

北京航空航天大学学报
*Journal of Beijing University of Aeronautics and Astronautics*
ISSN 1001-5965,CN 11-2625/V

# 《北京航空航天大学学报》网络首发论文

题目：基于多源风险代价地图的城市低空无人机 ACO-RRT*混合路径规划
作者：武博文，张启钱，张洪海，冯棣坤，石宗北
DOI：10.13700/j.bh.1001-5965.2026.0488
收稿日期：2026-07-12
网络首发日期：2026-11-06
引用格式：武博文，张启钱，张洪海，冯棣坤，石宗北．基于多源风险代价地图的城市低空无人机 ACO-RRT*混合路径规划[J/OL]．北京航空航天大学学报.
https://doi.org/10.13700/j.bh.1001-5965.2026.0488



**网络首发**：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

**出版确认**：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

# 基于多源风险代价地图的城市低空无人机 ACO-RRT*混合路径规划

武博文，张启钱✉，张洪海，冯棣坤，石宗北

（南京航空航天大学 民航学院，南京 211106）

*通信作者 E-mail： zhangqq@nuaa.edu.cn

摘要 针对城市低空物流无人机路径规划风险建模单一、路径安全性不足的问题，以无人机性能限制作为约束条件，建立兼顾路径长度与累计风险的多约束优化模型。构建了涵盖建筑障碍、禁飞空域、恶劣气象与人口密度的多源风险代价地图作为输入，提出蚁群-快速搜索随机树*混合算法，在蚁群算法中引入风险初始化信息素分布，设计启发式因子强化避险倾向，配以自适应挥发机制加速收敛路径骨架，构造快速搜索随机树*算法在骨架附近局部采样和重连优化。仿真实验表明，相较基准算法，混合算法借助蚁群算法对风险敏感的优势，解决了快速搜索随机树*算法忽视路径风险的问题，路径长度缩短 30.1%，累积风险降低 28.4%，有效结合了基准算法的优势。路径规划结果受代价权重和引导采样概率影响较大，使用参数敏感性分析方法，综合配置参数取值，以实现最佳的规划效果。

关键词 物流无人机；路径规划；风险建模；蚁群算法；启发式算法

中图分类号 V279.3 文献标志码 A DOI: 10.13700/j.bh.1001-5965.2026.0488

# ACO-RRT* path planning for urban low-altitude UAVs with multi-source risk cost maps

WU Bowen, ZHANG Qiqian✉, ZHANG Honghai, FENG Dikun, SHI Zongbei

（College of Civil Aviation, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China）

*E-mail: zhangqq@nuaa.edu.cn

**Abstract** Limited risk modeling often causes unsafe paths in low-altitude logistics. To address this problem, performance limitations of unmanned aerial vehicles (UAVs) were taken as constraints, and a multi-constraint optimization model was established with path length and cumulative risk as objectives. A multi-source risk cost map was constructed as the model input. The map integrated four risk layers: building obstacles, no-fly zones, adverse weather, and population density. To improve planning efficiency and path safety, a hybrid algorithm combining ant colony optimization (ACO) and rapidly exploring random tree star (RRT*), denoted as ACO-RRT*, was designed. In the ACO stage, a risk-aware initial pheromone distribution was introduced according to the risk cost map, and a heuristic factor was designed to strengthen the risk-avoidance tendency. An adaptive evaporation mechanism adjusted pheromone volatility to accelerate path-skeleton convergence. In the RRT* stage, local sampling and reconnection optimization were performed near the path skeleton generated by ACO. Simulation experiments were conducted in a constructed urban low-altitude environment with identical start and goal points. The proposed ACO-RRT* was compared with benchmark algorithms under the same UAV performance constraints and risk cost map. The comparison used path length and cumulative risk as evaluation indicators. The results show that ACO-RRT* uses the risk sensitivity of ACO to overcome the neglect of path risk in RRT*, shortens path length by 30.1%, and reduces cumulative risk by 28.4%; thus, it effectively combines the advantages of the benchmark algorithms. The two-stage design combines ACO risk sensitivity with RRT* sampling efficiency. Path planning performance is significantly affected by cost weights and guided sampling probability. Parameter sensitivity analysis was therefore used to vary these two

收稿日期：2026-07-12

基金项目：国家自然科学基金项目（U2133207）；国家社会科学基金重大项目（22&ZD169）

Fund：National Natural Science Foundation of China(U2133207); National Social Science Fund Major Project(22&ZD169)

网络首发时间：2026-11-06 09:39:45 网络首发地址：https://link.cnki.net/urlid/11.2625.V.20261105.1824.001

parameters over defined ranges and to determine the parameter configuration that achieved the best planning performance. The results provide a risk-aware path planning method and parameter configuration reference for UAV logistics in urban low-altitude environments.

**Key words** logistics UAV; path planning; risk modeling; ant colony optimization; heuristic algorithm

随着低空物流在城市场景的加速普及，无人机的路径规划技术面临着环境建模片面、结果缺乏工程实用性的挑战。与传统物流不同，低空物流的低空空域建筑人口密集，危险空域交错，同时存在风速变化、磁场干扰等气象环境，发生事故危害极大。同时受限于物理性能，无人机规划路径时必须妥善处理载荷与剩余电量。因此构建精细的城市风险环境，设计安全高效的多目标规划算法是当下低空物流行业的发展趋势[1]。

无人机路径规划算法可分为图搜索算法、启发式算法与学习型算法。传统图搜索算法中，Dijkstra 算法与 A*算法原理简单，但它们的计算效率低、路径不平滑[2]，后续有学者改进启发函数、引入动态步长等策略，取得一些进展[3]。概率路线图(probabilistic roadmap, PRM)算法是另一类典型的基于图采样算法，通过离线建图实现路径规划[4]。启发式算法凭借并行搜索能力和对目标函数形式的弱依赖性受到很多学者青睐，如遗传算法(genetic algorithm, GA)从迭代与选择角度逼近最优解[5]；差分进化(differential evolution, DE)算法在进化的基础上加入扰动策略[6]；粒子群算法(particle swarm optimization, PSO)模拟鸟群行为来更新个体速度与位置，尤其适合需要快速收敛问题[7]。近年来有学者使用强化学习(reinforcement learning, RL)通过智能体与环境的持续交互，逐步驱动寻找最优路径[8]。但模型训练太依赖先验环境，成熟模型面对陌生环境即时性差。

快速搜索随机树(rapidly-exploring random tree, RRT)作为一类经典的图搜索算法，在未知环境下表现出较强的适应性，能快速生成可行解[9]，但在实际路径规划中，RRT 生成的路径往往含有大段锯齿状折线段，不满足无人机真实飞行的平滑性要求。对此，Wang 等[10]提出改进的 RRT*算法，加入重连优化机制，使算法具有渐进优化特点，有效抑制了锯齿现象，路径更为平滑。尽管如此，RRT*算法仍因追求最短距离而忽视路径安全性，出现规划路径紧贴障碍物、与危险区间距过小的问题，很难保证结果的可行性与实用性。

蚁群算法(ant colony optimization, ACO)是一种经典的启发式算法，凭借正反馈进行经验积累与路径学习，但收敛速度慢，路径转折点繁多[11]。吴梅花等[12]在启发函数中加入转弯代价，提出新的信息素更新策略提高路径平滑度；郑琰等[13]把 ACO 与动态窗口法结合，提取 ACO 关键节点进行局部规划从而解决路径曲折问题。ACO 的信息素调控机制在风险敏感性路径规划中具备较强的可塑性，但目前尚未充分挖掘信息素对环境风险的响应记忆与调节能力。Silalahi 等[14]提出了与动态风险地图集成的自适应 ACO，采用基于风险的信息素更新机制，使路径能主动规避高风险区域。总体来说，现有 ACO 算法及变体在风险的考量上仍相对简单，缺乏对环境风险的多维度感知与复杂约束的响应能力，仍有较大改进空间。

综观现有研究，其不足在于：①改进型算法多聚焦单一性能短板，如 RRT*虽有效改善了路径平滑性，却始终未建立相应的风险感知机制；②ACO 对环境风险敏感的优势未得到充分发挥，风险建模多局限于单一的物理障碍，尚未系统纳入无人机路径规划中特有的空域限制、人员暴露、气象干扰等城市低空多源风险因素，难以为复杂城市环境下的安全飞行提供充分支撑。

文章对建筑、禁飞区、气象、人口密度等核心风险源分类量化，构建三维风险代价地图，并融合无人机性能约束建立优化模型。基于此，设计蚁群-快速搜索随机树*(ant colony optimization-rapidly-exploring random tree star, ACO-RRT*)混合算法，改进 ACO 强化全局搜索生成路径骨架，RRT*以骨架引导采样实现局部精细化调整。仿真实验表明，混合算法借助 ACO 算法对风险敏感的优势，解决了 RRT*算法忽视路径风险的问题，在路径长度和安全性上均优于单一算法，可以有效提升无人机规划路径质量。

# 1　问题建模

## 1.1 问题描述与相关假设

在城市低空物流的点对点路径规划问题中，无人机需从起点 $S$ 飞行至终点 $T$，生成一条路径点序列 $\{S, p_1, p_2, ...T\}$，相邻点之间空间连通。设飞行环境是长、宽、高分别为 $D$、$W$、$H$ 的长方体区域，以原点 $O$ 建立三维直角坐标系，采用栅格法对空域建模，按照栅格粒度 $l_g$ 进行分割得到 $u\times v\times h$ 个立体栅格，每个栅格的中心点是无人机可选飞行路径点。栅格空间模型如图 1 所示。

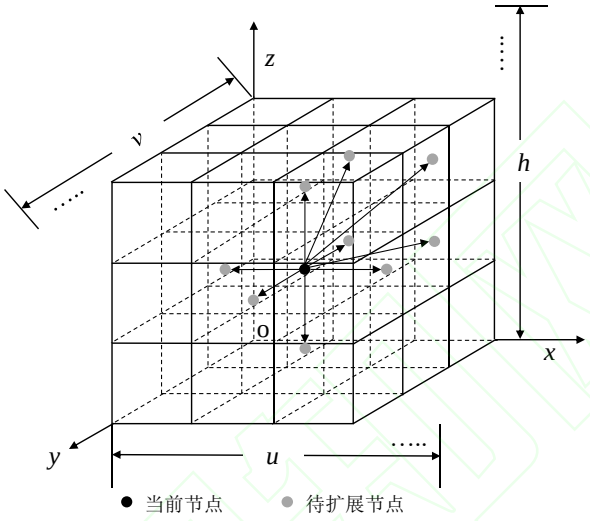


图 1 栅格空间模型
Fig. 1 Grid-based Spatial Model

## 1.2 多约束无人机路径规划模型

### 1.2.1 目标函数

目标函数包括路径长度、累积风险两个维度，加权得到综合代价，反映路径的优劣。

1) 路径长度。路径长度是各段飞行路径长度的累加和。

$$L=\sum_{i=1}^{n-1}\| p_{i+1}-p_i\| \quad (1)$$

式中：$p_i$ 为第 $i$ 个路径点。

2) 累积风险。累积风险反映无人机沿整条路径飞行过程中暴露于风险区域的累积程度，近似为两端点风险平均值与路径段长度之积。

$$C=\sum_{i=1}^{n-1}\frac{C(p_i)+C(p_{i+1})}{2}\cdot\| p_{i+1}-p_i\| \quad (2)$$

式中：$C(p_i)$ 为路径点 $p_i$ 所在栅格的栅格风险值；$\| p_{i+1}-p_i\|$ 为该路径段的长度。

本文采用全局动态极值归一化的方法将各维度目标值取值范围约束在[0,1]，通过加权叠加的方法来计算目标函数[15]，如下：

$$J=w_{\mathrm{L}}\cdot\hat{L}+w_{\mathrm{C}}\cdot\hat{C} \quad (3)$$

式中：$J$ 为综合代价；$\hat{L}$ 和 $\hat{C}$ 分别为归一化后的路径长度和累积风险；$w_{\mathrm{L}}$、$w_{\mathrm{C}}$ 分别为路径长度、累积风险的权重系数，满足 $w_{\mathrm{L}}+w_{\mathrm{C}}=1$。

### 1.2.2 约束条件

为确保生成的路径物理可实现并满足任务需求，必须满足以下约束条件：

1）最小路径段长度约束。补偿无人机轨迹偏差与指令响应延迟而预留的直飞安全缓冲距离。相邻两路径点间距离不小于最小路径段长度：

$$\| p_{i+1} - p_i \| \geq L_{\min} \tag{4}$$

式中：$L_{\min}$为最小路径段长度。

2）最大转弯角约束。假设无人机当前路径点坐标为$p_i(x_i, y_i, z_i)$，与之相邻两路径点坐标为$p_{i-1}(x_{i-1}, y_{i-1}, z_{i-1})$、$p_{i+1}(x_{i+1}, y_{i+1}, z_{i+1})$，则该相邻两路径段水平面夹角$\theta_i$。

$$\theta_i = \arccos \frac{(x_i - x_{i-1})(x_{i+1} - x_i) + (y_i - y_{i-1})(y_{i+1} - y_i)}{\sqrt{(x_i - x_{i-1})^2 + (y_i - y_{i-1})^2} \cdot \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2}} \leq \theta_{\max} \tag{5}$$

式中：$\theta_{\max}$为最大转弯角。

3）最大爬升/下降角约束。无人机完成爬升/下降操作时存在运动约束。

$$0 \leq \frac{|z_{i+1} - z_i|}{\sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2}} \leq \tan \phi_{\max} \tag{6}$$

式中：$\phi_{\max}$为最大爬升/下降角。

4）飞行高度约束。无人机存在最低与最高飞行高度。

$$z_{\min} \leq z_i \leq z_{\max} \tag{7}$$

式中：$z_{\min}$为最低飞行高度；$z_{\max}$为最高飞行高度。

5）最大载重约束。货物载重不超过最大载重。

$$m_{\mathrm{L}} \leq M_{\max} \tag{8}$$

式中：$m_{\mathrm{L}}$为实际载重；$M_{\max}$为最大载重。

6）能耗约束。为确保飞行总能耗不超过无人机的总续航能力。承担物流任务时，无人机需要考虑载重，故本文采用考虑载重因素的能耗模型，并在路径搜索过程中实时更新剩余电量。

$$E(p_i, p_{i+1}) = (m_0 + m_{\mathrm{L}}) \cdot (\lambda_{\mathrm{h}} \cdot d_{\mathrm{h}} + \lambda_{\mathrm{v}} \cdot d_{\mathrm{v}}) \tag{9}$$

$$E = \sum_{i=1}^{n-1} E(p_i, p_{i+1}) \tag{10}$$

$$E_{\mathrm{rem}}^{i+1} = E_{\mathrm{rem}}^{i} - E(p_i, p_{i+1}) \geq 0 \tag{11}$$

式中：$m_0$为空机重量；$\lambda_{\mathrm{h}}$、$\lambda_{\mathrm{v}}$分别为水平、垂直运动的单位质量能耗系数；$d_{\mathrm{h}}$、$d_{\mathrm{v}}$分别为水平、垂直运动的距离；$E(p_i, p_{i+1})$为无人机在相邻两路径点之间的飞行能耗；$E_{\mathrm{rem}}^{i+1}$为无人机到达第$i+1$个点的剩余电量。

## 2 多源风险代价地图

### 2.1 风险识别与量化

#### 2.1.1 建筑风险

在城市环境中，建筑是影响无人机飞行的主要物理障碍，不仅存在碰撞风险，还会引起气流扰动和信号干扰。因此，建筑风险不仅需要标识障碍栅格，还应将建筑邻近区域的缓冲风险考虑在内，通过引入安全裕度$\delta$，实现风险在建筑上方区域的线性衰减[16]。量化公式如下：

$$R_{\mathrm{b}}(i, j, k) = \begin{cases} 1, & \text{建筑内部栅格} \\ \dfrac{h_{\mathrm{b}} + \delta - k \cdot l_{\mathrm{g}}}{h_{\mathrm{b}}}, & \text{建筑上方栅格} \\ 0, & \text{其他} \end{cases} \tag{12}$$

式中：$R_b(i,j,k)$为栅格$(i,j,k)$的建筑风险值；$h_b$为建筑高度；$\delta$为安全裕度；$l_g$为栅格粒度。

### 2.1.2 空域风险

依据《无人驾驶航空器飞行管理暂行条例》，机场净空区、军事管理区、党政机关等区域严禁无人机擅自飞入[17]，因此本文对此类区域设置严格的全高度范围的路径避让要求。在实际划设中，需在严格禁飞区域外围设置一定的缓冲空间，以形成禁飞区安全裕度[18]。此外，对于工业区、主干道路等地面活动密集区域也应尽量避免飞越。为对不同栅格的风险属性进行差异化描述，设定各类特殊栅格的差异化风险值如表 1 所示。

$$R_f(i,j,k)=\begin{cases}1, & \text{禁飞区、高危害区}\\ R_d, & \text{主干道路危险区}\\ 0, & \text{其他（自由空域）}\end{cases} \quad (13)$$

式中：$R_f(i,j,k)$为栅格$(i,j,k)$的空域风险值；$R_d$为主干道路危险区的空域风险值，可据需求确定。

表1 栅格风险值

Table1 Grid Risk Value

| 栅格类别 | 飞行准则 | 风险值 |
|---|---|---|
| 政策禁飞区、事故高危害区 | 禁止飞入 | 1 |
| 主干道路危险区 | 尽量绕飞 | |
| 自由空域 | 可飞入 | 0 |

### 2.1.3 气象风险

城市低空环境中的强风、雨雪等恶劣天气会对无人机的飞行稳定性造成显著干扰，在风险环境建模中必须加以考虑。本文基于历史气象数据概率化气象风险，将动态天气因素转化为栅格内历史同期恶劣天气的发生概率。

$$R_w(i,j,k)=P_{haz}(i,j,k)=\frac{N_{haz}(i,j,k)}{N_t} \quad (14)$$

式中：$R_w(i,j,k)$为栅格$(i,j,k)$的气象风险值；$N_{haz}(i,j,k)$为栅格$(i,j,k)$历史同期发生恶劣天气的次数；$N_t$为总统计次数。

### 2.1.4 人口风险

鉴于交通枢纽、商业区等地面人群密集地区潜在风险较高，路径规划应尽量予以规避。城市中的建筑物与道路两旁的植被可有效缓冲坠机冲击作用，本文采用遮蔽因子$S(i,j,k)$进行量化，其取值根据栅格地物类型设定（见表 2）。考虑到无人机飞行高度越高对地面威胁越小，设定人口风险随高度上升而逐渐衰减。

表2 遮蔽因子取值

Table2 Shielding Factor

| 区域划分 | 遮蔽因子取值 |
|---|---|
| 无遮蔽　（空旷区域） | 0 |
| 部分遮蔽（沿街树木） | 0.2 |
| 良好遮蔽（建筑四周） | 0.4 |
| 完全遮蔽（建筑内部） | 0.8 |

$$R_p(i,j,k)=\left[\frac{D(i,j)}{D_{max}}\cdot\left(1-S(i,j,k)\right)\right]\cdot e^{-\lambda_{pop}\cdot z} \quad (15)$$

式中：$R_p(i,j,k)$为栅格$(i,j,k)$的人口风险值；$D(i,j)$为该栅格投影区域的人口密度；$D_{max}$为人口

密度最大值； $S(i,j,k)$ 为栅格 $(i,j,k)$ 的遮蔽因子； $\lambda_{\text{pop}}$ 为高度变化衰减因子； $z$ 为飞行高度。

### 2.2 构建风险代价地图

各风险对应风险值的权重采用层次分析法(analytic hierarchy process, AHP)确定，该方法已被广泛应用于路径规划的多目标决策问题[19]。结合风险值与相应权重，加权叠加得到栅格风险值，如下：

$$C(i,j,k)=w_{\text{b}}R_{\text{b}}+w_{\text{f}}R_{\text{f}}+w_{\text{w}}R_{\text{w}}+w_{\text{p}}R_{\text{p}} \quad (16)$$

式中： $R_{\text{b}}$ 、 $R_{\text{f}}$ 、 $R_{\text{w}}$ 、 $R_{\text{p}}$ 分别为建筑风险值、空域风险值、气象风险值、人口密度风险值，取值范围为[0,1]； $w_{\text{b}}$ 、 $w_{\text{f}}$ 、 $w_{\text{w}}$ 、 $w_{\text{p}}$ 为四类风险值对应的权重，满足 $w_{\text{b}}+w_{\text{f}}+w_{\text{w}}+w_{\text{p}}=1$ 。当四类风险值中任一个达到 1 时，栅格风险值 $C(i,j,k)$ 直接置为 1，表示该栅格应该禁飞。如果栅格风险值接近 1，算法在寻路时尽可能避免选择该栅格。

## 3 ACO-RRT*混合算法设计

### 3.1 基线算法原理

蚁群算法预先对地图信息素初始化，将 m 只蚂蚁置于起点，每只蚂蚁依据状态转移概率选择下一节点，构建出一条可行路径。当所有蚂蚁结束搜索后，对各路径信息素进行一次更新。蚁周模型(Ant-Cycle)的主要内容包含以下公式：

$$P_{ij}^{k}(t)=\begin{cases}\dfrac{\left[\tau_{ij}(t)\right]^{\alpha}\cdot\left[\eta_{ij}\right]^{\beta}}{\sum_{s\in A_k}\left[\tau_{is}(t)\right]^{\alpha}\cdot\left[\eta_{is}\right]^{\beta}}, & \text{若}j\in A_k\\ 0, & \text{否则}\end{cases} \quad (17)$$

$$\tau_{ij}(t+1)=(1-\rho)\cdot\tau_{ij}(t) \quad (18)$$

$$\tau_{ij}(t+1)=\tau_{ij}(t+1)+\sum_{k=1}^{m}\Delta\tau_{ij}^{k} \quad (19)$$

$$\Delta\tau_{ij}^{k}=\begin{cases}\dfrac{Q}{L_k}, & \text{若蚂蚁}k\text{经过路径}\ l_{ij}\\ 0, & \text{否则}\end{cases} \quad (20)$$

式中： $P_{ij}^{k}(t)$ 为第 $k$ 只蚂蚁在时刻 $t$ 从节点 $i$ 转移到节点 $j$ 的状态转移概率； $\alpha$ 、 $\beta$ 分别为信息素启发因子、期望启发因子； $\eta_{ij}$ 为边 $l_{ij}$ 上的启发式信息； $\tau_{ij}(t)$ 为 $t$ 时刻边 $l_{ij}$ 上的信息素浓度； $A_k$ 表示蚂蚁 $k$ 当前可选择的、尚未访问的节点集合； $\rho$ 为信息素挥发因子； $\Delta\tau_{ij}^{k}$ 为蚂蚁 $k$ 在本次迭代中向它经过的路径 $l_{ij}$ 上释放的信息素量； $Q$ 为信息素释放总量； $L_k$ 为蚂蚁 $k$ 在这次迭代中走过的路径总长度。

ACO 算法的原理及步骤参见文献[11]，本文不再赘述。

RRT*算法在 RRT 算法的基础上，为新生成的节点 $p_{\text{new}}$ 在局部邻域内选择代价更小的父节点；插入 $p_{\text{new}}$ 后，尝试以 $p_{\text{new}}$ 为父节点重新连接邻域内的现有节点，以降低其路径代价。

### 3.2 算法设计方案

本文提出一种 ACO-RRT*混合算法：以高风险栅格占比 $P_{\text{high}}$ ( $C(i,j,k)>0.7$ )、风险均值 $\mu$ 与两倍风险标准差 $2\sigma$ 三者中最大值定义环境复杂度 $\Phi$ ，综合反映高风险区域的空间覆盖度、整体水平及分布不均匀性。当 $\Phi$ 低于阈值时，环境相对简单，RRT*算法独立运行即可快速获得高质量路径；反之则由 ACO 算法在风险代价地图上生成全局路径骨架，利用 RRT*算法在骨架附近局部再优化，经动态规划(Dynamic Programming, DP)方法平滑，生成最终路径。

### 3.2.1 改进蚁群算法

1) 考虑风险因素的启发因子。传统的启发式信息只与当前节点与候选节点的距离有关，忽视终点的引导作用。同时由于没有引入风险相关因素，蚂蚁盲目追求最短距离，没有考虑到路径所属栅格是否风险最低。因此本文设计以距离倒数与风险折扣相乘的启发因子，既保持向终点的强引导，又抑制蚂蚁穿越高风险区域的倾向，如下：

$$\eta_{ij}=\frac{1}{d_{jT}}\cdot e^{-\lambda_{\text{risk}}\cdot C_{\text{avg}}} \quad (21)$$

式中：$d_{jT}$ 为候选点到终点的直线距离；$C_{\text{avg}}$ 为当前栅格与候选栅格风险均值；$\lambda_{\text{risk}}$ 为风险惩罚系数，该值越大算法越回避高风险区域。

2) 基于风险地图的初始信息素分布。标准蚁群算法采用均匀的初始信息素分布，导致算法初期盲目探索，不能快速得到可行路径。本文基于风险代价地图预先分配栅格初始信息素，低风险区域赋予较高初始信息素，高风险区域赋予较低初始信息素，蚂蚁优先探索安全区域。

$$\tau_{ij}(0)=\tau_0\cdot\left(1-\frac{C_{ij}}{C_{\max}}\right) \quad (22)$$

式中：$\tau_0$ 为基准值；$C_{\max}$ 为最大栅格风险值，取 1。

3) 自适应信息素更新机制。传统信息素挥发因子为常数，算法前期探索能力与后期收敛速度无法平衡。本文设计自适应信息素挥发因子，随迭代次数动态变化。针对路径长度、风险优化问题，将信息素增量与路径的综合代价相关联。

$$\rho(t)=\rho_{\min}+(\rho_{\max}-\rho_{\min})\cdot \mathrm{e}^{-\lambda_{\text{phe}}\cdot\frac{t}{T_{\max}}} \quad (23)$$

$$\Delta\tau_{ij}^{k}=\frac{Q}{J(k)} \quad (24)$$

式中：$t$ 为当前迭代次数；$T_{\max}$ 为总迭代次数；$\lambda_{\text{phe}}$ 为信息素挥发衰减系数；$J(k)$ 为路径综合代价；$\rho_{\min}$、$\rho_{\max}$ 分别为最小、最大信息素挥发因子。预实验取 $\lambda_{\text{phe}}$=1.0，使中期挥发因子适中。

### 3.2.2 改进 RRT*算法

1) 基于引导半径的混合采样。本文采用基于引导半径的混合采样，设 ACO 骨架路径中某个点 $p_i$，定义以 $p_i$ 为中心、以 $R$g 为半径的球形区域为引导区域。每次采样以概率 $P$g 从 $p_{\text{ACO}}$ 中随机选择一个路径点 $p_i$，在引导区域内均匀随机生成采样点；反之则在整个状态空间均匀随机采样。既保证 ACO 骨架路径附近区域被重点探索，也保留了对未知区域的探索能力。

2) 邻近节点重连。为保持 RRT*的渐进最优性，在每插入一个新节点 $p_{\text{new}}$ 后，执行邻近节点搜索与重连操作。标准 RRT*中重连半径随节点数量动态变化，本文栅格空间离散且环境规模已知，故使用固定半径 $r=5\cdot l_g$ 进行邻近节点搜索。

## 3.3 算法流程

本文三维风险代价地图构建与混合算法规划流程如图 2 和图 3 所示。

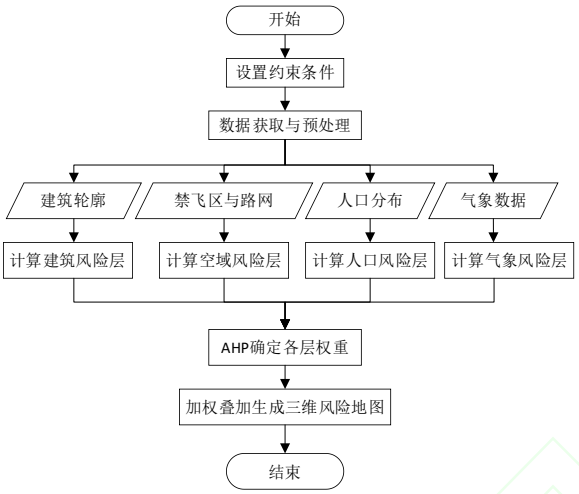


图 2 风险代价地图构建流程
Fig. 2 Flowchart of Risk Cost Map Construction

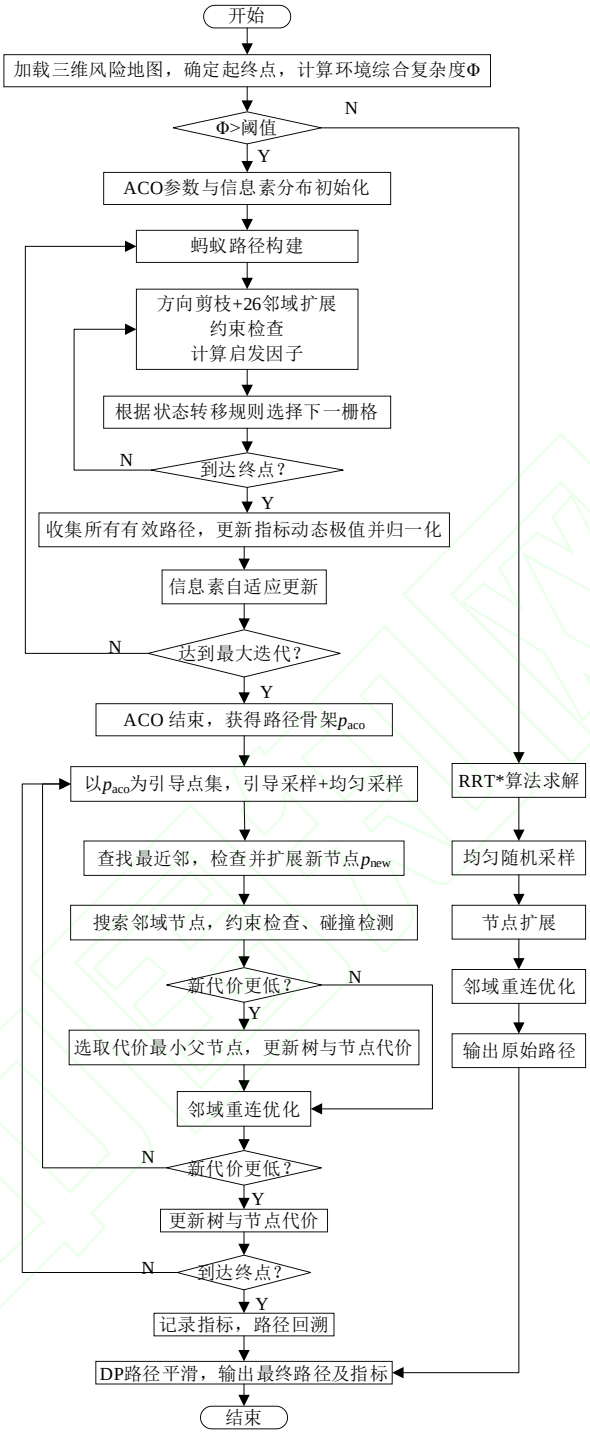


图 3 ACO-RRT*混合算法流程
Fig. 3 Flowchart of the ACO-RRT* Hybrid Algorithm

# 4　仿真验证

## 4.1 仿真环境搭建

为验证本文提出的 ACO-RRT*混合算法（以下简称混合算法）在城市低空环境下的有效性，截取 1000m×1000m×200m 的城市空域（见图 4（a）），将区域内地形高程与道路分布数据栅格化处理，生成栅格粒度为 10m 的栅格地图（见图 4（b））。禁飞区数据参考《无人驾驶航空器飞行管理

暂行条例》相关规定划设[17]。人口密度数据采用背景人口随机分布与建筑区域叠加的方式生成，按地表类型赋值遮蔽因子（见图 4（c））。气象数据采用基于城市典型地物类型的风险场建模方法，按照研究区域内高速公路、运动场、湖泊等地物的气象差异划分气象异常区域，并使用高斯分布函数拟合各气象异常区域的空间分布（见图 4（d））。起终点设于东西两侧具备净空条件的开阔地带，预期路径需穿越建筑群、禁飞区及气象风险区，可充分检验算法对复杂城市物流场景的规划能力[20]。

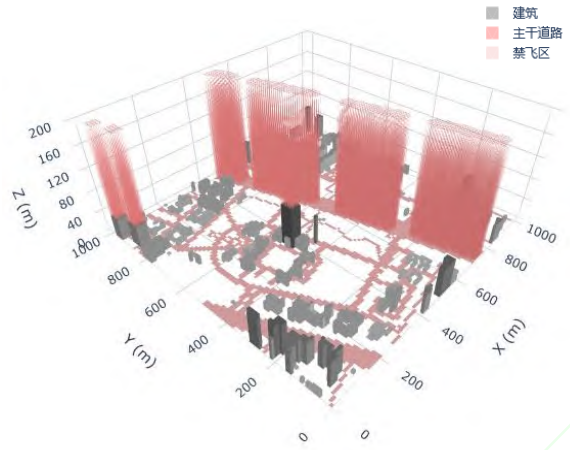


(a) 仿真环境三维模型

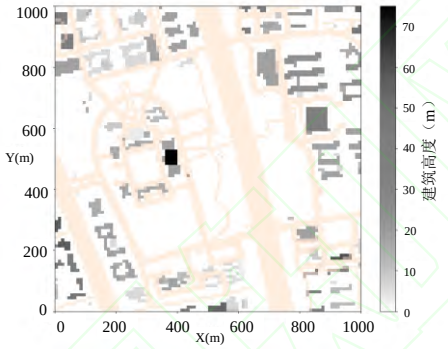


(b) 建筑与道路分布

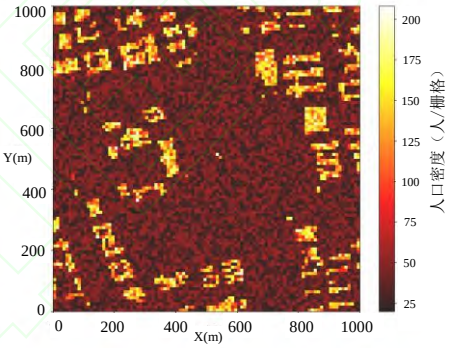


(c) 人口密度分布

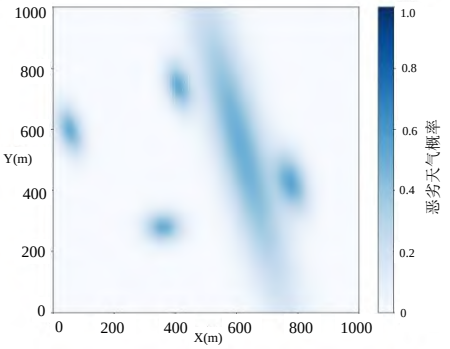


(d) 气象风险分布

图 4 无人机规划环境
Fig. 4 UAV Planning Environment

构造风险权重判断矩阵，通过特征向量法计算各权重 $w_b$ =0.222、 $w_f$ =0.25、 $w_w$ =0.111、 $w_p$ =0.417，一致性比率为 0.017<0.1。加权叠加各风险值生成三维风险代价地图，以 10m、40m 高度层为例，风险代价地图切片和各类风险源示意如图 5 所示。算法部分预设参数如表 3 所示。

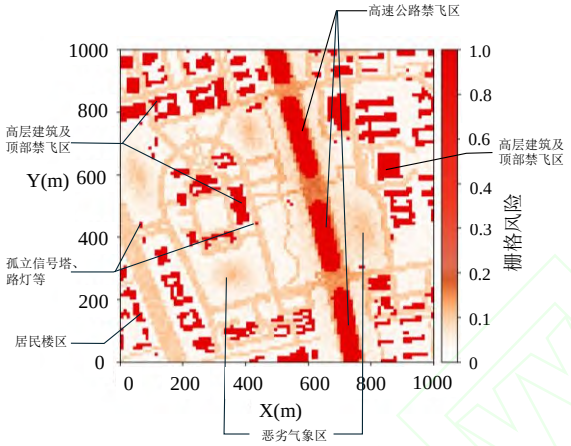


(a) 10m 高度

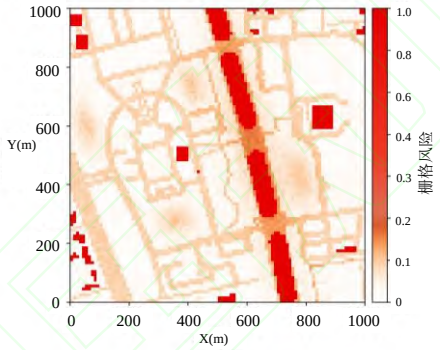


(b) 40m 高度

图 5 风险切片
Fig. 5 Risk Slices

表3 仿真参数
Table 3 Simulation Parameters

| 参数 | 数值 |
|---|---|
| 空机重量[21] $m_0$ /kg | 4 |
| 最大载重[21] $M_{max}$ /kg | 3 |
| 实际载重 $m_L$ /kg | 2 |
| 最小路径段长度[22] $L_{min}$ /m | 5 |
| 最大转弯角 $\theta_{max}$ /rad | $\pi/3$ |
| 最大爬升角 $\phi_{max}$ /rad | $\pi/3$ |
| 飞行高度最大值 $z_{max}$ /m | 120 |
| 飞行高度最小值 $z_{min}$ /m | 10 |
| 建筑风险安全裕度 $\delta$ /m | 10 |
| 禁飞区保护区/m | 10 |
| 路径长度权重 $w_L$ | 0.5 |
| 累积风险权重 $w_C$ | 0.5 |

| | |
|---|---|
| 单位距离质量水平运动能耗[21] $\lambda_h$ /(J·m$^{-1}$·kg$^{-1}$) | 22.5 |
| 单位距离质量垂直运动能耗[21] $\lambda_v$ /(J·m$^{-1}$·kg$^{-1}$) | 11.5 |
| 起点 $S$ 坐标/m | (40, 90, 10) |
| 总电池电量[21] $E_{tal}$ /kJ | 550 |
| 终点 $T$ 坐标/m | (910, 880, 10) |
| 信息素启发因子 $\alpha$ | 1.2 |
| 期望启发因子 $\beta$ | 4.0 |
| 最小挥发因子 $\rho_{min}$ | 0.05 |
| 最大挥发因子 $\rho_{max}$ | 0.4 |
| 信息素挥发衰减系数 $\lambda_{phe}$ | 1.0 |
| 引导采样概率 $Pg$ | 0.5 |

注：参数右上角标注文献表明该数值参考对应文献，未标注者依据无人机性能参数或实验设定。

## 4.2 算法性能分析

在相同仿真环境下，将混合算法分别与基线算法进行对比实验，分别运行 20 次所得代表性结果如图 6~图 8 所示，并从路径长度、累积风险和 CPU 时间方面进行分析，如表 4 所示。

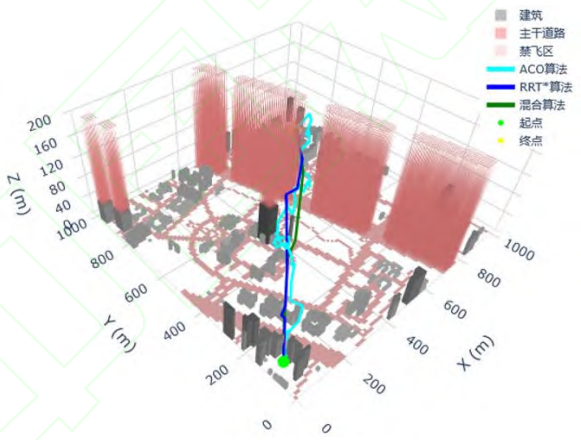


图 6 路径规划结果三维图
Fig. 6 3D View of Path Planning Results

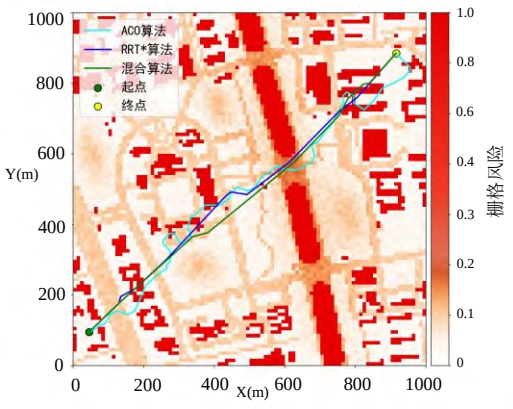


图 7 路径规划结果二维图
Fig. 7 2D View of Path Planning Results

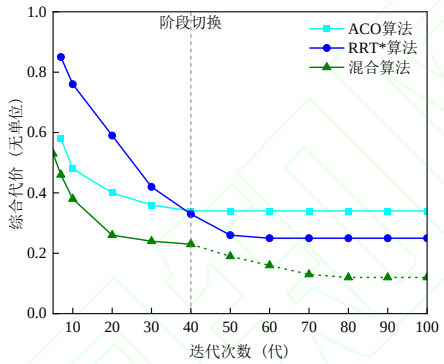


图 8 目标函数收敛曲线
Fig. 8 Convergence Curve of the Objective Function

表4 路径指标对比
Table 4 Comparison of Path Metrics

| 算法 | ACO 算法 | RRT*算法 | 混合算法 |
|---|---|---|---|
| 路径长度(m) | 1730.0±216.2 | 1310.3±56.8 | 1209.7±24.7 |
| 累积风险 | 134.3±29.6 | 118.9±20.1 | 96.2±14.3 |
| CPU 时间(s) | 503.9±42.0 | 93.6±1.9 | 183.9±30.4 |

结合表 4 及图 8 可知，混合算法在增加少量 CPU 时间的情况下，路径长度、累积风险均优于基准 ACO 和 RRT*算法。从图 8 来看，混合算法得到的综合代价为 0.13，而 ACO 算法的综合代价为 0.34，RRT*算法的综合代价为 0.26，本文提出的混合算法是优于 ACO 和 RRT*算法的。路径长度上，混合算法路径长度均值较 ACO 算法缩短 30.1%，较 RRT*算法缩短 7.7%，且路径平滑度明显改善，无人机飞行更平稳。路径风险上，混合算法将多源风险信息嵌入 ACO 的初始信息素分布与启发式因子，驱使无人机主动避开高风险区域，累积风险均值较 RRT*算法降低 19.1%，较 ACO 算法降低 28.4%。尽管混合算法的 CPU 时间略高于 RRT*，但相较于 ACO 缩短了 63.5%，考虑到城市低空无人机对飞行安全的极度敏感，用适度的时间成本换取更优的路径和更高安全性是有必要的。

为验证混合算法与经典路径规划方法的性能差异，选取最短路径规划三维 A*算法作为对比算法，运行结果如图 9、图 10 所示，每隔 20m 记录路径点风险值于图 11，各项指标记录于表 5。

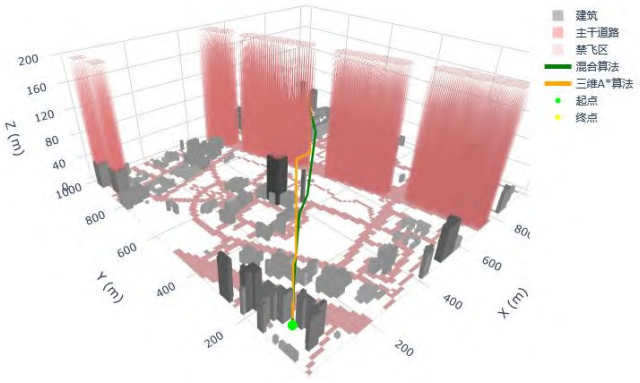


图 9 路径规划结果三维图
Fig. 9 3D View of Path Planning Results

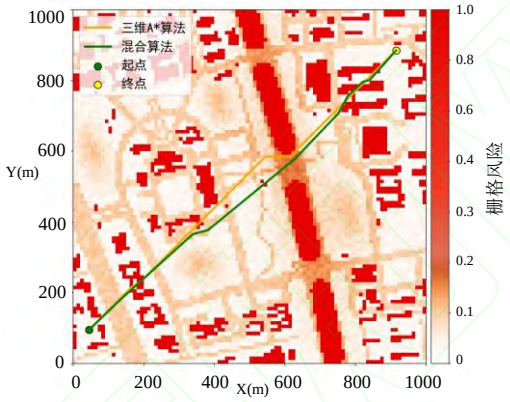


图 10 路径规划结果二维图
Fig. 10 2D View of Path Planning Results

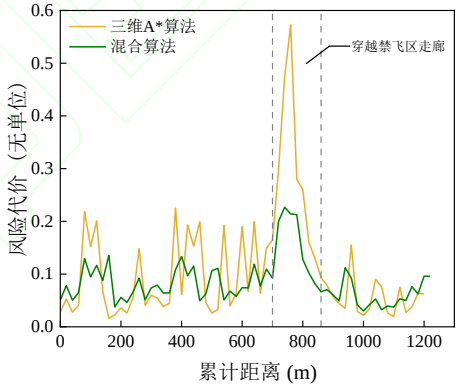


图 11 路径沿线风险代价曲线
Fig. 11 Risk Cost Curve along the Path

表5 路径指标对比
Table 5 Comparison of Path Metrics

| 算法 | 三维 A*算法 | 混合算法 |
|---|---|---|
| 路径长度(m) | 1195.1 | 1209.7±24.7 |
| 累积风险 | 123.02 | 96.2±14.3 |

结合图 11 及表 5 可知，三维 A*算法虽规划出最短路径，但忽略环境风险分布导致部分路径段紧贴禁飞区边界，并在约 780m 处出现显著风险峰值。本文混合算法在路径长度仅增加 1.2%的前提下，

累积风险较 A*大幅降低 21.8%，且风险始终维持在较低水平，有效规避了局部高风险区域。这一结果充分验证风险代价地图和混合策略的有效性，表明该算法面对复杂城市环境的可靠性和安全性。

### 4.3 参数敏感性分析

规划路径的质量受代价权重组合$\{w_L, w_C\}$的影响，本文采用对照实验法分析其影响，$w_L$、$w_C$依次按照表 6 取值，其他参数与环境设置保持不变，各运行 10 次后将结果指标记录于表 6，指标组合的变化趋势如图 12 所示。

表6 不同权重组合对结果的影响

Table 6 Impact of Different Weight Combinations on the Results

| 组别 | $w_L$ | $w_C$ | 路径长度(m) | 累积风险 | CPU 时间(s) |
|---|---|---|---|---|---|
| A | 0.3 | 0.7 | 1224.5 | 101.7 | 242.2 |
| B | 0.4 | 0.6 | 1228.7 | 98.9 | 194.5 |
| C | 0.5 | 0.5 | 1210.6 | 97.8 | 181.5 |
| D | 0.6 | 0.4 | 1208.3 | 99.4 | 205.1 |
| E | 0.7 | 0.3 | 1215.1 | 108.2 | 243.1 |

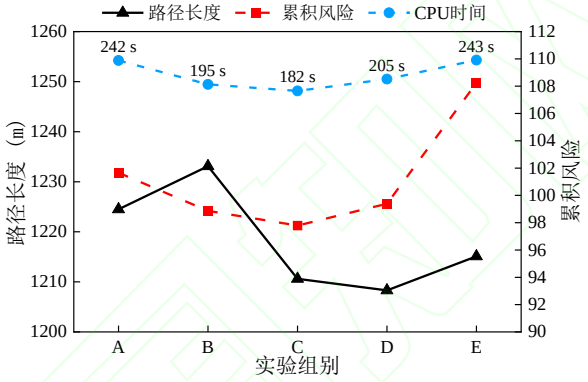


图 12 不同代价权重组合对结果的影响

Fig. 12 Impact of Different Cost Weight Combinations on the Results

由图 12 可知，路径指标随长度权重$w_L$的取值不同呈现明显变化。路径长度总体变化幅度较小，其中 D 组($w_L=0.6$)取得最小值；累积风险先降后升，在 C 组($w_L=0.5$)处降至最低 97.8；CPU 时间同样在 C 组最少，为 181s。经分析，长度权重增大虽可使路径略微变短，但过度追求最短路径会导致路径贴近高风险区,削弱风险规避能力，同时搜索效率下降；长度权重过小则造成绕行增多，CPU 时间随之增加。综上，C 组参数可综合平衡路径长度和累积风险，故选$w_L=0.5$、$w_C=0.5$为最优权重组合。

引导采样概率 *Pg* 直接控制 RRT*采取引导采样的比重，为检验 *Pg* 对算法性能的影响，固定代价权重组合$w_L=0.5$、$w_C=0.5$不变，取 *Pg* =0.1、0.3、0.5、0.7、0.9 各进行 10 次独立实验，路径指标记录于表 7，变化趋势如图 13 所示。

表7 不同 *Pg* 取值对结果的影响

Table 7 Impact of Different Pg Values on the Results

| 组别 | *Pg* | 路径长度(m) | 累积风险 | CPU 时间(s) |
|---|---|---|---|---|
| A | 0.1 | 1233.5 | 102.1 | 266.2 |
| B | 0.3 | 1244.4 | 96.1 | 201.7 |
| C | 0.5 | 1210.6 | 98.5 | 225.5 |
| D | 0.7 | 1219.4 | 95.6 | 209.2 |
| E | 0.9 | 1214.4 | 98.1 | 218.4 |

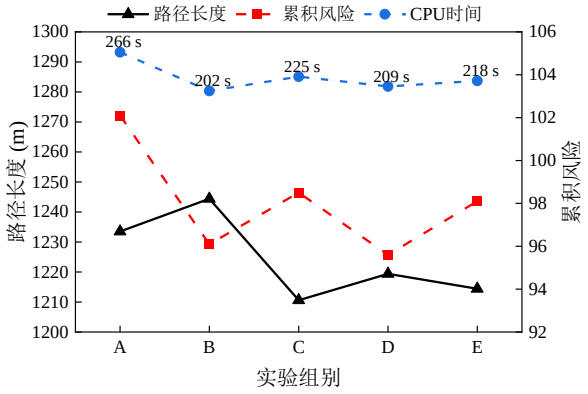


图 13 不同 *Pg* 取值对结果的影响

Fig. 13 Impact of Different *Pg* values on the Results

从图 13 可知，随着引导采样概率 *Pg* 的增大，路径长度在 1210~1244m 区间波动，且在 *Pg* = 0.5 时取得最小值。累积风险呈现先降后升趋势，在 *Pg* = 0.7 时取得最低值 95.6，较 *Pg* = 0.1 时降低 6.4%。经分析，当 *Pg* 过小时算法侧重随机搜索，对高风险区的敏感性不足，导致路径风险较高；而当 *Pg* 过大时又过度依赖 ACO 路径骨架，无法发挥 RRT*的渐进优化性，路径长度和累计风险难以改善。综上，D 组实验可有效发挥 ACO 的全局引导作用和 RRT*的局部优化作用，故选择 *Pg* = 0.7 作为最佳取值。

## 5　结 论

1)建立了兼顾路径长度和累积风险的多约束无人机路径规划模型，量化建筑、禁飞区、恶劣气象、人口密度四类风险并加权形成城市低空三维风险代价地图，为路径搜索提供了环境输入。

2)设计了 ACO-RRT*混合算法：改进 ACO 通过全局搜索生成路径骨架，RRT*在骨架附近引导采样实现局部优化。仿真结果表明，混合算法有效结合了基准算法的优势，路径长度较 ACO 算法缩短 30.1%，累积风险较 ACO 算法降低 28.4%。混合算法在增加少量 CPU 时间的情况下，显著提升了路径安全性。与三维 A*算法相比，混合算法风险始终维持在较低水平。

3) 使用参数敏感性分析方法，综合配置累积风险权重与引导采样概率取值，以实现最佳的规划效果。

本文方法可为城市低空物流无人机提供安全高效的路径参考。未来可基于元学习，研究更具通用性的场景-参数映射方法，以增强算法在不同场景下的适应能力。

## 参考文献（References）

[1] Shao Q,Li J,Li R,et al.Study of Urban Logistics Drone Path Planning Model Incorporating Service Benefit and Risk Cost[J].Drones,2022,6(12):418.

[2] De Filippis L,Guglieri G,Quagliotti F.A Minimum Risk Approach for Path Planning of UAVs[J].Journal of Intelligent & Robotic Systems,2011,61:203-219.

[3] 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（01）：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(01):256-264(in Chinese).

[4] Zhao P C,Hu Q W,Wang S H,et al.An improved probabilistic roadmap planning method for safe indoor flights of unmanned aerial vehicles[J].Drones,2023,7(2):92.

[5] 钱海力．基于改进操作算子的遗传算法无人机航路规划[J]．电子技术与软件工程，2020，（12）：131-132.
Qian H L.Genetic Algorithm with Enhanced Operators for UAV Path Planning[J].Computer And Multimedia Technology,2020,(12):131-132.(in Chinese).

[6] 孙彧龙，丁国绅．复杂约束下基于局部强化差分进化的无人机路径规划[J]．电脑知识与技术，2026，22（10）：30-34.
Sun Y L,Ding G S.Locally Enhanced Differential Evolution for UAV Path Planning under Complex Constraints[J].Computer Knowledge and Technology,2026,22(10):30-34.(in Chinese).

[7] 闫刚，夏孝程，李佳明．基于改进粒子群算法的无人机复杂三维路径规划[J]．自动化应用，2025，66（12）：38-42.
Yan G,Xia X C,Li J M.Three-Dimensional Path Planning for UAVs in Complex Environments Based on Improved Particle Swarm Optimization Algorithm [J].Automation Application, 2025,66(12):38-42(in Chinese).

[8] Pina R,Tibebu H,Hook J,et al.Overcoming Challenges of Applying Reinforcement Learning for Intelligent Vehicle Control[J].Sensors,2021,21(23):7829.
[9] Karaman S,Frazzoli E.Sampling-based algorithms for optimal motion Planning[J].The International Journal of Robotics Research,2011,30(7):846–894.
[10] Wang X,Gao J,Zhou X,et al.Path Planning for the Gantry Welding Robot System Based on Improved RRT*[J].Robotics and Computer-Integrated Manufacturing,2024,85:102643.
[11] He Y,Zeng Q,Liu J,et al.Path planning for indoor UAV based on Ant Colony Optimization[C]//2013 25th Chinese Control and Decision Conference(CCDC),2013:2919–2923.
[12] 吴梅花，宋晓波，刘红翠．基于改进蚁群算法的移动机器人路径规划研究[J]．工业控制计算机，2026，39（8）：72-74．
Wu M,Song X B,Liu H C.Path Planning of Mobile Robots Based on Improved Ant Colony Algorithm[J].Industrial Control Computer,2026,39(8):72-74(in Chinese).
[13] 郑琰，席宽，巴文婷，等．基于蚁群-动态窗口法的无人驾驶汽车动态路径规划[J]．南京信息工程大学学报，2025，17（2）：256-264．
Zheng Y,Xi K,Ba W T,et al.Dynamic path planning of autonomous vehicles based on ant colony optimization combined with dynamic window approach[J].Journal of Nanjing University of Information Science & Technology,2025,17(2):256-264(in Chinese).
[14] Silalahi N H M,Firdaus E A,Hutapea H M.Adaptive ant colony optimization integrated with dynamic risk mapping for tactical vehicle path planning in dynamic battlefields[J].Journal of Defense Technology and Engineering,2025,1(1):1-13.
[15] Wu S,Dong A,Li Q,et al.Application of ant colony optimization algorithm based on farthest point optimization and multi-objective strategy in robot path planning[J].Applied Soft Computing,2024,167(PC):112433-112433.
[16] 张启钱，许卫卫，张洪海，等．基于 IOCAD 的无人机避障路径规划[J]．西北工业大学学报，2020，38（02）：238-245．
Zhang Q Q,Xu W W,Zhang H H,et al.The Obstacle-Avoidance Path Planning for UAV Based on IOCAD[J].Journal of Northwestern Polytechnical University,2020,38(02):238-245(in Chinese).
[17] 国务院，中央军事委员会．无人驾驶航空器飞行管理暂行条例[Z]．国务院、中央军事委员会令第 761 号，2023．
State Council,Central Military Commission.Interim Regulation on the Flight Management of Unmanned Aerial Vehicles[Z].Decree of the State Council and the Central Military Commission No.761,2023(in Chinese).
[18] 邹依原．智慧城市环境下无人机安全间隔标定方法研究[D]．南京航空航天大学，2021．
Zou Y Y.Research on the Demarcation Method of Safe Separation for Unmanned Aerial Vehicle in Future Smart Cities[D].Nanjing University of Aeronautics and Astronautics,2021(in Chinese).
[19] Brafßel H,Zeh T,Lindner M,et al.Risk-Aware UAV Trajectory Optimization Using Open Urban GIS Data and Target Level of Safety Constraints[J].Drones,2025,9(10):666.
[20] Brunelli M,Ditta C C,Postorino M N.New infrastructures for Urban Air Mobility systems:A systematic review on vertiport location and capacity[J].Journal of Air Transport Management,2023,112:102460.
[21] DJI 大疆．经纬 M30 系列技术参数[EB/OL]．（2024-04-20）[2026-05-13]．https：//enterprise．dji．com/cn/matrice-30/specs．DJI．Matrice 30 Series Technical Specifications[EB/OL]．（2024-04-20）[2026-05-13]．https：//enterprise．dji．com/cn/matrice-30/specs（in Chinese）．
[22] 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（07）：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).