2 000	84.652	44.003	0.246	5.130	0.976
2 150	85.654	47.303	0.261	5.130	0.976
2 300	84.872	50.604	0.249	5.130	0.976
2 450	86.724	54.013	0.278	5.130	0.976
2 600	88.019	57.314	0.300	5.130	0.976
2 750	85.755	60.724	0.262	5.130	0.976
2 900	86.373	63.804	0.272	5.130	0.976

2　算法设计

面向低空出行公共航路网络设计的双层规划模型, 具体算法结构如图 2(a)所示。上层网络规划模型算法生成初始网络结构, 作为初始解传至下层流量分配模型; 下层流量分配模型基于接收到的网络结构, 考虑用户均衡特性, 进行用户出行分配, 形成低空出行公共航路网络配流方案, 并反馈给上层网络规划模型; 上层网络规划模型计算该配流方案下的各优化目标值, 如网络平均延误指数、非直线系数及网络长度, 并进行解的更新和迭代; 上下层模型不断互馈迭代, 最终达到均衡状态, 形成最优低空出行公共航路网络设计结果。

在上层网络规划模型中, 解的编码、更新和迭代可以通过多目标启发式算法实现, 如常用的 MOSA 算法和非支配排序遗传算法(nondominated sorting genetic algorithm II, NSGA-II)[8]。

在下层流量分配模型中, 研究主要参考道路交通流量分配的用户均衡理论[14], 通过 Frank-Wolfe 算法进行目标函数的线性化转换, 具体流程可以参考文献 [15]。研究针对上层网络规划模型改进求解算法设计, 提出了多目标模拟退火-遗传算法 (multi-objective simulated annealing-genetic algorithm, MOSA-GA), 考虑到 MOSA 解的多样性与全局搜索能力较为突出, 而 NSGA-II 在算法收敛性和解的筛选效率方面表现更优, 因此, 通过结合 2 种算法, 可以有效平衡解迭代过程的收敛性和多样性, 在保证搜索效率的同时, 提升跳出局部最优与规避过慢收敛的能力, 具体算法流程如图 2(b)所示, 其中, T_i 为 MOSA 第 i 次迭代的温度参数。

上层低空出行公共航路网络规划模型主要基于路径生成的机制, 具体步骤如下:

1) 生成解编码, 计算解编码映射的网络拓扑结构性指标, 包括非直线系数和网络长度, 并将生成的网络结构传递给下层流量分配模型。

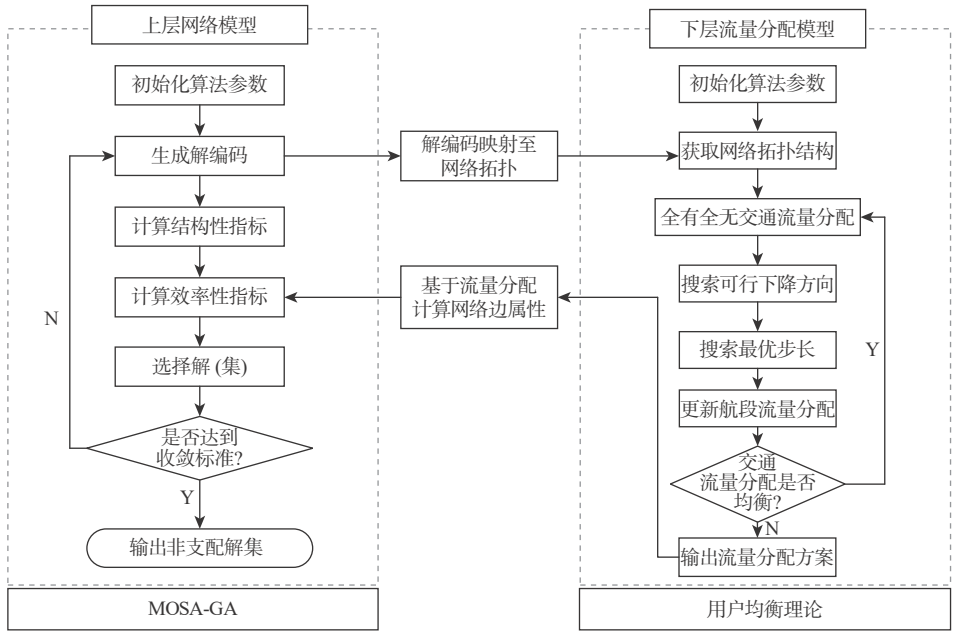
2) 下层网络获取解编码映射的网络结构, 基于用户均衡原理进行交通流量分配, 并输出网络配流方案, 反馈至上层网络规划模型用于计算网络效率性指标, 如延误指数。

3) 上层网络进一步优化调整网络结构, 重复上述步骤直至双层模型间的迭代过程收敛。

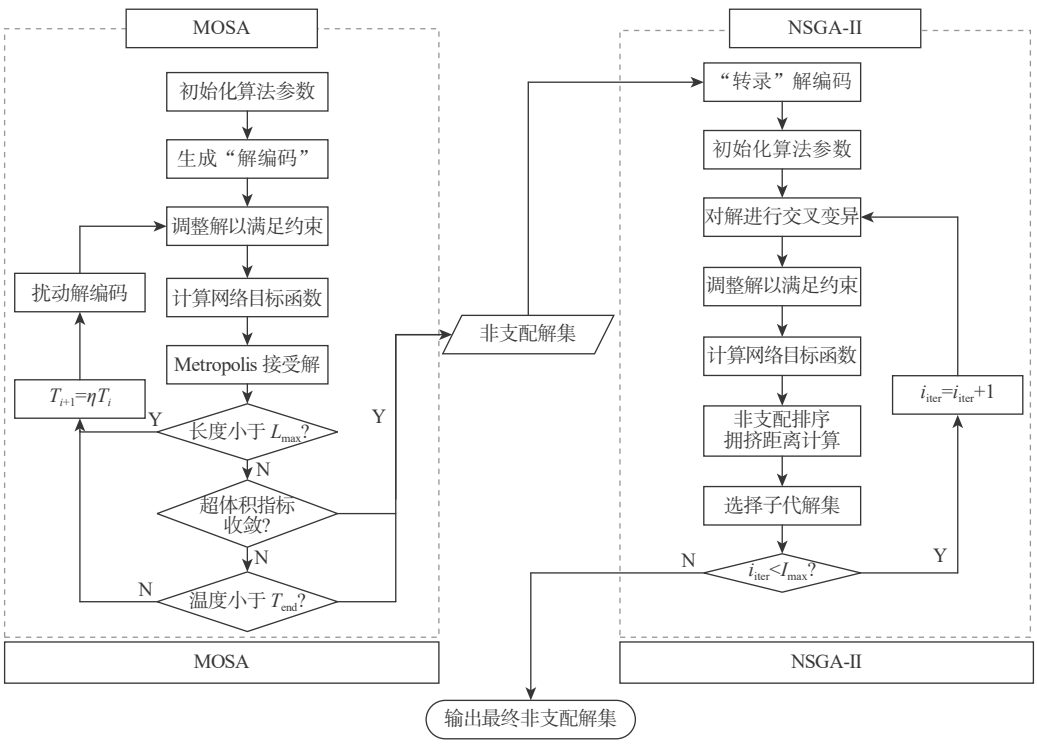
上述步骤中, 由于涉及 2 种算法交互, 结合低空出行公共航路网络规划问题的特点, 需要对算法的解编码问题进行专门设计, 其中, MOSA 编码流程具体如下:

1) 基于航路候选点集, 利用 K 最短路径(K shortest paths, KSP)算法[16]搜索 OD 间多条最优可行路径, 构建候选路径集合, 并以该集合作为候选解空间, 相较于传统基于最短路径的网络设计方法, KSP 算法可以提高候选解的多样性, 如图 3(a)所示, 其中, W_n 为候选航路点。

2) 采用二进制编码表示路径选择状态, 编码长



(a) 面向低空出行公共航路网络设计的双层规划模型框架



(b) MOSA-GA 算法设计流程框架

图 2 算法设计框架示意图

Fig. 2 Algorithm design framework diagram

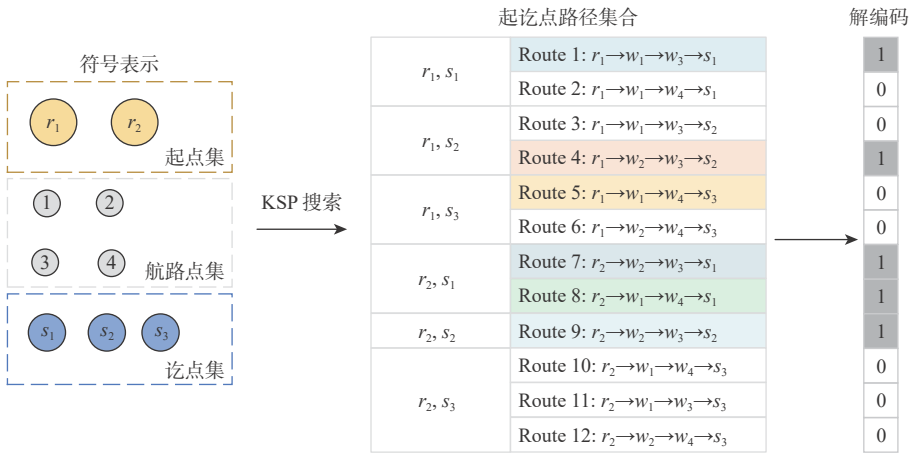
度等于候选路径集合大小，编码值为 1 表示对应路径被选入生成网络，值为 0 则表示未选入。

3）在初始解生成或扰动操作中，可能出现某个 OD 对无通路的情形。此时，需进行解的修复操作，如图 3(b)所示，可以从候选路径集中选取该 OD 对间的一条或多条路径，并将其编码值由 0 修改为 1，从而实现修复操作。

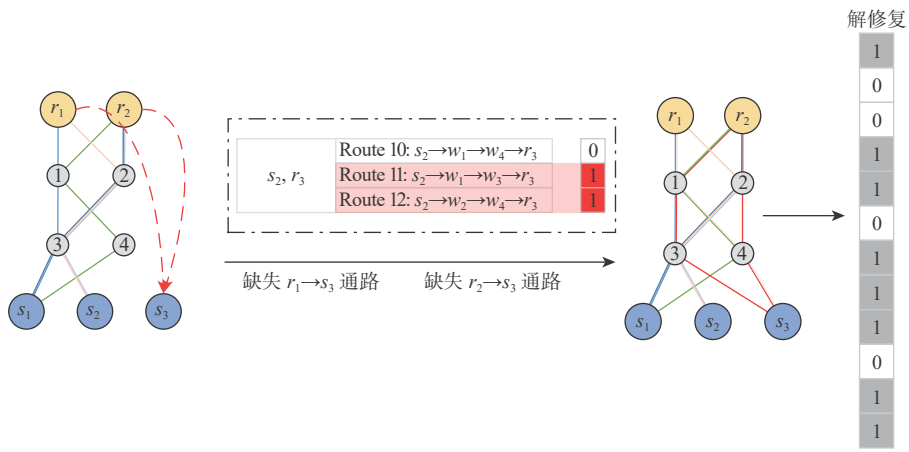
考虑到 MOSA 和 NSGA-II 在解编码设计的差异，进一步设计了两者之间的编码转录流程，通过编码转录，可以实现从基于路径的解编码到基于航段的解编码的转换，并确保解的一致性，在此基础上进行解的更新迭代，具体流程如下：

1）将 MOSA 输出的非支配解集进行转录，将候选路径解映射为航路点的连边关系，并进行二进制编码，从而实现解的转录操作，如图 4 所示。

2）对编码进行交叉和变异操作，生成新的候选解，并对新解进行检查，若违反约束条件，如存在 OD 对不连通，则同样需要进行解修复操作。



(a) 面向低空航路网络设计的 MOSA 编码方式



(b) MOSA 候选解修复机制

图 3　MOSA 编码与候选解修复示意图

Fig. 3　Schematic diagram of MOSA coding and candidate solution repair

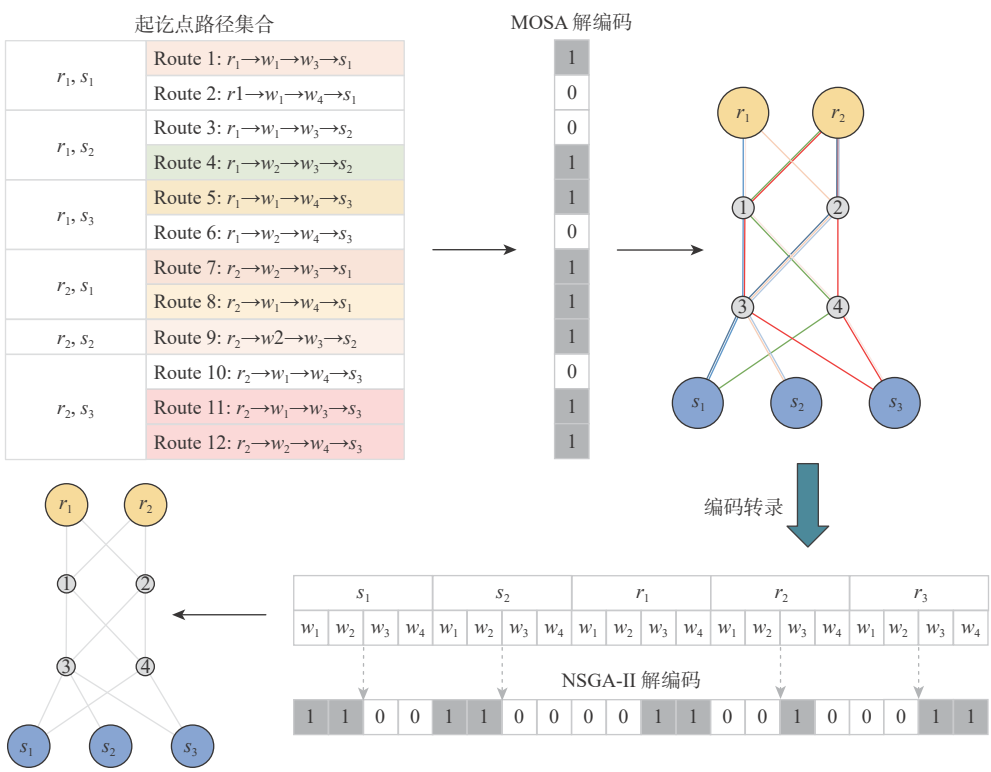
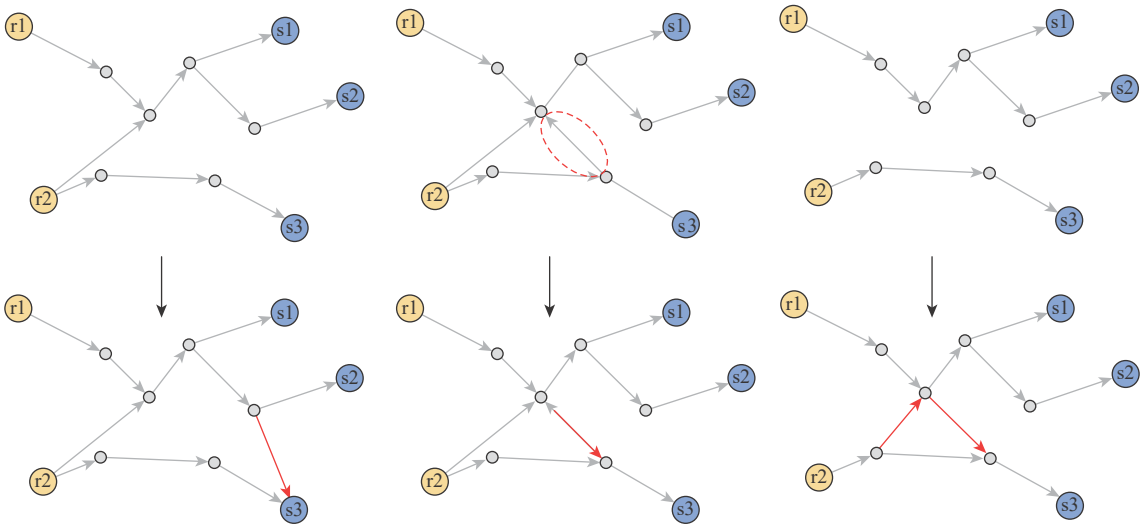


图 4　编码转录示意图

Fig. 4　Coding transcription schematic diagram

3）随机选择一对未连通的OD对，对其进行修复操作，如图5所示。若在同一分量内，将网络视为无向图，在其关联路径中搜索可使该OD对连接的边，并将其作为有向边添加到网络中；若不在同一分量，分别提取起点和讫点所在分量的节点集合，检查是否存在可连接的跨分量边。



(a) 起讫点缺少通路，一个子图分量无向图，不存在可能边　(b) 起讫点缺少通路，一个子图分量无向图，存在可能边　(c) 起讫点缺少通路，多个子图分量

图5　NSGA-II拓扑修复机制示意图

Fig. 5　Schematic diagram of NSGA-II topology repair mechanism

4）若存在可连接边，随机选择边加入网络中，并返回步骤2）继续执行，直至所有OD对连通。若不存在有效连接方案，则舍弃当前解。

算法的具体伪代码实现过程如下：

输入：①航路网输入：飞行器速度 v、制动加速度 a、安全间隔系数 n、时间窗 T、航路网络结构 G、OD集合 R 和 S；②MOSA参数输入：初始温度 T_0、温度下降率 η、马尔可夫链长度 $L_{\max}$、超体积收敛阈值 ε_1、超体积最大连续收敛次数 $t_{\max}$、强制结束温度 T_{end}；③NSGA-II参数输入：最大进化次数 $I_{\max}$、种群大小 N_{pop}、变异概率 p_{m}、交叉概率 p_{c}。

输出：非支配解集。

MOSA部分：

1. 初始化参数，随机生成初始解

2. while MOSA温度 $\geqslant T_{\text{end}}$ and 超体积连续收敛计数 $t_{\text{c}} \leqslant t_{\max}$ do

3. 扰动当前解生成新解

4. 对新解进行可行性检查与修复（详见MOSA编码步骤3））

5. 使用Frank-Wolfe算法进行用户均衡交通流量分配

6. 基于流量分配计算目标函数值

7. Metropolis准则接受新解

8. 计算超体积，判断是否收敛

9. return 初步非支配解集

NSGA-II部分：

10. 初始化参数，转录MOSA非支配解编码

11. while 迭代次数 $i_{\text{iter}} \leqslant I_{\max}$ do

12. 执行非支配排序，确定非支配解集

13. 选择前 N_{pop} 精英解，基于概率进行交叉变异操作生成新解

14. 对新解进行可行性检查（NSGA-II编码步骤2）～4））

15. 使用Frank-Wolfe算法进行用户均衡交通流量分配

16. 基于流量分配计算目标函数值

17. 更新算法参数

18. return 非支配解集

3　案例分析

3.1　多源数据采集与处理

城市低空出行公共航路网络规划需要结合传统用户出行信息、城市用地属性、建筑物高程分布及可用空域信息等进行起降点的选取和可用航路点的筛选，在此基础上，运用本文提出的双层规划模型进行低空出行公共航路网络的优化方案。鉴于此，选取纽约市作为实验案例，这是因为高质量的城市规划和交通数据可开源访问方便低空运行环境的风险评估和优化方案的应用性验证。本文涉及的多源数据来源、类型和用途如表2所示。

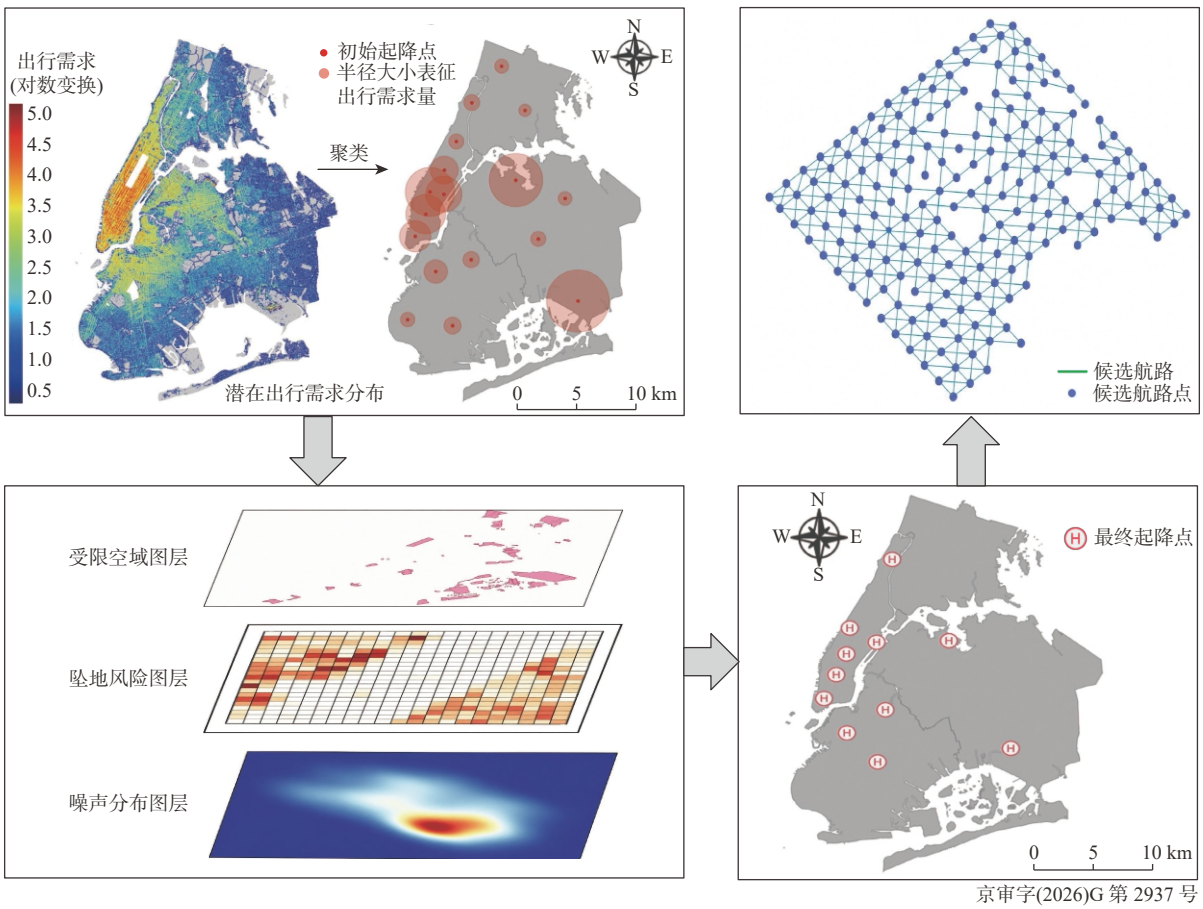
纽约市位于美国东北部，是美国人口最多的城市，同时也是世界最大的商业和金融中心。研究首

表 2　数据来源及用途

Table 2　Data sources and uses

数据类型	来源	用途
出租车出行记录	https://data.cityofnewyork.us/Transportation/2015-Yellow-Taxi-Trip-Data/2yzn-sicd/about_data	挖掘并刻画潜在低空出行需求分布
城市用地属性	https://data.cityofnewyork.us/City-Government/Primary-Land-Use-Tax-Lot-Output-PLUTO-/64uk-42ks/about_data	获取敏感空域分布及用地特征信息
建筑物高程分布	https://data.cityofnewyork.us/City-Government/3-D-Building-Model/tnru-abg2/about_data	获取建筑物高程分布及机场等重要设施位置
噪声投诉数据	https://data.cityofnewyork.us/Social-Services/Noise-Complaints-in-2017-/be8n-q3nj	刻画噪声敏感区域分布

先选取 2015 年 3 月市区范围的大规模出租车出行记录, 剔除出行距离小于 10 km、出行范围位于研究区域外、出行费用和速度异常的记录信息, 作为未来低空潜在出行需求, 具体需求分布如图 6 第 1 幅图左面所示。参考文献 [17] 的空间聚类方法, 识别出初始候选起降点位置(如图 6 第 1 幅图右面所示)。



京审字(2026)G 第 2937 号

图 6　多源数据驱动的垂直起降点选址和空域栅格化处理

Fig. 6　Multi-source data-driven vertiports location and airspace rasterization processing

在此基础上, 基于采集的城市用地特征和建筑物高程数据, 识别警务机构、消防设施、机场净空区等敏感区域, 构建敏感区域图层; 此外, 依据文献 [13] 提出的低空坠地风险评估方法和文献 [18] 提出的无人机噪声评估方法, 并基于采集的多源数据, 建立低空坠地风险态势图和噪声影响核密度分布图, 如图 6 第 2 幅图所示。

经过上述多源图层的进一步过滤, 最终选取面向城市低空出行公共航路网络运行的起降点选址方案, 如图 6 第 3 幅图所示, 图中, 起降点的大小与该位置的出行需求呈正相关。在此基础上, 结合起降点选址的分布范围, 选取西经 74.25°～73.75°、北纬 40.50°～41.00°作为低空出行公共航路网络的规划范围, 参考文献 [18] 的数字空域栅格化方法对研究范围进行空域栅格化处理, 选取 2 000 m 作为栅格单元大小, 结合低空坠地风险态势图和噪声核密度影响分布图, 过滤满足低空出行公共航路网络规划使用的栅格单元, 并将其栅格中心作为候选航路点, 如图 6 第 4 幅图所示。

3.2　算法参数设置与性能对比

在上述基础上, 使用本文提出的双层规划模型及 MOSA-GA 进行低空出行公共航路网络规划设计。算法的具体参数设置如表 3 所示。

研究选取反转世代距离(inverted generational

表3 算法参数设置

Table 3 Algorithm parameter settings

自由流速度/(m·s^{-1})	飞行器最大制动加速度/(m·s^{-2})	时间窗/s	MOSA初始温度/℃	MOSA结束温度/℃	马尔可夫链长度	MOSA超体积收敛阈值	Frank-Wolfe收敛阈值	NSGA-II最大进化次数	NSGA-II种群大小	NSGA-II变异概率	NSGA-II交叉概率
45	10	3 600	10	0.1	50	10^{-6}	10^{-4}	100	100	10^{-4}	1

distance, IGD)指标，通过计算每个在真实帕累托前沿面上的点(个体)到算法获取的个体集合之间的最小距离和，评估多目标算法的收敛性能和非支配解集的分布性能。

如图7所示，算法在初始迭代阶段IGD值较高，这与MOSA产生的初步非支配解集质量相关。随着迭代次数增加，IGD值整体呈现下降趋势，表明算法的收敛性能逐渐提升。

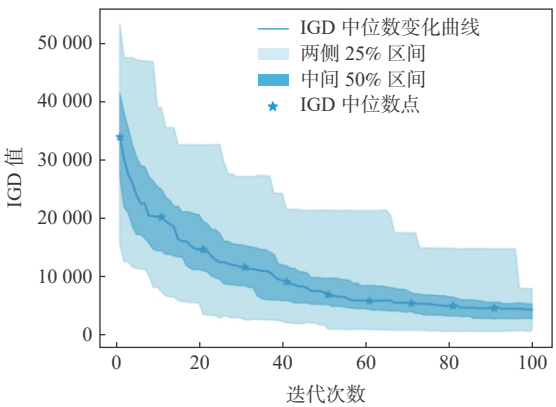


图7 IGD随迭代次数变化趋势及分布

Fig. 7 The variation trend and distribution of IGD with the number of iterations

同时，IGD值的分布区域在早期迭代阶段宽广，说明此阶段解较为离散，不确定性较高；在迭代后期，分布区间缩小，算法的解逐步稳定，IGD趋于收敛，说明算法表现出较好的稳定性和收敛性。

当上层网络规划模型采取不同启发式搜索算法时，求解性能具有显著差异，各算法的帕累托前沿面结果如图8所示。进一步地，结合图9不难发现，MOSA-GA和NSGA-II的解集在多个目标上的分布比MOSA更加均匀。在各目标函数表现方面，MOSA-GA在网络长度上峰值比NSGA-II高约20.0%，但在延误指数和出行时间总和上分别比NSGA-II降低约7.6%和14.3%；2种算法在非直线系数上表现相当。与MOSA相比，MOSA-GA在延误指数、非直线系数和出行时间总和的峰值接近，但解集分布更广，且在网络长度上峰值比MOSA峰值减小了约25%。

综上所述，MOSA-GA兼具MOSA在延误和出行时间控制上的优势及NSGA-II在网络长度优化方面的能力，实现了空域资源利用与出行效率的平衡，提升了解的实用性和可行性。

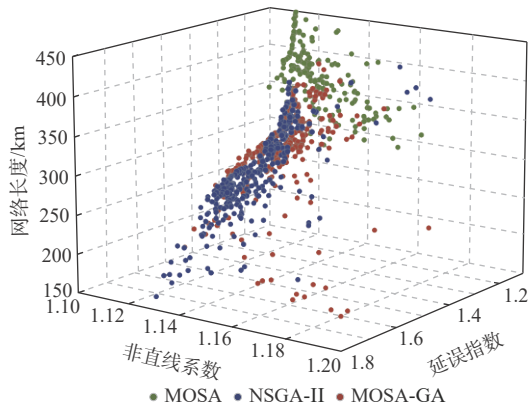


图8 3种算法前沿分布

Fig. 8 Front distribution of three algorithms

3.3 模型结果分析

图10分别呈现了低空出行公共航路网络双层规划的4类结果，分别对应最优延误指数网络(网络Ⅰ)、最优非直线系数网络(网络Ⅱ)、最优网络长度网络(网络Ⅲ)及最优出行时间总和网络(网络Ⅳ)。从图10中4类优化目标网络的流量分布特征可以看出，各网络在流量分配策略与结构布局方面存在显著差异：网络Ⅰ、网络Ⅱ和网络Ⅳ表现出较为均衡的流量分布，但部分航段利用效率较低，存在冗余路径；而网络Ⅲ的流量高度集中于少数主干航段，整体结构紧凑但冗余度较低，在高负荷下存在通行瓶颈。

多目标航路网络优化结果如表4所示。延误指数、非直线系数及出行时间总和最优的网络综合性能接近；而网络长度最优方案虽展现近45%的航路里程缩减优势，但核心航路交通负荷过大，导致出行时间激增，这表明网络时空效能与建设成本呈现显著权衡关系。

为进一步揭示城市低空出行公共航路网络拓扑特征与交通流负荷的关系，采用介数中心性指标对航路点和航段进行分析，结果如图11(a)所示。该指标通过量化节点(边)在最短路径中的出现频率，表征其在交通流传输中的枢纽作用。统计结果表明，流量主要集中于高介数中心性的航段边，表明这些航段作为城市低空交通网络的关键通道，承担着核心流量的传输功能。在此基础上，研究分析优化后的低空出行公共航路网络拓扑结构特性。

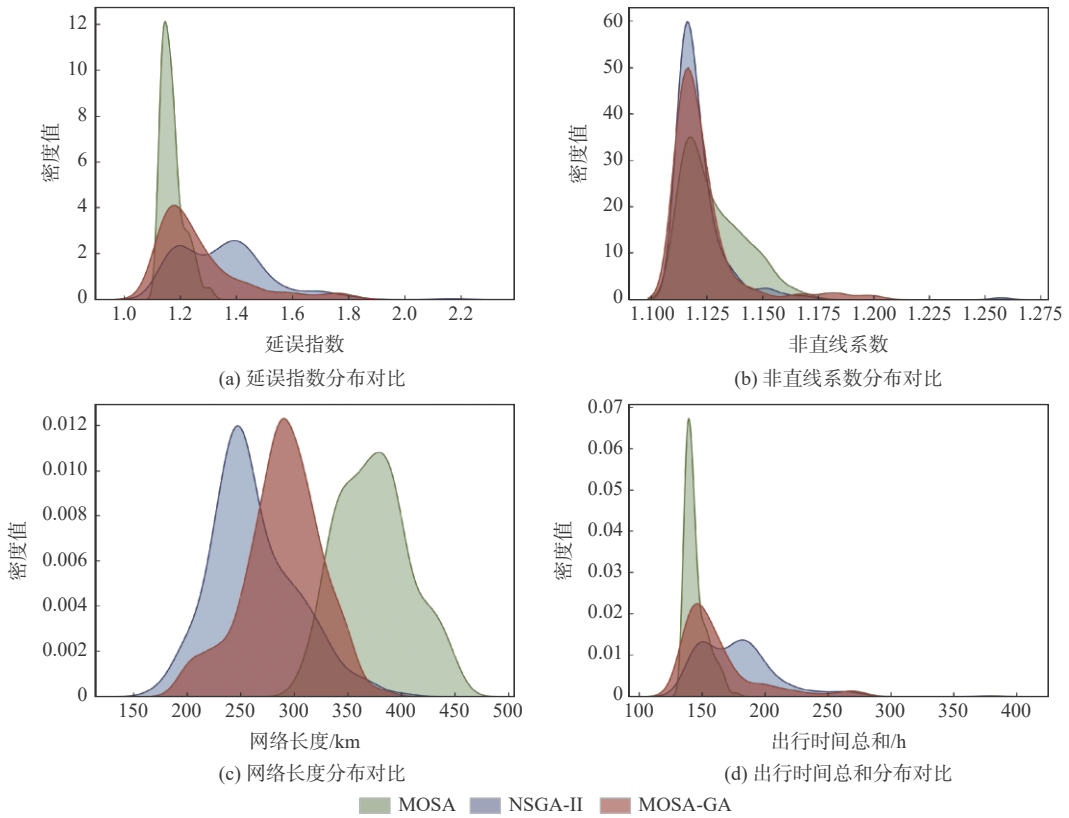


图 9　3 种算法目标函数分布

Fig. 9　Objective function distribution of three algorithms

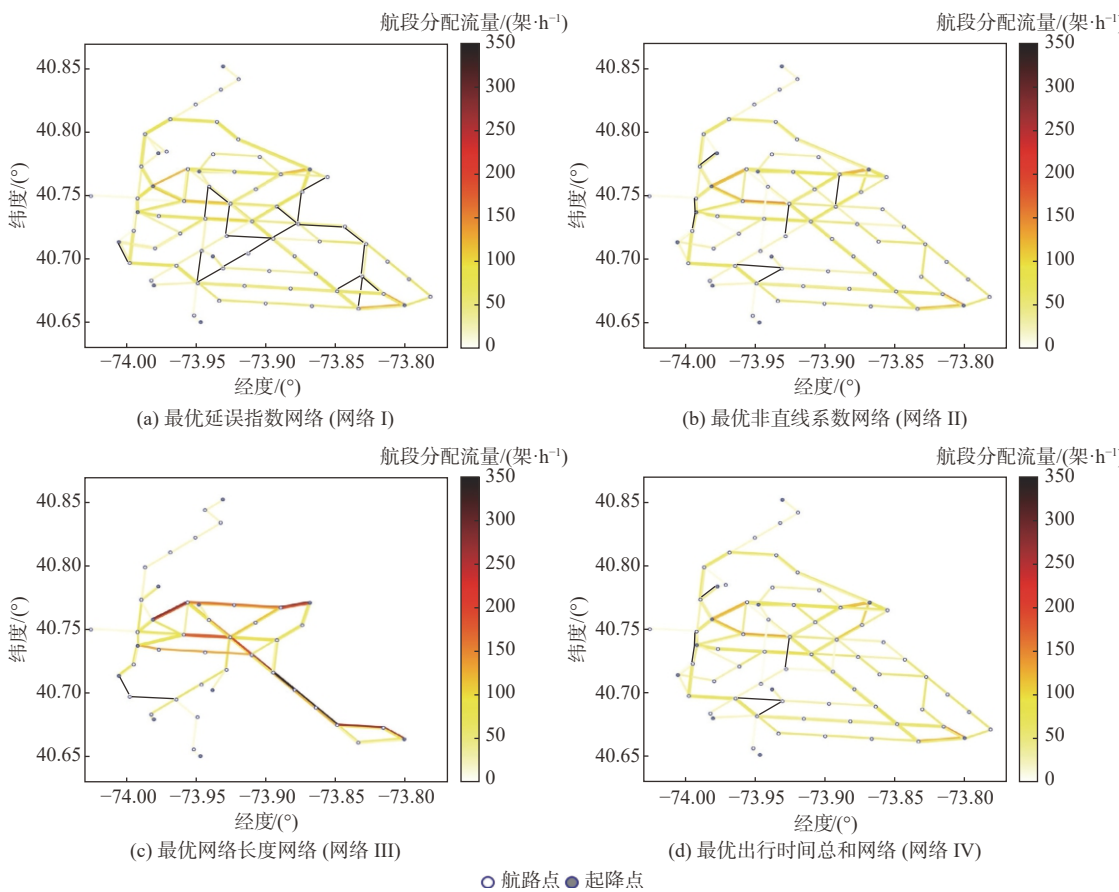


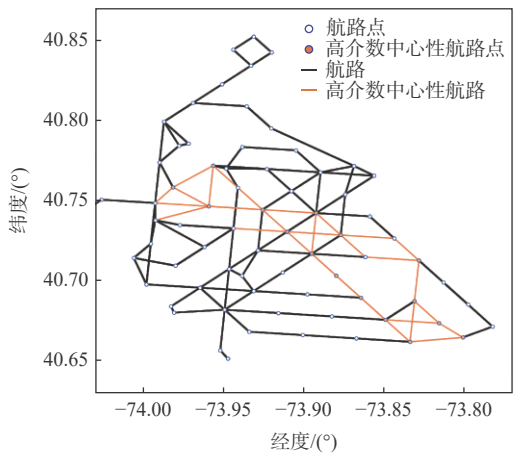
图 10　低空出行公共航路网络优化结果示意图

Fig. 10　Schematic diagram of low-altitude travel public air route network optimization results

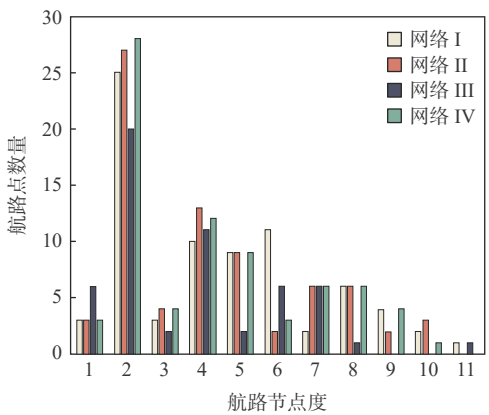
表 4 最优网络目标函数值

Table 4 Optimal network objective function value

网络/目标函数	延误指数	网络长度/km	非直线系数	出行时间总和/h
网络Ⅰ	1.111 77	384.8	1.121 26	136.49
网络Ⅱ	1.118 24	352.7	1.113 31	135.75
网络Ⅲ	1.808 09	195.4	1.200 54	264.32
网络Ⅳ	1.115 51	354.2	1.115 44	135.69



(a) 介数中心性高的节点及边分布



(b) 航路节点度分布

图 11 航路网络拓扑分析结果

Fig. 11 Air route network topology analysis result

节点度分布统计结果如图 11(b)所示，网络拓扑中以低度节点为主。核心区域存在高度值枢纽节点，其承担的交通流量显著高于普通节点，形成网络流量依赖的脆弱节点。

3.4 目标函数间相关性分析

进一步分析非支配解集的三维分布特征，结果表明，非支配解在目标空间中呈现凹形曲面分布特征，初步揭示了目标函数之间的权衡关系。为解析多目标优化中目标函数间的权衡机制，本节通过计算非支配解目标函数间的皮尔逊相关系数，揭示了目标函数之间的内在关联。

目标函数之间的分布关系如图 12 所示，通过将点投影到坐标面上，以呈现目标函数间的相互关系。具体而言，延误指数与非直线系数之间的皮尔逊相关系数为 0.68，呈显著正相关，表明非直线系数升高时，路径迂回程度增加，导致网络整体通行效率下降；延误指数与网络长度之间的皮尔逊相关系数为−0.92，呈强负相关性，表明网络规模的扩展通过增加 OD 间的可选路径，能够显著降低延误指数；非直线系数与网络长度之间的皮尔逊相关系数为−0.58，呈负相关性，表明网络长度变化较小时，非直线系数主要受局部路径结构的影响。

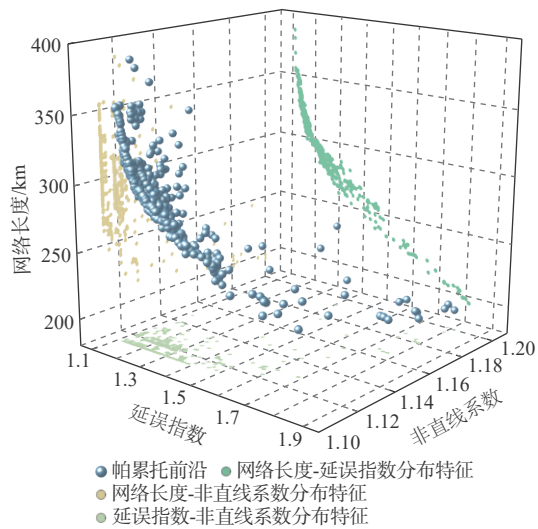


图 12 帕累托前沿分布

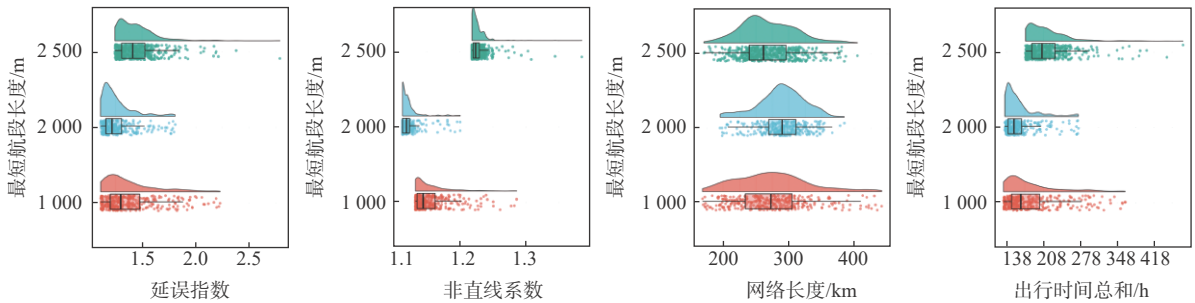
Fig. 12 Pareto frontier distribution

3.5 敏感性分析

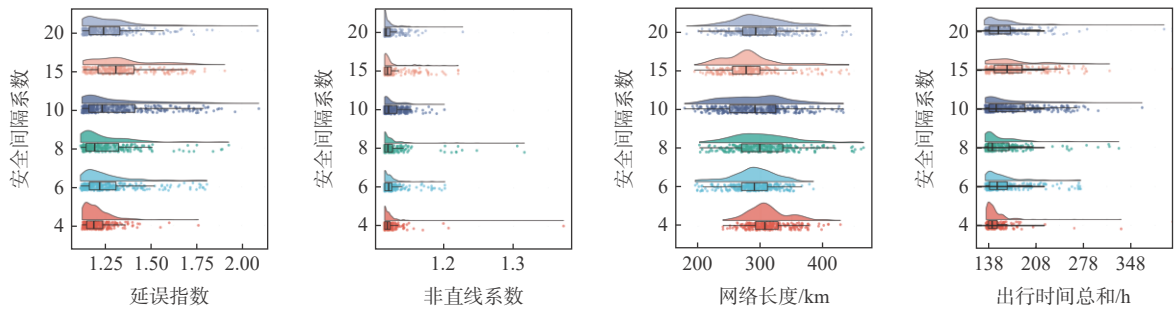
在飞行程序设计中，区域导航航段的最短距离是指 2 个航路点之间能够保证飞行安全和导航精度的最小距离。如果最短航段长度过短，可能导致航空器无法在短时间内完成必要的飞行姿态调整，从而降低航路网络的飞行安全性；若最短航段长度过长，则会增加不必要的飞行距离和时间，进而降低航路网络的整体飞行效率。

在实验设计中，考虑到最短航段长度(本文中即栅格单元长度)和安全间隔对目标函数值的影响较为显著，进行了 2 组敏感性实验分析。

第 1 组实验聚焦于最短航段长度的影响，设置了 3 种不同的最短航段长度(1 000 m、2 000 m 和 2 500 m)，对其在各项性能指标下的表现进行对比分析，结果如图 13(a)所示。不难看出，最短航段长度对延误指数、非直线系数、网络长度及出行时间总和目标函数均产生了显著影响。最短航段长度为 1 000 m 时，网络连接更密集，路径选择性多，但可能出现低效航段的比例增加，加剧了网络的延误；最短航段长度为 2 500 m 时，网络路径选择受限，主干航段流量集中，也加剧了通行延误和系统负荷。



(a) 目标函数随最短航段长度的变化



(b) 目标函数随安全间隔系数的变化

图 13　参数敏感性分析结果

Fig. 13　Parameter sensitivity analysis results

相比之下, 模型最短航段长度设置为 2 000 m 时, 延误指数和出行时间总和相对较低, 非直线系数处于合理范围, 显示出较优的通行效率和路径合理性。

第 2 组实验主要聚焦安全间隔参数 n 的影响, 对 6 组间隔标准 n=4,6,8,10,15,20 进行了对比实验, 以探究安全间隔对航路性能的影响。图 13(b)的结果表明, 随着安全间隔的增大, 延误指数呈上升趋势, 从 n=4 时的均值 1.2 增大到 n=15 时的 1.35, 表明增大安全间隔会降低网络通行能力。当安全间隔增加, 时间窗内的航段安全容量降低, 网络在某些区域采用更远的替代路径, 导致非直线系数上升, 整体分布更加离散。网络长度在区间内波动, 表明模型在安全约束下维持了合理的网络规模。出行时间总和与安全间隔呈正相关, 但增速较慢, 主要受航段容量限制的制约。

4　结　论

本文立足现有城市低空出行公共航路网络研究, 综合考虑航路网络规划和用户出行需求特性, 构建双层航路网络规划模型, 提出 MOSA-GA 求解算法, 并基于城市多源数据, 对面向城市居民低空出行的公共航路网络设计进行研究分析, 主要结论如下:

1) MOSA-GA 在双层网络规划模型求解中, 有效平衡了解集的分布广度与目标函数优度, 显著提升了航路网络运行效率。

2) 多目标函数之间存在显著的制约关系, 单一优化某一目标将导致其他目标性能下降, 并对下层流量分配模型中的用户出行时间总和产生影响。

3) 双层规划模型对最小航段长度与安全间隔参数表现出敏感性, 在优化过程中, 需合理设定相关参数, 以保证模型性能与航路网络的可行性。

4) 受出行需求分布和可用空域资源的约束, 优化后的网络呈现流量向主干航路聚集的特征, 导致部分航段利用效率相对较低。

低空出行尚处于探索和变革阶段, 运行规则和管控机制尚不清晰, 后续研究可拓展如下方面: ①鉴于低空出行服务对象对出行时间具有较高敏感性, 本文仅选取出租车数据作为低空出行的潜在需求, 而都市出行中, 地铁、公交等多种出行方式也占据重要地位, 未来研究需要对出行用户的出行行为进行更为全面和细致的刻画; ②联合城市低空出行公共航路网络与地面交通网络的规划设计, 形成考虑空地多式联乘的航路网络规划方案; ③随着低空经济的发展, 多网融合技术快速迭代, “通、导、监”一体化技术日益成熟, 低空通信质量及网络信号覆盖可以纳入低空出行公共航路网络规划设计的考量中, 提升低空出行公共航路网络规划方案的工程应用性。

参考文献 (References)

[1] 廖小罕, 屈文秋, 徐晨晨, 等. 城市空中交通及其新型基础设施低空公共航路研究综述[J]. 航空学报, 2023, 44(24): 1-29.
Liao X H, Qu W Q, Xu C C, et al. A review of urban air mobility and its new infrastructure low-altitude public routes[J]. Acta Aero-

nautica et Astronautica Sinica, 2023, 44(24): 1-29(in Chinese).

[2] 中国人民大学课题组. 中国低空经济城市发展指数 (LCDI) 2025(发布版)[EB/OL]. [2025-04-30]. http://keyan.ruc.edu.cn/docs/2025-03/ae9eb3d4bb36483fbf7489577e5ba097.blk.pdf.
Research Group of Renmin University of China. China low-altitude economy urban development index 2025 (release)[EB/OL]. [2025-04-30]. http://keyan.ruc.edu.cn/docs/2025-03/ae9eb3d4bb36483fbf7489577e5ba097.blk.pdf(in Chinese).

[3] 钱欣悦, 张洪海, 张芳, 等. 末端配送物流无人机起降点选址分配问题研究[J]. 武汉理工大学学报 (交通科学与工程版), 2021, 45(4): 682-687.
Qian X Y, Zhang H H, Zhang F, et al. Research on location allocation of UAV landing points for terminal distribution logistics[J]. Journal of Wuhan University of Technology (Transportation Science & Engineering), 2021, 45(4): 682-687(in Chinese).

[4] Rajendran S, Zack J. Insights on strategic air taxi network infrastructure locations using an iterative constrained clustering approach[J]. Transportation Research Part E: Logistics and Transportation Review, 2019, 128: 470-505.

[5] Rath S, Chow J Y J. Air taxi skyport location problem with single-allocation choice-constrained elastic demand for airport access[J]. Journal of Air Transport Management, 2022, 105: 102294.

[6] Wu Z Q, Zhang Y. Integrated network design and demand forecast for on-demand urban air mobility[J]. Engineering, 2021, 7(4): 473-487.

[7] Wang K, Li A Y, Qu X B. Urban aerial mobility: network structure, transportation benefits, and Sino-US comparison[J]. The Innovation, 2023, 4(2): 100393.

[8] Li S, Zhang H H, Yi J, et al. A bi-level planning approach of logistics unmanned aerial vehicle route network[J]. Aerospace Science and Technology, 2023, 141: 108572.

[9] Willey L C, Salmon J L. A method for urban air mobility network design using hub location and subgraph isomorphism[J]. Transportation Research Part C: Emerging Technologies, 2021, 125: 102997.

[10] 唐志星, 黄山, 潘卫军. 灵活使用空域中的空中交通流量分配方法研究[J]. 兵器装备工程学报, 2019, 40(12): 90-94.
Tang Z X, Huang S, Pan W J. Research on scheduling method for air traffic flow allocation in FUA[J]. Journal of Ordnance Equipment Engineering, 2019, 40(12): 90-94(in Chinese).

[11] 王兴隆, 齐雁楠, 潘维煌. 基于功能脆弱性的空中交通相依网络流量分配[J]. 航空学报, 2020, 41(4): 179-187.
Wang X L, Qi Y N, Pan W H. Flow allocation of air traffic interdependent network based on functional vulnerability[J]. Acta Aeronautica et Astronautica Sinica, 2020, 41(4): 179-187(in Chinese).

[12] 张兆宁, 王帝. 基于容流匹配的机场群流量分配策略研究[J]. 现代电子技术, 2019, 42(22): 113-116.
Zhang Z N, Wang D. Research on flow allocation strategy based on capacity matching for airport group[J]. Modern Electronics Technique, 2019, 42(22): 113-116(in Chinese).

[13] 陈艺君, 余莎莎, 张学军. 城市低空场景下无人机运行对地风险量化评估[J]. 北京航空航天大学学报, 2025, 51(3): 806-815.
Chen Y J, Yu S S, Zhang X J. Ground risk quantitative assessment for UAV operations in urban low-altitude scenarios[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(3): 806-815(in Chinese).

[14] Wardrop J G, Whitehead J I. Correspondence. some theoretical aspects of road traffic research[J]. Proceedings of the Institution of Civil Engineers, 1952, 1(5): 767-768.

[15] Frank M, Wolfe P. An algorithm for quadratic programming [J]. Naval Research Logistics Quarterly, 1956, 3(1-2): 95-110.

[16] Liu H P, Jin C Q, Yang B, et al. Finding top-k shortest paths with diversity[J]. IEEE Transactions on Knowledge and Data Engineering, 2018, 30(3): 488-502.

[17] Lim E, Hwang H. The selection of vertiport location for on-demand mobility and its application to Seoul metro area[J]. International Journal of Aeronautical and Space Sciences, 2019, 20(1): 260-272.

[18] Wang Z, Delahaye D, Farges J L, et al. Route network design in low-altitude airspace for future urban air mobility operations: a case study of urban airspace of Singapore[C]//Proceedings of the International Conference on Research in Air Transportation. Tampa: International Conference on Research in Air Transportation, 2022.

A bi-level programming method for urban low-altitude travel public air route network driven by multi-source data

WANG Weiwen[1], BAO Jie[1,*], CHEN Fangxiao[1], ZHOU Jun[1], YANG Zhao[2]

(1. College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China;
2. College of General Aviation and Flight, Nanjing University of Aeronautics and Astronautics, Liyang 213300, China)

Abstract: Urban low-altitude travel is the core of high-quality development in the low-altitude economy and an important link for enabling low-altitude empowerment and economic radiation. For urban low-altitude public flight routes, this study suggests a multi-source data-driven dual-layer planning approach that creates a feedback optimization mechanism between low-altitude demand allocation and flight route network planning. A road impedance function calibration method tailored for low-altitude travel is presented, and the multi-objective simulated annealing-genetic algorithm (MOSA-GA) hybrid evolutionary algorithm is designed for solution search. Finally, taking a typical metropolitan area as a case study, multi-source urban data such as airspace, buildings, land use, pedestrian flow, and noise distribution are extracted, and the proposed dual-layer planning method is validated through comparison. The experimental findings demonstrate that the MOSA-GA algorithm successfully strikes a compromise between the optimality of the goal functions and the diversity of the solution set, greatly enhancing the low-altitude route network's operational efficiency. The solution results yield multiple Pareto-optimal solutions that are mutually non-dominated, with significant trade-offs between multiple objectives, which impact traffic flow allocation. Additionally, sensitivity analysis reveals that safety intervals and minimum segment lengths significantly affect the network optimization outcomes. The research findings are expected to guide the deployment of urban low-altitude public flight route networks and improve the level of low-altitude travel services.

Keywords: urban air mobility; low-altitude public air route network; bi-level programming model; traffic assignment; multi-objective optimization

Received: 2025-05-12; **Accepted**: 2025-05-30; **Published Online**: 2025-06-10 15:59

URL: link.cnki.net/urlid/11.2625.V.20250610.1349.001

Foundation items: National Key Research and Development Program of China (2022YFB4300905); National Natural Science Foundation of China (52572356,52172328); the Fundamental Research Funds for the Central Universities (NS2024042)

* **Corresponding author**. E-mail: jiebao@nuaa.edu.cn

http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2025.0417

基于轻量化 YOLOv8n 的无人机视角目标检测算法

宋骏宇[1,2]，庞岩[1,2,*]

(1. 大连理工大学 工业装备结构分析优化与 CAE 软件全国重点实验室，大连 116024；
2. 大连理工大学 辽宁省空天飞行器前沿技术重点实验室，大连 116024)

摘 要：在无人机 (UAV) 视角下的目标检测任务中，为使其在有限资源内保证目标检测精度，提出一种轻量化 YOLOv8n 的无人机视角下目标检测算法 YOLOv8n-WMCBS。采用 Wise-IoU v3 为网络整体损失函数，动态聚焦低质量预测框；引入 MobileNetV3 网络与坐标注意力 (CA) 机制骨干网络，降低参数量与计算复杂度；引入小目标检测层与检测头，并去除大目标检测层，保留小目标细节特征和位置信息，减少模型计算负担；设计残差幻影卷积 (RGConv)，进一步增强骨干网络的特征丰富性，与双向特征金字塔网络 (BiFPN) 模块结合作为新颈部网络模块，增强颈部网络的动态特征融合；提出改进的非跨步空深卷积 (Conv-SPD) 取代原跨步下采样，充分保留高分辨率小目标信息。实验结果表明：在 VisDrone 2019 数据集中，改进算法在参数量降低 40.5% 和模型文件大小减小 35.5% 的同时，mAP0.5 和 mAP0.5:0.95 较原算法分别提升 4.6% 和 2.9%，表明模型有着良好的检测效果和更好的轻量化性能。

关 键 词：YOLOv8；无人机；损失函数；小目标检测层；轻量级网络
中图分类号：V19; TP183; TP391.41
文献标志码：A **文章编号**：1001-5965(2026)11-4122-13

无人机因其灵活、成本低且轻便易携带等优点，可在各种危险或复杂的场景中执行任务，使其自主巡检技术得到了迅速发展。而 YOLO[1] 系列的单阶段目标检测算法简洁的网络结构有着更快的推理速度，降低了对设备硬件和计算资源的需求，因此，该算法成为目标检测领域内的一大研究热点。然而，无人机视角下图像目标常呈现小尺寸、低分辨率及分布密集等特点，将目标检测模型部署在无人机等边缘设备并提高图像小目标检测精度仍极具挑战性，因此，无人机视角下目标检测算法研究广受关注。Tan 等[2] 首次提出一种加权双向特征金字塔网络 (bidirectional feature pyramid network, BiFPN)，改进 YOLOv8 算法颈部路径聚合网络-特征金字塔网络 (path aggregation network and feature pyramid network, PAN-FPN)，增强了模型多尺度特征融合能力。张瑞芳等[3] 在 BiFPN 基础下设计双向加权多尺度动态颈部网络，实现了浅层与深层特征深度融合，显著提升小目标检测精度。李金凤等[4] 在无人机红外小目标检测中，针对小目标检测问题在原颈部网络插入坐标注意力 (coordinate attention, CA)，有效增强了红外小目标的边缘响应。潘玮等[5] 融合感受野注意力卷积 (receptive-field attention convolution, RFAConv)[6] 与卷积块注意力模块 (convolutional block attention module, CBAM)[7]，并在空间池化金字塔模块中融入大核可分离卷积注意力 (large separable kernel attention, LSKA)[8]，增强骨干网络特征提取的同时，提升了不同层间的语义融合。Yuan 等[9] 为解决面部穴位检测表面无明显物理特征与几何形状问题，采用广义交并比 (generalized intersection over union, GIoU)[10] 损失函数，既关注检

收稿日期：2025-06-30；录用日期：2025-11-14；网络出版时间：2025-12-30 16:10
网络出版地址：link.cnki.net/urlid/11.2625.V.20251230.1323.004
*通信作者. E-mail：ypang@dlut.edu.cn

引用格式：宋骏宇，庞岩. 基于轻量化 YOLOv8n 的无人机视角目标检测算法 [J]. 北京航空航天大学学报，2026，52（11）：4122-4134.
Song J Y，Pang Y. UAV perspective target detection algorithm based on lightweight YOLOv8n[J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（11）：4122-4134（in Chinese）.

测帧的重叠区域, 也关注非重叠区域, 极大程度增强了模型面部物体检测能力和面部穴位关键点检测。为解决 YOLOv8 回归损失函数无法优化宽高值不同、纵横比相同的预测框与真实框问题, Ma 等[11]提出一种基于最小点距离的交并比 (minimum point distance intersection over union, MPDIoU), 包含了现有损失函数的所有相关因素。

尽管以上改进方法在目标检测任务中取得了不错效果, 但也存在模型过大、计算复杂度较高及在复杂场景中难以定位分布密集的目标等问题。即目前无人机视角下的目标检测任务仍存在以下难点: ①模型性能与计算资源需求的矛盾; ②航拍目标尺度多变且目标分布密集; ③背景复杂、小目标定位困难。

对于以上无人机视角下目标检测存在的问题, 本文提出一种基于 YOLOv8n 的改进算法——YOLOv8n-WMCBS。针对无人机等平台资源受限问题, 为平衡模型效率与精度, 改进算法引入 MobileNetV3-Small 网络, 嵌入 CA 形成轻量化骨干网络, 降低网络复杂度与计算量, 有效保留了目标细粒度坐标信息。同时, 特征传递路径引入残差幻影卷积 (residual ghost convolution, RGConv), 对冗余特征进行压缩与重建, 进一步降低了模型的参数量与计算复杂度; 针对目标尺度多变、目标分布密集问题, 颈部网络采用 BiFPN, 构建了多路径特征融合网络, 强化网络对小目标特征的表达能力, 提升多尺度检测性能; 新增 P2 小目标检测层和检测头替代原 P5 检测层, 以降低模型复杂度, 提升模型小目标感知能力; 改进 Wise-IoU v3 损失函数以降低模型小目标的尺度敏感性。

1　改进算法结构

在无人机航拍目标检测任务中, 存在小目标居多、复杂遮挡、目标尺度跨度较大、背景复杂等问题, 而原 YOLOv8n[12]算法采用跨阶段局部网络 (cross stage partial net, CSPNet)[13]的骨干网络, 全局感受野过大, 难以聚焦小目标局部细节, 其中, 三阶段检测头 (P3～P5) 缺少高分辨率浅层目标信息, 且在多次上下采样后易导致特征丢失, 使该算法对无人机视角下中小目标检测精度不高, 且容易造成误检和漏检。因此, 本文提出一种改进的轻量化 YOLOv8n 无人机视角下目标检测算法, 改进算法的具体网络结构如图 1 所示。

1) 改进 Wise-IoU 损失函数。采用 Wise-IoU v3 损失函数, 根据目标尺寸动态调整梯度增益, 降低低质量边界框的负面影响, 进一步提升模型整体小

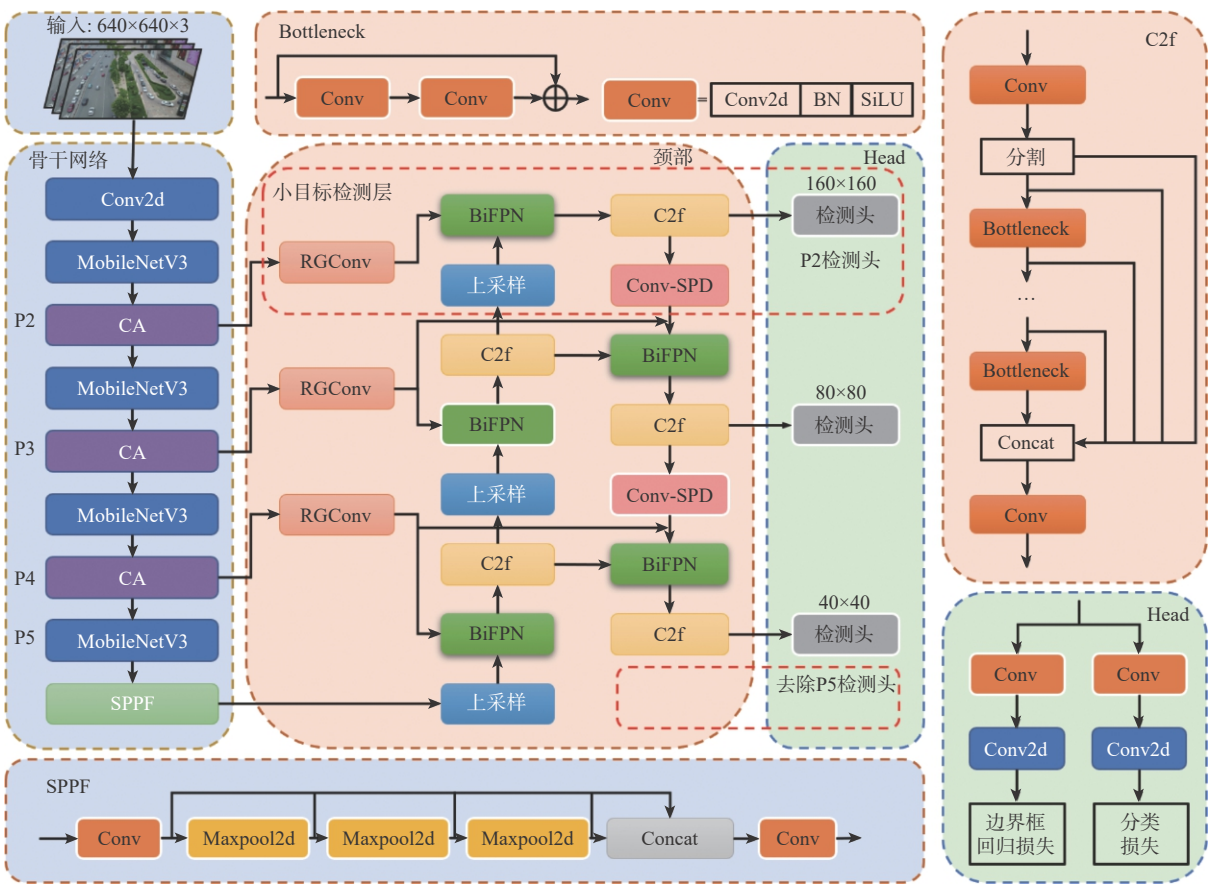


图 1　YOLOv8n-WMCBS 算法网络结构

Fig. 1　Network architecture of YOLOv8n-WMCBS algorithm

目标检测性能。

2）改进轻量化的骨干网络。采用MobileNetV3-Small作为轻量化的基础特征提取骨干网络，融合CA机制构建MobileNetV3-CA模块，增强浅层特征的空间定位能力，确保网络移动端部署友好性。

3）引入小目标检测层。在原始P3～P5检测头基础上新增高分辨率的P2小目标检测层与检测头，移除感知能力不高的P5大目标低分辨率检测头，减轻计算负担的同时，提升网络对高分辨率小目标的感知能力。

4）设计多尺度特征增强模块。设计RGConv模块作为特征传递路径，结合BiFPN形成新的颈部网络模块，增强多尺度特征丰富性与融合能力，实现跨层级语义-细节信息互补。

5）改进下采样。为解决原网络频繁下采样易导致的小目标细节信息丢失问题，本文采用改进非跨步空深卷积(convolution-space-to-depth, Conv-SPD)取代传统跨步卷积，充分保留高分辨率小目标空间信息。

2 改进算法设计

2.1 损失函数改进

原算法采用完整交并比(complete intersection over union, CIoU)[14]和分布焦点损失(distribute focal loss, DFL)[15]形成边界框损失回归，DFL方法以交叉熵形式，使网络更快聚焦到目标位置和临近区域，随后由CIoU损失函数对预测框和真实框进行损失计算。然而，无人机视角目标检测任务中，CIoU损失函数存在明显不足：①未考虑低质量与高质量样本的平衡，对低质量样本的惩罚可能会对模型整体训练产生较大影响；②当预测框与真实框无重叠(交并比为0)时，梯度计算失效，导致困难样本无法被有效优化。针对上述问题，提出Wise-IoU v3[16]作为边界框损失函数，可在降低低质量样本产生有害梯度的同时，显著提升模型对小目标和困难样本的回归精度。

Wise-IoU v3通过基于低质量预测框离群度指标β生成一个非单调的动态聚焦系数r，并将r应用于Wise-IoU v1中，由此得到Wise-IoU v3。当β值较小，基于该值的动态聚焦权重r也越小时，表示预测框的质量较高，此时，降低高质量预测框在损失函数中的权重，相反，若β值较大，则表示一个低质量的预测框，此时，为其分配一个小的梯度增益，从而降低该低质量样本产生的有害梯度。因此，Wise-IoU v3通过这种梯度增益分配策略，动态优化了损失中低质量和高质量预测框的权重，使该模型聚焦于平均质量的样本，从而提升模型整体检测性能。该函数公式为

$$\begin{cases} R_{\mathrm{WIoU}}=\exp\left[\dfrac{(b_{cx}^{\mathrm{gt}}-b_{cx})^2+(b_{cy}^{\mathrm{gt}}-b_{cy})^2}{c_w^2+c_h^2}\right] \\ L_{\mathrm{IoU}}=1-b_{\mathrm{IoU}} \\ L_{\mathrm{WIoUv1}}=R_{\mathrm{WIoU}}L_{\mathrm{IoU}} \\ \beta=\dfrac{L_{\mathrm{IoU}}^{*}}{L_{\mathrm{IoU}}}\in[0,+\infty) \\ r=\dfrac{\beta}{\delta\alpha^{\beta-\delta}} \\ L_{\mathrm{WIoUv3}}=rL_{\mathrm{WIoUv1}} \end{cases} \tag{1}$$

式中：R_{WIoU}为惩罚因子；b_{cx}^{gt}、b_{cy}^{gt}和b_{cx}、b_{cy}分别为真实框和预测框的中心坐标；c_w和c_h分别为真实框与预测框最小外接矩形的宽和高；b_{IoU}为真实框与预测框交集面积除以并集面积，即交并比；L_{IoU}为基础损失，反映边界框的重叠质量；L_{WIoUv1}和L_{WIoUv3}分别为加权交并比损失v1版本和加权交并比损失v3版本；L_{IoU}^{*}为移动平均交并比损失；α和δ为调节超参数，分别控制损失缩放强度和曲线陡峭度。

2.2 骨干网络改进

2.2.1 MobileNetV3

MobileNetV3[17]为Google团队提出的轻量级卷积神经网络，以低参数量和计算复杂度为特点，旨在提高模型在移动端设备上的速度和准确性，这也使其更适合计算资源受限的嵌入式设备等边缘计算设备。该网络继承了此前版本的深度可分离卷积和倒残差瓶颈结构，在上一版本瓶颈结构基础上引入轻量级挤压和激励(squeeze and exciation, SE)[18]注意力模块和改进非线性Hard-swish激活函数。

MobileNetV3网络将倒残差瓶颈与SE注意力机制结合，结构如图2所示。输入图像经1×1卷积扩张，随后通过深度卷积进行升维，并应用SE注意力机制，筛选对网络性能更好的特征通道权重，抑制对网络性能不好的特征通道权重，得到各通道的权重，输入特征图与得到的权重相乘，优化生成的特征图，使用1×1逐点卷积减少通道数并输出，增强每个通道的特征信息捕捉能力。当步长为1且输入和输出通道数相等时，进行残差连接，而当步长为2时，直接输出下采样的特征图。

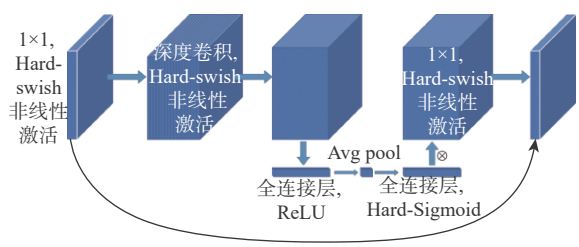


图2 瓶颈结构示意图

Fig. 2 Schematic diagram of the bottleneck structure

考虑到无人机等边缘设备计算资源的限制, MobileNetV3 网络有着参数量小、特征提取能力强、较高的移动端设备适配性等特点, 本文采用该网络 Small 版本作为改进的骨干网络进行特征提取, 该网络由 11 个 Bottleneck 瓶颈层、3 个卷积层组成, 为进一步减轻计算负担, 去除最后 4 层, 保留该网络核心部分。

2.2.2　坐标注意力

大量移动网络设计研究表明, 通道注意力(如 SE 等注意力模块)对模型性能有显著的提升, 然而, 这些注意力通常忽略位置信息。MobileNetV3 作为骨干网络, 轻量化的同时, 瓶颈结构可能忽略细粒度的空间位置信息, 故在此之后引入 CA 机制[19], 其专为移动网络设计而提出, 仅全局平均池化和少量 1×1 卷积, 与 MobileNetV3 的轻量化设计高度兼容。

受 Cai 等[20]在改进 YOLOv8 的无人机水稻图像生长阶段识别研究中启发, 根据 CA 模块在 MobileNetV3 骨干网络不同层之间的影响, 经验证, 在输出特征图尺度分别为 160 像素×160 像素、80 像素×80 像素、40 像素×40 像素处应用该模块时得到最优效果。CA 模块结构如图 3 所示。

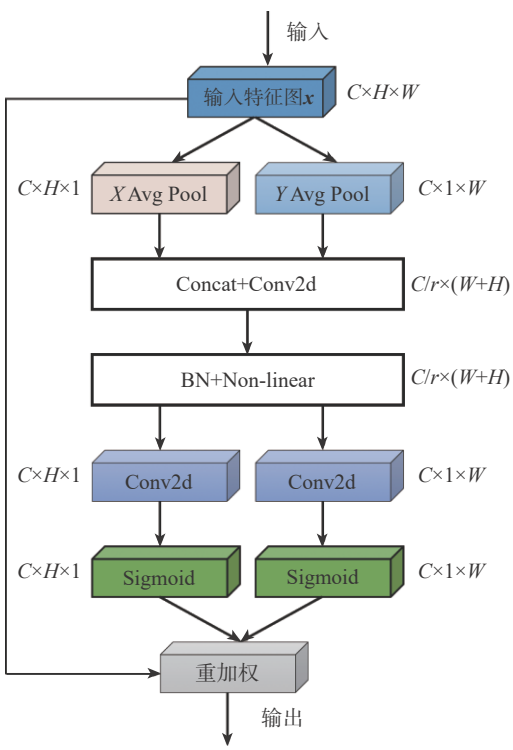


图 3　CA 结构

Fig. 3　CA structure

CA 模块将位置信息嵌入通道注意力中, 尤其是在需要空间选择性注意力的视觉任务中, 与传统的通道注意力机制不同, CA 将特征张量分别沿 2 个垂直和水平方向聚合形成 2 个特征图, 随后, 特征图被分别编码为注意力图, 于是, 每个注意力图都能捕获输入特征图沿一个方向的远程依赖关系, 又能保留沿另一个空间方向的精确位置信息。具体而言, 给定输入特征图 $\boldsymbol{x}$, 经过 2 个大小为 $(H,1)$ 和 $(1,W)$ 的池化核全局平均池化后, 分别沿水平坐标和垂直坐标对每个通道进行编码, 以生成 $C\times H\times 1$ 和 $C\times 1\times W$ 大小的特征图, 输出表示为

$$z_{\mathrm{c}}^{h}(h)=\frac{1}{W}\sum_{0\leqslant i\leqslant W}\boldsymbol{x}_{\mathrm{c}}(h,i) \tag{2}$$

$$z_{\mathrm{c}}^{w}(w)=\frac{1}{H}\sum_{0\leqslant j\leqslant H}\boldsymbol{x}_{\mathrm{c}}(j,w) \tag{3}$$

式中: z_{c}^{h}和z_{c}^{w}分别为通道沿高度 h 和宽度 w 方向的输出; $\boldsymbol{x}_{\mathrm{c}}$ 为输入特征图。

将生成的 2 个聚合特征图拼接后, 通过共享 1×1 卷积进行降维处理, 并生成新特征图, 输出为

$$\boldsymbol{f}=\sigma(F_1([z_{\mathrm{c}}^{h},z_{\mathrm{c}}^{w}])) \tag{4}$$

式中: $\boldsymbol{f}$为对水平和垂直方向空间信息编码的中间特征图; σ为 Sigmoid 非线性激活函数; F_1 为 1×1 卷积转换。

将中间特征图沿空间维度分为单独张量$\boldsymbol{f}^{h}$、$\boldsymbol{f}^{w}$, 通过 1×1 卷积对其进行维度增强, 并分别应用 Sigmoid 激活函数, 以得到 2 个方向的权重:

$$\begin{cases}\boldsymbol{g}_{\mathrm{c}}^{h}=\sigma(\boldsymbol{F}_h(\boldsymbol{f}^{h}))\\ \boldsymbol{g}_{\mathrm{c}}^{w}=\sigma(\boldsymbol{F}_w(\boldsymbol{f}^{w}))\end{cases} \tag{5}$$

式中: $\boldsymbol{g}_{\mathrm{c}}^{h}$和$\boldsymbol{g}_{\mathrm{c}}^{w}$分别为高度和宽度方向的权重; $\boldsymbol{F}_h$ 和 $\boldsymbol{F}_w$ 分别为沿高度和宽度方向的卷积变换。

将注意力权重 $\boldsymbol{g}_{\mathrm{c}}^{h}$、$\boldsymbol{g}_{\mathrm{c}}^{w}$与输入特征图 $\boldsymbol{x}_{\mathrm{c}}$ 相乘进行加权运算, 得到经过 CA 模块的 $\boldsymbol{Y}\in\mathbf{R}^{C\times H\times W}$ 特征图输出:

$$\boldsymbol{y}_{\mathrm{c}}(i,j)=\boldsymbol{x}_{\mathrm{c}}(i,j)\boldsymbol{g}_{\mathrm{c}}^{h}(i)\boldsymbol{g}_{\mathrm{c}}^{w}(j) \tag{6}$$

2.3　颈部网络改进

2.3.1　整体网络结构改进

为解决原检测层应对小目标检测任务的不足, 加入 P2 (160×160) 小目标检测层与检测头, 该检测层未经过下采样, 具有高分辨率、特征图尺寸大等特点, 充分保留了小目标的边缘与纹理特征。此外, 将 P5 (20×20) 检测头删除, 减少小尺度特征图的后续计算, 仅保留 P2、P4, 降低计算开销与模型参数量。P2 检测层的加入, 结合使小目标上下文增强的 BiFPN 特征融合模块, 不仅可加强网络模型对小目标检测位置信息和特征信息的融合, 提高微小目标的检测精度, 又可有效降低计算资源需求。最终, 将 3 组检测头 (P2、P3、P4) 中多尺度信息输入后续 Head 部分进行预测。

2.3.2 动态RGConv

骨干网络追求轻量化设计，牺牲了部分检测精度，虽然CA模块的加入增强了网络对关键特征的聚焦，提高了特征表达能力，但该骨干网络不同尺度输出通道数少，与原算法通道数差异较大，故与后续BiFPN模块跨尺度融合时通道对齐困难，难以充分发挥BiFPN模块性能。

于是，本文设计了基于Ghost[21]卷积的动态RGConv模块作为骨干网络与颈部网络连接的特征传递途径，其中，RGConv模块结构如图4所示，其中，$\boldsymbol{\Phi}_k$为第k个廉价线性变换或廉价操作分支，用于由主卷积分支输出特征生成补充特征；残差部分为深度可分离卷积（depthwise separable convolution，DSConv）。

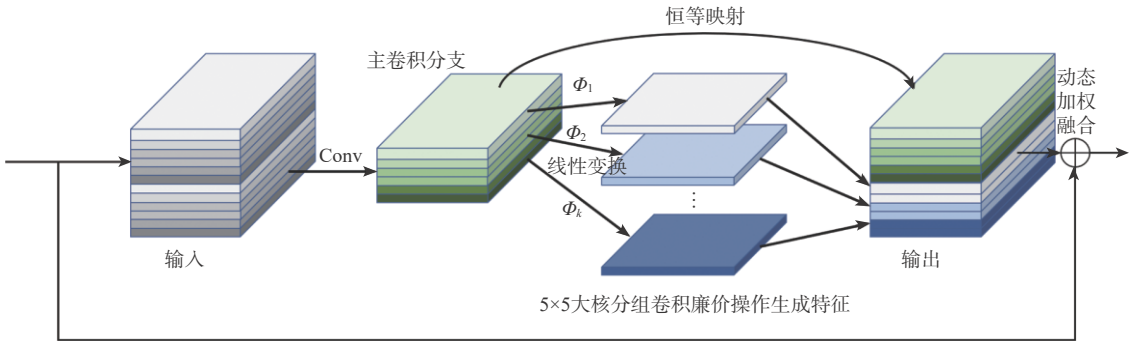


图4 RGConv模块

Fig. 4 RGConv module

主路径幻影卷积廉价操作生成更为丰富的特征信息，当输入输出不同时，残差路径采用DSConv（3×3深度卷积进行空间特征提取，1×1逐点卷积进行通道调整）以低参数量和低计算成本增强特征表达能力，并实现特征对齐，引入可学习的通道级权重参数，通过Sigmoid函数动态控制主路径与残差路径的贡献。改进的RGConv模块特征提取与输出表示为

$$\begin{cases}\boldsymbol{F}_{\text{main}}=\varphi(\text{BN}(\boldsymbol{W}_{\text{main}}\boldsymbol{X}))\\ \boldsymbol{F}_{\text{cheap}}=\varphi(\text{BN}(\boldsymbol{W}_{\text{dw}}\boldsymbol{F}_{\text{main}}))\\ \boldsymbol{F}_{\text{ghost}}=\text{Concat}(\boldsymbol{F}_{\text{main}},\boldsymbol{F}_{\text{cheap}})\end{cases}\tag{7}$$

式中：$\boldsymbol{X}$为RGConv模块输入特征图；$\boldsymbol{F}_{\text{main}}$、$\boldsymbol{F}_{\text{cheap}}$、$\boldsymbol{F}_{\text{ghost}}$分别为主卷积分支输出、廉价操作分支输出、拼接后的幻影卷积输出特征图；$\boldsymbol{W}_{\text{main}}\in\mathbf{R}^{(C_{\text{out}}/2)\times C_{\text{in}}\times 1\times 1}$、$\boldsymbol{W}_{\text{dw}}\in\mathbf{R}^{(C_{\text{out}}/2)\times 1\times 5\times 5}$分别为主卷积核、深度卷积核，分别生成$C_{\text{out}}/2$的特征，$C_{\text{in}}$、$C_{\text{out}}$分别为输入、输出通道数；$\varphi$为SiLU激活函数；Concat为拼接函数；BN为批量归一化。

当输入输出不匹配或步长大于1时，引入残差路径，最终双路径经可学习权重参数$\boldsymbol{\lambda}\in\mathbf{R}^{C_{\text{out}}\times 1\times 1}$动态融合得到最终输出：

$$\begin{cases}\boldsymbol{F}_{\text{res}}=\boldsymbol{W}_{\text{pw}}(\boldsymbol{W}_{\text{res_dw}}\boldsymbol{X})\\ \boldsymbol{\lambda}=\sigma(\boldsymbol{W}_{\boldsymbol{\lambda}})\\ \boldsymbol{Y}=\boldsymbol{\lambda}\odot\boldsymbol{F}_{\text{ghost}}+(\boldsymbol{I}-\boldsymbol{\lambda})\odot\boldsymbol{F}_{\text{res}}\end{cases}\tag{8}$$

式中：$\boldsymbol{F}_{\text{res}}$为残差路径输出特征图；$\boldsymbol{W}_{\text{pw}}$为点卷积核；$\boldsymbol{W}_{\text{res_dw}}$为残差深度卷积核；⊙表示广播相乘；$\boldsymbol{W}_{\boldsymbol{\lambda}}$为权重向量；$\boldsymbol{Y}$为最终输出特征图。

2.3.3 改进的BiFPN

在原YOLOv8算法模型中，颈部网络由FPN与PAN组合而成，该网络仅将得到的特征进行简单聚合处理，现阶段已不足以满足小目标检测任务需求，因此，本文采用改进的BiFPN[22]作为颈部网络。

BiFPN模块由自下而上、自上而下的特征信息传递及多尺度特征融合3部分组成。该模块通过引入可学习权重来获取不同输入特征的重要性，同时，迭代应用于自下而上和自上而下的多尺度特征融合，其引入特征信息的双向流，即同时引入水平和垂直连接，以更好地融合和利用不同尺度的特征，因此，在处理复杂场景时具有更强的鲁棒性，可解决在不同尺度上特征提取时信息丢失和冗余的问题[23]。

结合加入的小目标检测层，并移除大目标检测头，将BiFPN通过向现有的FPN和PAN框架引入额外2个横向连接创新，保留了从骨干网络提取的经RGConv模块增强后的原始特征，并将其整合到检测特征图中。其中，FPN、PAN及本文改进的BiFPN模块结构如图5所示。

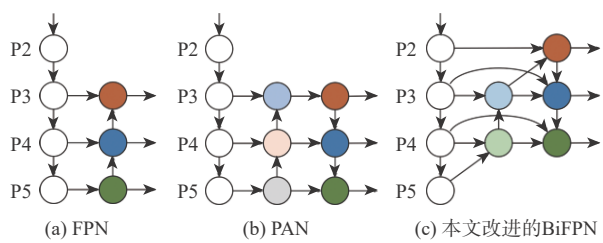


图5 FPN、PAN及BiFPN结构

Fig. 5 Structure of FPN, PAN and BiFPN

2.3.4　非跨步 Conv-SPD

传统神经网络频繁下采样, 大量的冗余像素信息被卷积或池化操作跳过, 易导致模型损失关键信息, 从而降低小目标检测性能。于是, 本文采用 Conv-SPD 替代原传统跨步卷积。相较由 Sunkara 等提出的 Conv-SPD[24] 模块, 本文选择将普通非跨步卷积作用在空深 (space-to-depth, SPD) 模块前, 普通卷积在高分辨率下提取局部语义过滤噪声, 保留高分辨率小目标信息, SPD 模块对已提取的局部语义特征进行重组, 实现真正意义上的信息保留下采样。此外, 原 SPD 模块最后阶段仅进行简单的通道维度拼接, 无法区分不同子特征图的贡献, 易导致关键特征被噪声淹没或冗余特征未被抑制。为解决该问题, 采用可学习加权融合, 初始化时, 4 个特征图均具有为 1 的权重值, 即初始状态不做任何偏好设置, 通过训练逐渐学习每个子特征图的重要性, 并得到不同权重值, 将 4 个子特征图进行加权融合, 可有效解决特征冗余、表达力不足等问题。改进 Conv-SPD 模块结构如图 6 所示。

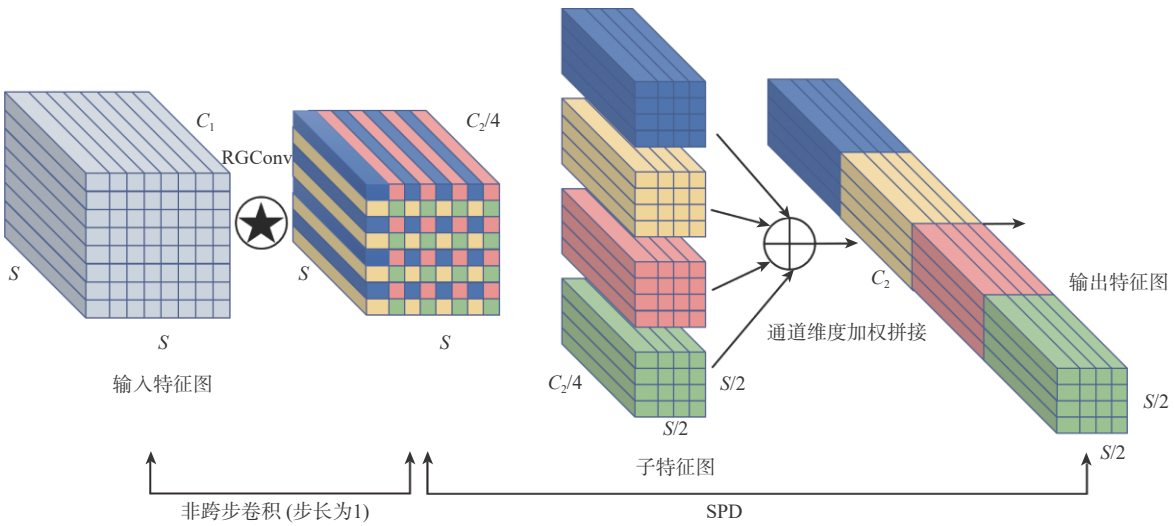


图 6　Conv-SPD 模块结构

Fig. 6　Conv-SPD module structure

Conv-SPD 主要由 2 个模块组成, 即普通非跨步卷积 (步长为 1) 和 SPD 模块。输入特征图经非跨步卷积过滤噪声, SPD 模块将特征图的空间信息转换为深度信息, 主要过程为: 首先, 将输入特征图划分为多个子特征图, 减少空间维度, 同时, 扩展通道数得到深度信息; 然后, 沿通道维度拼接, 通道数变为原来的 4 倍; 最后, 完成特征图从空间信息到深度信息的转化。其中, 若输入特征图维度为 (S, S, C_1), SPD 模块采用 2 倍尺度缩减因子对输入特征图进行下采样, 分为 4 个维度为 ($S/2$, $S/2$, $C_2/4$) 的子特征图, 进行通道维度的权重拼接, 完成输出维度为 ($S/2$, $S/2$, C_2) 的采样后特征图。

3　实验结果与分析

3.1　实验设置

3.1.1　数据集

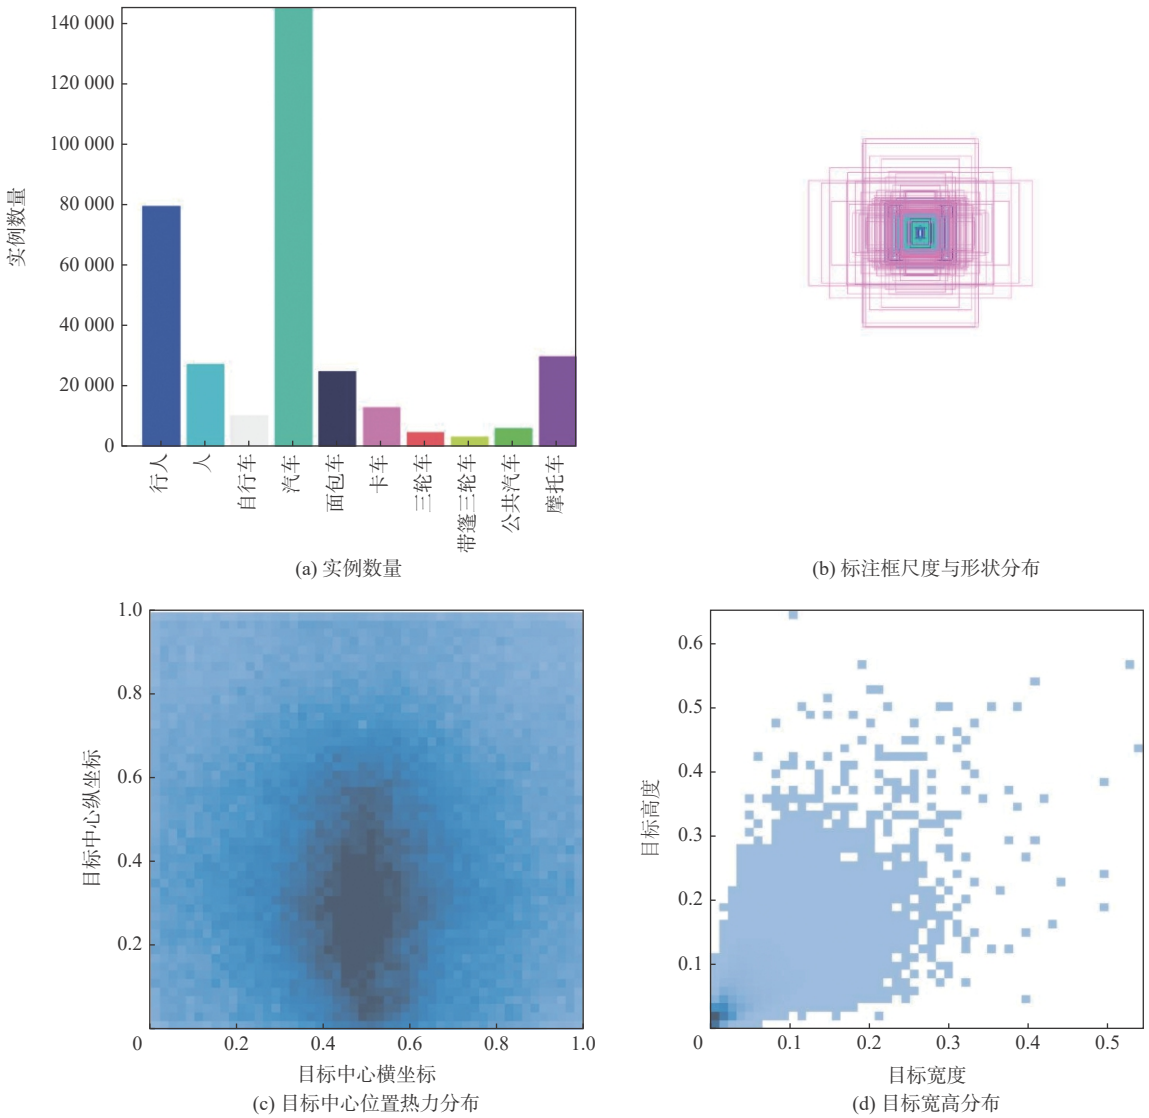
采用 VisDrone-DET 数据集[25] 进行模型训练, 由天津大学的机器学习和数据挖掘实验室的 Aiskyeye 团队进行收集开发。该数据集取自十几个不同城市真实场景, 包括城市、农村和公路等, 覆盖范围广, 由无人机视角下多角度、多场景、不同天气和光照条件下取得, 共有 8 629 张无人机航拍图像, 划分 6 471 张为训练集、548 张为验证集、1 610 张为测试集, 多达 260 万个实例中包含 10 种不同对象类别, 如行人、自行车、汽车和公共汽车等。

图 7 为该数据集的实例数量、实例类别分布及数据集各类目标标注的宽高分布。可以看到, 小目标居多, 且各类别的比例不均衡。

3.1.2　实验环境与评估指标

实验环境为租用服务器, GPU 为 NVIDIA GeForce RTX 4090D, 24 GB 显存, CPU 为 18 vCPU AMD EPYC 9754 128-Core Processor, 60 GB 内存, 操作系统为 Ubuntu22.04, 采用 python 3.12 版本, 模型训练依赖 CUDA 12.4、PyTorch 2.5.1 和 8.3.90 版本 Ultralytics 库深度学习框架。实验参数如表 1 所示。

采用精确度 P、召回率 R、平均精度均值(mean average precision, mAP)、参数量、浮点运算量、推理帧率及模型文件大小为评估指标。精确度 P 表示评估模型预测为正样本的能力; 召回率 R 表示评估模型能找到正样本的能力; mAP 为评估模型计算



(a) 实例数量　(b) 标注框尺度与形状分布

(c) 目标中心位置热力分布　(d) 目标宽高分布

图 7　VisDrone 数据集标注情况

Fig. 7　VisDrone dataset annotation situation

表 1　实验参数配置

Table 1　Experimental parameter configuration

初始输入图像尺寸/(像素×像素)	批次大小	训练轮次	工作线程数	优化器	动量系数	权重衰减系数	patience	初始学习率	最终学习率
640×640	16	100	8	AdamW	0.937	0.000 5	50	0.01	0.01

注: patience表示模型若经历50轮次后性能仍未提升则立即停止训练。

所有类别的平均精确度均值; 参数量为模型可训练的参数数量, 表示该算法模型占用内存的大小; 推理帧率表示每秒能处理图像数, 反映模型的检测速度; 浮点运算量表示每秒浮点运算次数, 反映模型的计算复杂度; 模型文件大小指模型训练后产生的 pt 文件, 表示训练好的模型权重和偏置等参数的文件磁盘占用大小, 直接关系到模型部署到算力有限的无人机等边缘设备上的难易程度及模型加载速度和推理速度。其中, P、R、单一类别的平均精度(average precision, AP)、mAP、推理帧率的计算公式分别为

$$\begin{cases} P = \dfrac{n_{\mathrm{TP}}}{n_{\mathrm{TP}}+n_{\mathrm{FP}}} \times 100\% \\ R = \dfrac{n_{\mathrm{TP}}}{n_{\mathrm{TP}}+n_{\mathrm{FN}}} \times 100\% \\ \mu_{\mathrm{AP}} = \displaystyle\int_0^1 P(R)\mathrm{d}R \\ \mu_{\mathrm{mAP}} = \dfrac{1}{N}\displaystyle\sum_{i=1}^{N}\mu_{\mathrm{AP},i} \\ \mu_{\mathrm{FPS}} = \dfrac{1\,000}{t_{\mathrm{pre}}+t_{\mathrm{inf}}+t_{\mathrm{post}}} \end{cases} \tag{9}$$

式中: n_{TP} 表示真实样本为正例、模型预测为正的样本数; n_{FP} 表示真实样本为负例、模型预测为正的样本数; n_{FN} 表示真实样本为正例、模型检测为负的样本数; N 为目标类别数; $P(R)$ 为由 P-R 曲线与坐标

轴围成的面积; $\mu_{AP,i}$ 为第 i 类样本的平均检测精度; t_{pre} 为前处理时间; t_{inf} 为推理时间; t_{post} 为后处理时间。

3.2　改进网络结构与损失函数消融实验分析

为验证本文模块的有效性, 在 VisDrone 2019 数据集上设计了多组消融实验, 与原算法进行对比分析。

3.2.1　整体颈部网络重设计实验分析

为验证重新设计颈部网络的合理性, 进行改进算法与原 YOLOv8n 算法的实验对比分析, 其中, YOLOv8n-P2 算法表示在原 YOLOv8n 网络中加入小目标检测层和检测头 P2, 并删去 P5 检测头。实验结果如表 2 所示。

表 2　颈部网络重设计实验结果

Table 2　Neck network redesign experiment results

模型	P/%	R/%	mAP0.5/%
YOLOv8n	41.7	32.2	31.9
YOLOv8n-P2	45.6	34.9	35.3
YOLOv8n-WMCBS	48.0	36.4	36.5

从表 2 可以看出, 经过重新设计的颈部网络整体结构在 P、R、mAP0.5(IoU 阈值为 0.5 时的平均精度均值)上, 相较于 YOLOv8n 分别提升 6.3%、4.2%、4.6%, 对比 YOLOv8n-P2, 在 P、R、mAP0.5 上分别提升 2.4%、1.5%、1.2%。说明最终 YOLOv8n-WMCBS 算法改进了原算法 FPN-PAN 整体颈部特征融合网络结构, 保留了 P3、P4 深层特征图, 在考虑丰富语义的同时, 充分利用了新增的 160 像素×160 像素尺度(P2)小目标检测层的细节信息, 显著提高了模型的目标检测性能, 增强了模型的小目标敏感性。

3.2.2　损失函数改进实验分析

为验证改进损失函数后的模型更适合小目标尺度检测任务, 与原算法 CIoU 损失函数进行对比实验分析, +CIoU 表示 YOLOv8n 算法采用 CIoU 损失函数, +Wise-IoU v3 表示 YOLOv8n 算法采用 Wise-IoU v3 损失函数。实验结果如表 3 所示。

表 3　损失函数改进实验结果

Table 3　Experimental results of loss function improvement

模型	边界框回归损失	P/%	R/%	mAP0.5/%
+CIoU	1.331	41.4	32.1	31.9
+Wise-IoU v3	1.256	43.5	32.4	32.1

从表 3 可以看出, 改进损失函数为 Wise-IoU v3 后, P、R、mAP0.5 相较于原应用 CIoU 损失函数时分别提升 2.1%、0.3%、0.2%, 虽然检测精度提升并不显著, 但边界框损失 box_loss 显著下降, 这说明改进后模型预测边界框与目标实际边界框位置偏差越小, 因此, 改进 Wise-IoU v3 函数计算损失, 对提升模型整体小目标检测性能有重要意义。

3.3　综合消融实验分析

以 YOLOv8n 为基线模型, 在 VisDrone 2019 数据集上对改进模块进行单独添加和总添加的综合消融实验分析, 进一步验证各个模块的作用, 实验结果如表 4 所示。其中, A、B、C、D、E 分别表示在 YOLOv8n 的基础上各自加上 Wise-IoU v3、Mobile-CA、小目标检测层、RG-BiFPN、Conv-SPD 改进后的实验结果。可以看出, 虽然算法 A 的 mAP0.5 值提升并不显著, 仅提升 0.2%, 但该损失函数边界框惩罚策略对小目标检测有着重要意义; 算法 B 在牺牲一定精度的条件下, 参数量与模型文件大小都降低, 有助于在实际无人机硬件上的部署; 而算法 C、D 在牺牲部分检测速度的情况下, 模型文件大小和参数量都进一步降低, 检测精度显著提高, mAP0.5 值分别提升了 3.4%、3.7%; 算法 E 的 mAP0.5 值提升 0.4%, 且其改进非跨步卷积后, 检测速度显著提高。与原 YOLOv8n 基准模型相比, 算法 F 的 mAP0.5 和 mAP0.5:0.95(IoU 阈值从 0.5 到 0.95, 步长为 0.05 时各阈值下 mAP 的平均值)值分别提高 4.6% 和 2.9%, 达到 36.5% 和 21.3%, 参数量和模型文件大小相较原算法分别降低 40.5% 和 35.5%, 以更小的模型文件大小和参数量达成更高的检测精度, 且在该

表 4　综合消融实验结果

Table 4　Comprehensive ablation experiment results

算法	Wise-IoU v3	Mobile-CA	+P2, −P5	RG-BiFPN	Conv-SPD	mAP0.5/%	mAP0.5:0.95/%	推理帧率/(帧·s^{-1})	参数量	模型文件大小/MB
YOLOv8n						31.9	18.4	326.9	3.01×10^6	6.2
A	√					32.1	18.5	313.7	3.01×10^6	6.2
B		√				28.5	15.4	297.5	2.58×10^6	5.4
C			√			35.3	21.1	229.2	2.01×10^6	4.3
D				√		35.6	21.2	223.7	2.44×10^6	7.9
E					√	32.3	18.9	387.3	3.15×10^6	6.5
F	√	√	√	√	√	36.5	21.3	199.3	1.79×10^6	4.0

硬件设备中推理帧率达到 199.3 帧/s，满足无人机移动设备的实时性要求。

3.4 对比实验

为更直观地体现改进后模型整体性能，将基线模型 YOLOv8n 与改进算法在同实验平台同训练参数条件下进行训练，并输出数据对比，采用 Origin 绘图软件对输出结果绘制曲线，如图 8 所示。可以看出，前 50 个迭代轮次模型收敛速度较快，检测精度也随之迅速上升，而后 50 个迭代轮次收敛速度和检测精度皆逐渐趋于平稳。改进算法的 mAP0.5 达到 36.5%，相比原 YOLOv8n 算法提升 4.6%，精确度 P 和召回率 R 较原算法分别提升 6.3% 和 4.2%，达到 48.0% 和 36.4%。边界框损失相较于原算法显著降低，充分表明损失函数改进的有效性。因此，上述改进对无人机等资源受限设备的目标检测任务具有明显贡献。

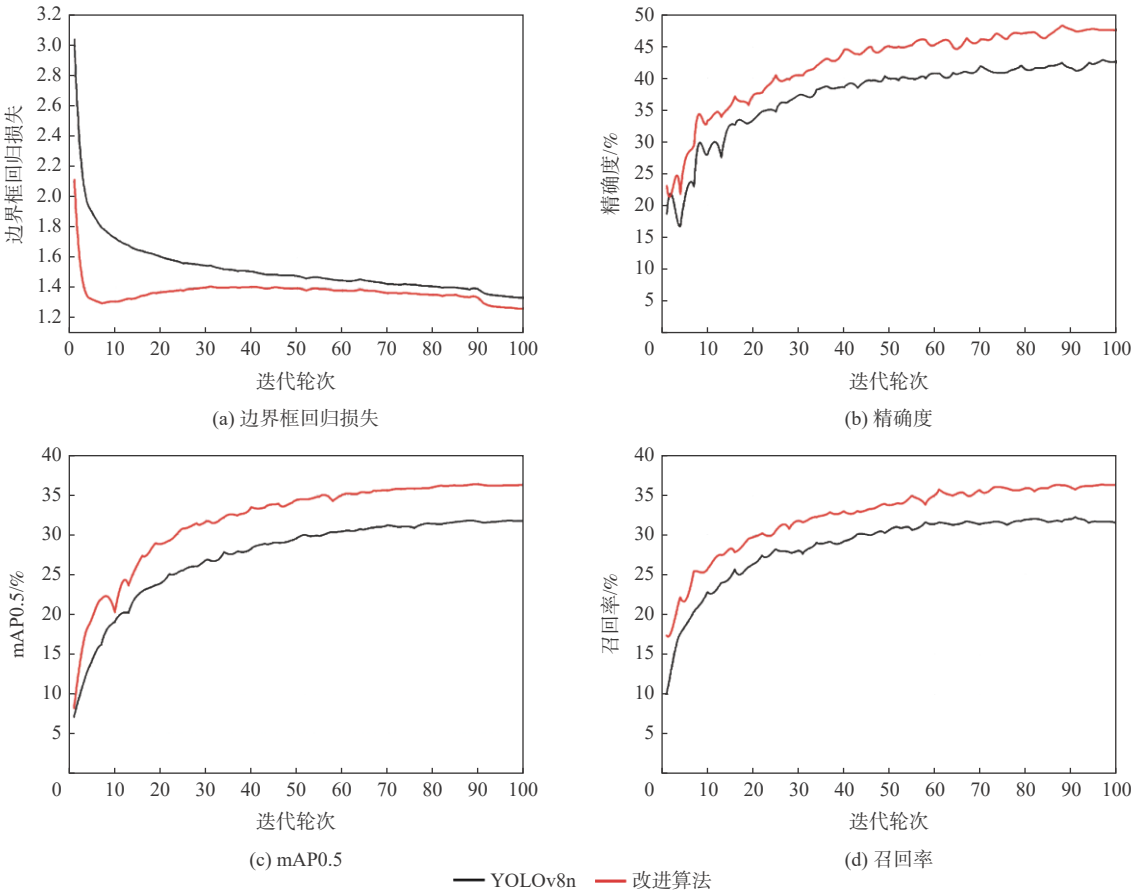


图 8 模型评价指标对比曲线

Fig. 8 Comparison curves of model evaluation metrics

此外，进行改进算法与其余主流目标检测算法 YOLOv4[26]、YOLOv5s[27]、YOLOv6s、FPN[28]、YOLOv11n、YOLOv12n 及基线算法 YOLOv8n 在 VisDrone 2019 数据集上的各类别检测效果对比实验，结果如表 5 所示。可知，对于该数据集的 10 种目标类别，改进算法整体明显优于原算法。且在行人、人、汽车、面包车及摩托车类别中检测效果均优于其余算法，尤其在行人、人和摩托车小目标检测对象中，AP 值分别达到 41.1%、33.6% 和 41.3%，为该类别最优。因此可以得出，改进算法 YOLOv8n-WMCBS 在该数据集上的综合表现优异，有着比原算法更强的检测性能。

为验证模型整体性能，进行上述算法参数量、浮点运算量和 mAP 的对比实验，结果如表 6 所示。可知，在 VisDrone 2019 数据集中，改进算法相比其余算法，参数量最小，模型最小，在无人机等移动设备中更具优势；浮点运算量相较原算法略有增加，但 mAP0.5 与 mAP0.5:0.95 值分别得到相当可观的提升。因此，改进算法较其余算法有着更为轻量化的优势，以更小的参数量和模型文件大小取得了比原算法更优异的检测效果，可有效解决无人机等边缘设备资源受限难以部署目标检测模型的问题。

为进一步验证改进算法的泛化能力，将原算法 YOLOv8n 与改进算法 YOLOv8n-WMCBS 在 VOC-2007 数据集上进行对比实验分析，实验结果如表 7

表 5　VisDrone 2019 数据集上不同算法对比实验结果

Table 5　Comparison experiments results of different algorithms on the VisDrone 2019 dataset

算法	AP/%										mAP0.5/%
	行人	人	自行车	汽车	面包车	卡车	三轮车	带篷三轮车	公共汽车	摩托车	
YOLOv4[26]	24.8	12.6	8.6	64.3	22.4	22.7	11.4	7.6	44.3	21.7	30.7
YOLOv5s[27]	26.8	13.9	9.0	71.0	36.8	37.4	16.3	**18.4**	**56.1**	28.3	31.4
YOLOv6s	24.4	12.9	6.9	71.0	37.5	**39.0**	15.1	18.0	56.0	26.7	30.7
FPN[28]	33.0	25.8	**13.9**	69.4	40.0	34.3	**27.4**	13.4	49.1	37.6	35.6
YOLOv11n	34.3	26.4	7.8	75.2	38.6	27.3	21.6	11.9	48.1	36.9	32.8
YOLOv12n	40.2	32.2	**10.3**	73.3	35.9	27.5	18.1	10.7	41.5	39.7	33.0
YOLOv8n(原算法)	33.4	27.4	7.4	74.7	38.0	26.3	20.8	10.9	45.3	34.3	31.9
改进算法	**41.1**	**33.6**	8.7	**79.1**	**40.8**	31.3	24.2	14.0	50.7	**41.3**	**36.5**

注: 加粗数值表示该类别最优值。

表 6　算法性能对比

Table 6　Comparison of algorithm performance

算法	mAP0.5/%	mAP0.5:0.95/%	参数量	浮点运算量/次
YOLOv4[26]	30.7	17.9	2.450×10^{7}	8.79×10^{10}
YOLOv5s[27]	31.4	18.3	9.100×10^{6}	2.38×10^{10}
YOLOv6s	30.7	18.0	1.630×10^{7}	4.40×10^{10}
YOLOv11n	32.8	19.1	2.590×10^{6}	6.50×10^{9}
YOLOv12n	33.0	19.4	2.570×10^{6}	6.50×10^{9}
YOLOv8n	31.9	18.5	3.010×10^{6}	$\mathbf{8.20\times10^{9}}$
改进算法	**36.5**	**21.3**	$\mathbf{1.790\times10^{6}}$	1.31×10^{10}

注: 加粗数值表示性能最优。

表 7　VOC2007 数据集上泛化性实验结果

Table 7　Generalization experiment results on the VOC2007 dataset

模型	*P*/%	*R*/%	mAP0.5/%	推理帧率/(帧·s^{-1})
YOLOv8n	75.3	67.5	75.1	561
改进算法	76.5	68.9	75.9	323

所示。可以看出, 相较于原 YOLOv8n 算法, 改进算法在 VOC2007 数据集中, *P*、*R*、mAP0.5 分别提升了 1.2%、1.4%、0.8%, 推理帧率为 323 帧/s, 有着良好的实时性, 说明改进算法在其余数据集上仍有较为出色的效果, 模型泛化能力强。

3.5　可视化分析

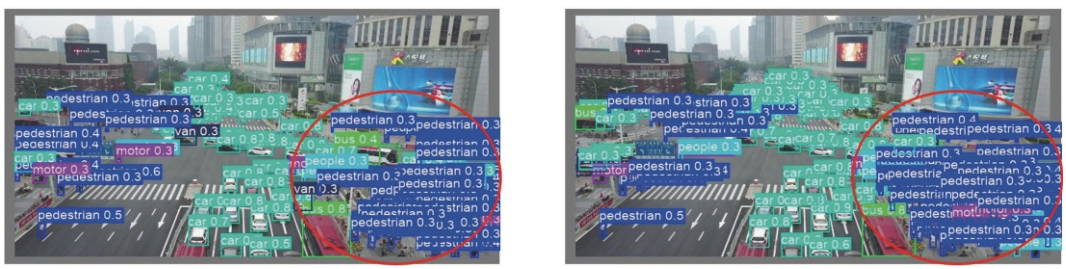
为更全面评估改进算法在不同场景下的检测性能, 在所有数据集图像中选取 4 类具有代表性的场景, 包括夜晚低光照场景、小目标场景、密集复杂场景及高空场景, 并对以上 4 个场景进行 YOLOv8n 算法与改进算法的可视化对比分析, 可视化效果对比如图 9 所示, 其中, 左侧为 YOLOv8n 算法检测效果, 右侧为改进算法检测效果。可以看出, YOLOv8n 算法在不同场景中检测性能都有待提升, 尤其是小目标检测场景, 存在大量的漏检和误检问题。相较于 YOLOv8n 算法, 改进算法即使在夜晚昏暗场景中仍能检测出大量如行人、自行车、摩托车等密集小目标; 在小目标场景中, 检测对象(如行人等)常具有尺度小且多变的特点, 改进算法表现出比原算法更为优异的效果, 显著降低了模型检测漏检率; 而在人群车辆密集且易形成遮挡的复杂密集场景下, 改进算法仍能保持高检测精度与低漏检率; 在高空场景下, 检测效果对比进一步验证了本文算法的改进有效性。



(a) 夜晚低光照场景检测效果对比



(b) 小目标场景检测效果对比



(c) 密集复杂场景检测效果对比



(d) 高空场景检测效果对比

京审字 (2026) G第2942号

图 9 不同场景下可视化效果对比

Fig. 9 Comparison of visualization effects in different scenarios

4 结 论

本文提出一种基于轻量化 YOLOv8 的无人机视角目标检测算法，改进了原网络检测层，加入 P2 检测头与检测层、移去 P5 检测头与检测层；设计了动态 RGConv 模块，形成改进的 RG-BiFPN 颈部网络；改进了 Conv-SPD 代替传统下采样，使算法模型聚焦高分辨小目标信息。得出以下结论：

1）改进算法在可视化分析中表现出优异的检测性能，有效改善了 YOLOv8n 算法存在的误检与漏检问题，且在数据集中各类别目标 AP 均有提升，如行人、人、摩托等小目标检测精度分别提升 7.7%、6.2%、7.0%。

2）改进算法与原算法相比，在 VisDrone 2019 数据集中满足实时性要求下，参数量和模型文件大小分别降低 40.5% 和 35.5%，mAP 提升 4.6%。

3）改进算法以更有优势的模型文件大小达成了更高的精度提升，提升了模型在资源受限无人机平台的部署适配性。

本文聚焦于无人机航拍检测算法模型创新。未来的重要方向是将本文模型部署到实际的无人机边缘计算平台上，并综合运用模型压缩与加速技术，进行详尽的功耗和实时性分析，以推动其在实际应用中的落地。为解决更为复杂场景下目标检测精度不高的问题，后续将对改进算法进行多源数据融合及并行双分支网络结构设计，使无人机对实际生活中复杂应用场景具有更为出色的检测性能。

参考文献（References）

[1] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 779-788.

[2] Tan M X, Pang R M, Le Q V. EfficientDet: scalable and efficient object detection[C]//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 10778-10787.

[3] 张瑞芳, 杜伊婷, 程小辉. 无人机视角下小目标检测算法[J]. 激光与光电子学进展, 2025, 62(4): 0437002.
Zhang R F, Du Y T, Cheng X H. Algorithm for small target detection from an unmanned aerial vehicle view[J]. Laser & Optoelectronics Progress, 2025, 62(4): 0437002(in Chinese).

[4] 李金凤, 崔少华, 潘立慧, 等. 无人机视角下改进 YOLOv8 的红外小目标检测算法[J]. 河北师范大学学报 (自然科学版), 2024, 48(6): 558-564.
Li J F, Cui S H, Pan L H, et al. Infrared small target detection algorithm based on improved YOLOv8 from the perspective of UAV[J]. Journal of Hebei Normal University (Natural Science Edition), 2024, 48(6): 558-564(in Chinese).

[5] 潘玮, 韦超, 钱春雨, 等. 面向无人机视角下小目标检测的 YOLOv8s 改进模型[J]. 计算机工程与应用, 2024, 60(9): 142-150.
Pan W, Wei C, Qian C Y, et al. Improved YOLOv8s model for small object detection from perspective of drones[J]. Computer Engineering and Applications, 2024, 60(9): 142-150(in Chinese).

[6] Zhang X, Liu C, Yang D G, et al. RFAConv: receptive-field attention convolution for improving convolutional neural networks[EB/OL]. (2026-02-28)[2026-06-20]. https://arxiv.org/abs/2304.03198.

[7] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[C]//Proceedings of the Computer Vision-ECCV 2018. Berlin: Springer, 2018: 3-19.

[8] Lau K W, Po L M, Rehman Y A U. Large separable kernel attention: rethinking the large kernel attention design in CNN[EB/OL]. (2023-10-20)[2025-06-20]. https://arxiv.org/abs/2309.01439.

[9] Yuan Z J, Shao P W, Li J R, et al. YOLOv8-ACU: improved YOLOv8-pose for facial acupoint detection[J]. Frontiers in Neurorobotics, 2024, 18: 1355857.

[10] Rezatofighi H, Tsoi N, Gwak J, et al. Generalized intersection over union: a metric and a loss for bounding box regression[C]//Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 658-666.

[11] Ma S L, Xu Y. MPDIoU: a loss for efficient and accurate bounding box regression[EB/OL]. (2023-07-14)[2025-06-20]. https://arxiv.org/abs/2307.07662.

[12] Jocher G. YOLOv8n[EB/OL]. (2023-09-27)[2025-06-20]. https://github.com/ultralytics/ultralytics.

[13] Wang C Y, Mark Liao H Y, Wu Y H, et al. CSPNet: a new backbone that can enhance learning capability of CNN[C]//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Piscataway: IEEE Press, 2020: 1571-1580.

[14] Li X, Wang W H, Wu L J, et al. Generalized focal loss: learning qualified and distributed bounding boxes for dense object detection [EB/OL]. (2020-06-08)[2025-06-20]. https://arxiv.org/abs/2006.04388.

[15] Zheng Z H, Wang P, Liu W, et al. Distance-IoU loss: faster and better learning for bounding box regression[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993-13000.

[16] Tong Z J, Chen Y H, Xu Z W, et al. Wise-IoU: bounding box regression loss with dynamic focusing mechanism[EB/OL]. (2023-01-24)[2025-06-20]. https://arxiv.org/abs/2301.10051.

[17] Howard A, Sandler M, Chen B, et al. Searching for MobileNetV3[C]//Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2019: 1314-1324.

[18] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 7132-7141.

[19] Hou Q B, Zhou D Q, Feng J S. Coordinate attention for efficient mobile network design[C]//Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2021: 13708-13717.

[20] Cai W X, Lu K B, Fan M T, et al. Rice growth-stage recognition based on improved YOLOv8 with UAV imagery[J]. Agronomy, 2024, 14(12): 2751.

[21] Han K, Wang Y H, Tian Q, et al. GhostNet: more features from cheap operations[C]//Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 1577-1586.

[22] Chiley V, Thangarasa V, Gupta A, et al. RevBiFPN: the fully reversible bidirectional feature pyramid network[EB/OL]. (2023-04-28)[2025-06-20]. https://arxiv.org/abs/2206.14098.

[23] Xu W Y, Cui C, Ji Y C, et al. YOLOv8-MPEB small target detection algorithm based on UAV images[J]. Heliyon, 2024, 10(8): e29501.

[24] Sunkara R, Luo T. No more strided convolutions or pooling: a new CNN building block for low-resolution images and small objects[C]//Proceedings of the Machine Learning and Knowledge Discovery in Databases. Berlin: Springer, 2023: 443-459.

[25] Du D W, Wen L Y, Zhu P F, et al. VisDrone-DET2020: the vision meets drone object detection in image challenge results[C]//Proceedings of the Computer Vision-ECCV 2020 Workshops. Berlin: Springer, 2020: 692-712.

[26] Bochkovskiy A, Wang C Y, Liao H Y M. YOLOv4: Optimal speed and accuracy of object detection[EB/OL]. (2020-04-23)[2025-06-05]. https://arxiv.org/abs/2004.10934.

[27] Jocher G. Ultralytics YOLOv5[EB/OL]. (2020-05-29)[2025-06-05]. https://github.com/ultralytics/yolov5.

[28] Lin T Y, Dollar P, Girshick R, et al. Feature pyramid networks for object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2017: 2117-2125.

UAV perspective target detection algorithm based on lightweight YOLOv8n

SONG Junyu[1, 2], PANG Yan[1, 2, *]

(1. State Key Laboratory of Structural Analysis, Optimization and CAE Software for Industrial Equipment, Dalian University of Technology, Dalian 116024, China;
2. Liaoning Provincial Key Laboratory of Frontier Technology of Aerospace Vehicles, Dalian University of Technology, Dalian 116024, China)

Abstract: In order to ensure the accuracy of target detection within limited resources, a lightweight YOLOv8n target detection algorithm YOLOv8n-WMCBS from the perspective of an unmanned aerial vehicle (UAV) was proposed. Firstly, Wise-IoU v3 is used as the overall loss function of the network, and the low-quality prediction frame is dynamically focused. Secondly, the MobileNetV3 network and the coordinate attention (CA) backbone network were introduced to reduce the number of parameters and the computational complexity. In order to preserve the specific characteristics and position data of the small target and lessen the model's computational load, the big target detection layer is eliminated and the small target detection layer and detection head are added concurrently. Then, the residual ghost convolution (RGConv) was designed to further enhance the feature richness of the backbone network, and was combined with the bidirectional feature pyramid network (BiFPN) module as a new neck network module to enhance the dynamic feature fusion of the neck network. Finally, in order to fully preserve the high-resolution small target information, an enhanced convolution-space-to-depth (Conv-SPD) is suggested to replace the initial step-down down sampling. Experimental results show that in the VisDrone 2019 dataset, while the number of parameters and the model size are reduced by 40.5% and 35.5%, the mAP0.5 and mAP0.5:0.95 are increased by 4.6% and 2.9%, respectively, compared with the original algorithm, which has stronger generalization ability and is more suitable for resource-constrained equipment such as UAVs.

Keywords: YOLOv8; unmanned aerial vehicle; loss function; small-object detection layer; lightweight networks

Received: 2025-06-30; **Accepted**: 2025-11-14; **Published Online**: 2025-12-30 16:10
URL: link.cnki.net/urlid/11.2625.V.20251230.1323.004

* **Corresponding author**. E-mail: ypang@dlut.edu.cn

《北京航空航天大学学报》征稿简则

《北京航空航天大学学报》是北京航空航天大学主办的以航空航天科学技术为特色的综合性自然科学学术期刊(月刊)。本刊以反映航空航天领域研究成果与动态、促进学术交流、培养科技人才和推动科技成果向社会生产力转化为办刊宗旨。本刊为中国自然科学技术核心期刊,并被 Ei Compendex 等国内外权威文献检索系统收录。本刊向国内外公开发行,为进一步提高办刊质量和所刊出文章的学术水平,特制定本简则。

1 论文作者及内容

1.1 本刊面向海内外所有学者。

1.2 主要刊载与航空航天科学技术有关的材料科学及工程、飞行器设计与制造、宇航科学与工程、信息与电子技术、控制技术和自动化工程、流体力学和动力工程、计算机科学及应用技术、可靠性工程与失效分析等领域的研究文章。航空航天科学技术民用方面以及具有航空航天工程背景的应用数学、应用物理、应用力学和工程管理等方面的文章也在本刊优先考虑之列。

2 来稿要求

2.1 论文应具有创新性、科学性、学术性和可读性。

2.2 论文为原创作品,尚未公开发表过,并且不涉及泄密问题。若发生侵权或泄密问题,一切责任由作者承担。

2.3 主题明确,数据可靠,图表清晰,逻辑严谨,文字精练,公式符号标准规范,标点符号正确。

2.4 文稿撰写顺序:中文题名(一般不超过 20 个汉字),作者中文姓名、单位、所在城市、邮政编码(作者顺序始终不得更改),中文摘要(包括目的、方法、结果及结论),中文关键词(5 ~ 8 个),中图分类号,引言,正文,参考文献,英文题名,作者英文姓名、单位、所在城市、邮政编码、国别,英文摘要,英文关键词。首、末页下角注明基金项目名称及编号,作者信息。

2.5 作者请登录本刊网页进行在线投稿。

3 稿件的审核、录用与版权

3.1 来稿须经专家两审和主编、编委讨论后决定刊用与否。

3.2 若来稿经审查后认定不宜在本刊发表,将及时告知作者。如果在投稿满 3 个月后仍未收到本刊任何通知,作者有权改投其他刊。在此之前,请勿一稿多投,否则一切后果自负。

3.3 来稿一经作者签字并在本刊刊出,即表明所有作者都已经认可其版权转至本刊编辑部。本刊在与国内外文献数据库或检索系统进行交流及合作时,不再征询作者意见。

邮寄地址:100191 北京市海淀区学院路 37 号 《北京航空航天大学学报》编辑部
办公地点:北京航空航天大学办公楼西配楼412~416房间
电　　话:(010)82316698,82316981,82315499,82317448
E-mail: jbuaa@ buaa. edu. cn
http://bhxb. buaa. edu. cn
http://www. buaa. edu. cn

集群成员期刊

《北京航空航天大学学报》
第五届编辑委员会

主　任（主　编）：赵沁平

（以下按姓氏笔画为序）

副主任（副主编）：丁希仑　王少萍　孙志梅　李秋实　李焕喜　杨嘉陵
苗俊刚　相　艳　徐立军　钱德沛　曹晋滨

编　委：马殿富　王　琪　王　聪　邓小燕　王青云　王荣明　刘　宇
刘　红　江　洁　刘　强　闫　鹏　朱天乐　刘铁钢　齐铂金
陈万春　邹正平　苏东林　杨世春　沈成平　邱志平　宋知人
杨树斌　张晓林　杨晓奕　杨继萍　李惠峰　吴新开　张瑞丰
杨照华　宋凝芳　周　锐　林宇震　林贵平　战　强　姚仰平
胡庆雷　赵秋红　段海滨　赵巍胜　席　平　郭　宏　徐　洁
徐世杰　郭洪波　康　锐　翟　锦　熊华钢

编辑部主任：张　嵘

编　　辑：孙　芳　万玉敏　王　茜　卞欢欢　李亚泰

北京航空航天大学学报

Beijing Hangkong Hangtian Daxue Xuebao

（原《北京航空学院学报》）

（月刊　1956 年创刊）

第52卷 第11期 2026年11月

JOURNAL OF BEIJING UNIVERSITY OF AERONAUTICS AND ASTRONAUTICS (JBUAA)

(Monthly, Started in 1956)

Vol.52 No.11 November 2026

主管单位　中华人民共和国工业和信息化部
主办单位　北京航空航天大学
主　　编　赵沁平
编辑出版　《北京航空航天大学学报》编辑部
邮　　编　100191
地　　址　北京市海淀区学院路37号
印　　刷　北京科信印刷有限公司
发　　行　《北京航空航天大学学报》编辑部
发行范围　国内外发行
联系电话　(010) 82316698 82316981
82315499 82317448
电子信箱　jbuaa@ buaa.edu.cn

Administrated by Ministry of Industry and Information Technology of the People's Republic of China
Sponsored by Beijing University of Aeronautics and Astronautics (BUAA)
(Beijing 100191, P. R. China)
Chief Editor ZHAO Qinping
Edited and Published by Editorial Board of JBUAA
Printed by Beijing Kexin Printing Co., Ltd.
Distributed by Editorial Board of JBUAA
Telephone (010) 82316698 82316981
82315499 82317448
E-mail jbuaa@buaa.edu.cn
http: //bhxb.buaa.edu.cn

中国标准连续出版物号：ISSN 1001-5965 / CN 11-2625/V

ISSN 1001-5965

国内定价：50.00元／期

微信公众号　超星电子书