http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2025.0429

基于伪标签增强与多特征融合的毫米波雷达无人机检测

鲁亚宁[1]，张生军[1,*]，于钱米[2]，李洪明[1]

(1. 重庆交通大学 信息科学与工程学院，重庆 400074；2. 宁波华东核工业勘察设计院集团有限公司，宁波 315040)

摘 要：针对毫米波雷达无人机检测领域，开展了基于多特征融合与伪标签增强的弱监督学习方法研究。采用恒定虚警率（CFAR）算法对毫米波雷达回波信号进行目标预检测，从中提取频谱能量分布特征、运动轨迹变化特征及统计分布特征，综合反映无人机的距离、速度及运动状态；利用 LogitBoost 提升算法构建分类模型，通过迭代加权弱分类器，有效提高了分类准确性。为缓解标注样本不足问题，进一步引入伪标签自训练机制，并通过人工辅助修正，实现了未标注数据的利用，并提升了模型的泛化能力。基于自建的毫米波雷达数据集，开展了多轮实验验证，结果表明：所提方法在 3 种不同场景的弱监督条件下，接收者工作特征曲线下面积（AUC）分别提升约 7.2%/1.6%/6.6%，虚警率降低约 36.9%/0%/10.6%，检测准确率较传统方法有显著提高。此外，所提方法表现出较强的环境适应能力，能够在复杂背景下稳定识别小型飞行目标。研究表明，多特征融合结合伪标签增强策略为毫米波雷达无人机检测提供了一种有效的解决方案，具备较高的实用价值和推广潜力。

关 键 词：毫米波雷达；无人机检测；多特征融合；伪标签学习；恒定虚警率

中图分类号：TN957.51

文献标志码：A **文章编号**：1001-5965(2026)09-3172-11

随着小型无人机市场的发展，无人机在各个领域的应用随处可见：借助无人机进行农林植保不仅可以降低成本，还能实现良好的增产效果。此外，无人机在应急救援、消防灭火、景区管理、物流配送及无人机灯光表演领域均有广泛应用。虽然无人机在诸多领域都有其优势，但其快速发展也带来了诸如非法飞行等安全、隐私问题。面对这些问题，无人机的检测显得尤为重要。

目前，已知的无人机检测方法有很多，包括视觉检测法，如 Zhang[1] 提出的多尺度 YOLOv8 改进算法用于无人机小目标检测，在 VisDrone 数据集上检测效果优异；声学检测法，如 Sun 等[2] 利用麦克风阵列采集无人机声音信号，结合波束形成算法及卷积神经网络（convolutional neural network, CNN）分类，检测距离可达 135 m；无线电频谱检测法，如 Bi 等[3] 利用无人机发出的 WiFi 流量独特特征，分类其源媒体访问控制（media access control, MAC）地址来构建机器学习模型的方法，以此弥补监控弱区域的无人机入侵行为的早期识别；融合传感器检测方面，Pereira 等[4] 将光电（electro optical, EO）和红外传感器进行比较和融合，结合 YOLOv7 对无人机进行检测和跟踪。然而，受限于各自的物理特性，视觉检测对光照条件有着严苛要求，且在遮挡条件下精度差，也无法应对恶劣天气；声学检测面临诸多

收稿日期：2025-07-02；**录用日期**：2025-10-24；**网络出版时间**：2025-12-03 14:22

网络出版地址：link.cnki.net/urlid/11.2625.V.20251203.1033.001

基金项目：江西省地质局青年科学技术带头人培养计划项目 (2022JXDZKJRC07)；江西省地质局科技计划项目 (2021AA04)；重庆市自然科学基金 (CSTB2024NSCQ-MSX0275)

* **通信作者**. E-mail：sjzhang@cqjtu.edu.cn

引用格式：鲁亚宁，张生军，于钱米，等. 基于伪标签增强与多特征融合的毫米波雷达无人机检测 [J]. 北京航空航天大学学报，2026，52（9）：3172-3182. Lu Y N，Zhang S J，Yu Q M，et al. Pseudo-label enhanced multi-feature fusion for millimeter-wave radar UAV detection [J]. Journal of Beijing University of Aeronautics and Astronautics，2026，52（9）：3172-3182（in Chinese）.

环境噪声干扰; 无线电频谱检测只适合于有控制信号的场景, 对于自动飞行的无人机及信号屏蔽的无人机无从下手; 融合传感器, 类似红外传感器、激光雷达等设备昂贵且部署麻烦, 且只适用于中远距离; 而传统的雷达技术在复杂环境下存在虚警率高、易失效等问题。

近年来, 毫米波雷达逐渐进入人们的视野。毫米波雷达以其全天候工作能力、对遮蔽性强目标的高分辨率检测能力及良好的运动感知能力, 逐渐受到研究人员的青睐。相比上述方法, 毫米波雷达不依赖光照、可穿透非金属物质遮挡, 且在雨雾等极端天气下, 仍能提供稳定的距离速度信息, 这些特性为毫米波雷达建立全天时、全场景的无人机检测与跟踪等提供了可能性。Khawaja 等[5] 将射频(radio frequency, RF)分析仪、雷达、通信系统组合成基于 RF 的无人机的检测、分类和跟踪(detection, classification and tracking of unmanned aerial vehicle, DCT-U)的系统, 并进一步对比了传统雷达和现代雷达系统, 还将通信系统用于主动模式下的联合通信与感知, 并作为 DCT-U 的照明源。Semenyuk 等[6] 将雷达、RF、光学和升学传感器集成, 提升了无人机的检测精度、范围和可靠性。

Soriano[7] 总结了恒定虚警率(constant false alarm rate, CFAR)及其有关变体如(单元平均恒虚警率(cell-averaging CFAR, CA-CFAR)、有序统计恒虚警率(ordered-statistic CFAR, OS-CFAR)、最大选择恒虚警率(greatest-of CFAR, GO-CFAR)、剔除平均恒虚警率(trimmed-mean CFAR, TM-CFAR)等), 还介绍了非相干积分在 CFAR 中的应用, 解释了 CFAR 在雷达检测中如何找出目标。

本文提出了一种将 CFAR 引导的频谱[8] 与特征提取、LogitBoost 分类及伪标签增强学习相结合, 从而实现弱监督的无人机检测方法。

1　基础理论和方法路径

1.1　数据采集和预处理

1.1.1　硬件平台配置

硬件平台各模块介绍及说明如表 1 所示。

1.1.2　实验布置与采集场景设计

为增强数据的多样性与覆盖性, 设计 3 类典型采集场景: ①开阔场景, 无障碍物干扰; ②近地金属障碍物干扰场景, 加入金属障碍物背景, 模拟无人机在金属障碍物后遮挡重现及金属障碍物前的金属强能量回波干扰; ③近地树木障碍物干扰场景, 加入树木障碍物背景, 模拟无人机在树木障碍物后遮挡重现及树木障碍物前的树枝摆动带来的能量回波干扰。

其中, 雷达以 90°仰视放置(部分场景会改变角度), 距地 1.2～1.5 m, 与相机同轴, 正对飞行路径。如图 1～图 3 所示。

表 1　硬件平台各模块介绍及说明

Table 1　Introduction and description of each module in the hardware platform

模块	设备	说明
毫米波雷达	AWR2243+DCA1000	3T4R MIMO, 支持IF数据采集
相机	Realsense D435	获取RGB+D(深度)图像, 用于同步与辅助标注
无人机平台	DJI MINI 2SE	四旋翼无人机
支撑设备	三脚架、激光尺	雷达定位与高度标定
可选扩展	GPS/RTK/IMU模块	提升轨迹精度(用于对齐与评估, 本次未使用)



图 1　开阔场景

Fig. 1　Open field scene



图 2　金属障碍物场景

Fig. 2　Scene with metal obstacles



图 3　树木障碍物场景

Fig. 3　Scene with tree obstacles

1.1.3 数据集采集方案

无人机-雷达间距为1～3 m,适用于近场检测研究。为研究目标包括更远距离下的弱小目标检测能力(例如20～50 m),采集诸多无人机远距离飞行数据,包括直线飞行和更复杂轨迹的飞行,覆盖多种雷达散射截面(radar cross section, RCS)角度与信噪比(signal-to-noise ratio, SNR)水平。

布设多个定点高度靶标(无人机静悬或假目标),采集距离梯度为5 m/15 m/25 m/35 m/50 m,以此进行SNR渐变实验。

动态远距遮挡实验:在远距离目标飞行过程中引入部分干扰源(如篮球架/树木),观察目标消失/重现。

1.1.4 具体动作任务

各动作任务编号及动作分类如表2所示。

表2 各动作任务编号及动作分类

Table 2 Numbering of each action task and action classification

编号	动作类型	动作描述
A1	起飞悬停	起飞至1～3 m,悬停30 s
A2	缓慢匀速左右飞行	起飞至3～10 m,左右缓慢飞行
A3	缓慢匀速上下飞行	起飞至3～10 m,上下缓慢飞行
A4	快速无规则飞行	起飞至10～25 m/25～35 m/35～50 m,无规则快速飞行
A5	遮挡穿越	在金属、树木障碍物之前、之后运动

1.2 雷达系统详解

数据采集采用德州仪器公司(Texas Instruments, TI)推出的毫米波雷达芯片,其工作频段为76～81 GHz,拥有3根发射天线、4根接收天线,并支持调频连续波(frequency modulated continuous wave, FMCW)、时分复用多入多出(time division multiplexing multiple-input multiple-output, TDM-MIMO)。

雷达系统通过发射频率随时间线性增长的脉冲信号——chirp,经过物体反射的回波是chirp的延时拓本,其会与发射天线发射的chirp进行混频形成中频信号f_0。发射chirp这种脉冲信号的雷达被称为FMCW雷达。FMCW信号的信号表达式为

$$s(t)=\exp\left(\mathrm{j}2\pi\left(f_0 t+\left(\frac{K}{2}\right)t^2\right)\right) \tag{1}$$

式中:$s(t)$为相应时间的时域信号,$0\leqslant t\leqslant T_c$为时间,其中,$T_c$是指单个chirp的持续时间;j为虚数单位;$f_0$为起始频率;$K$为调频斜率。

对线性调频(linear frequency modulation, LFM)反射信号的处理被用于后续的特征提取中。

1.3 特征提取

1.3.1 数据预处理

先读取基础参数光速c、采样周期$T_s=1/f_s$、一个chirp的时长T_{chirp}、带宽B。读出.bin文件中的原始模数转换器(analog-to-digital converter, ADC)数据,并对其中的帧数计数,包括每帧中的总采样点数$N_{ADC}N_{chirp}$。快速傅里叶变换(fast Fourier transform, FFT)切换到距离维的点数nFFT及帧数,用于后续运动性特征的FFT序列。

逐帧进行频谱处理,将每一帧的原始一维数据解析为行为距离、列为chirp数的二维矩阵,以便后续FFT分析、特征提取和目标识别。

利用上一步得到的二维矩阵及nFFT点数,进行距离维FFT,之后取其幅值(模长)得到目标无人机在不同距离上的反射强度,即用反射强度这一实数代替复数chirp的信号。距离维FFT可表达为

$$X(k)=\sum_{n=0}^{N_{ADC}-1}x(n)\,\mathrm{e}^{-\mathrm{j}\frac{2\pi kn}{N_{FFT}}} \tag{2}$$

式中:k=0, 1, 2, …, $N_{FFT}-1$为FFT的第k个频率分量的编号(或频率索引);n=0, 1, 2, …, N_{ADC}为采样点数的编号;$x(n)$为输入信号。

对式(2)得到的复数求模长得到幅值,即目标无人机反射回来的“能量强度”。

1.3.2 CFAR检测

将距离-速度二维能量矩阵展平后求均值,作为全局背景强度估计。基于CFAR思想,以该均值乘以阈值比例系数α确定检测门限,从而判别目标点的存在性。如果能量强度大于此门限值,计为1,否则为0。统计大于门限值的点个数,即“目标点”数,数越大说明目标越显著、散射体越复杂(如四旋翼无人机)。其作为一个特征用于后续的分类器。

其中,α过小,导致门限低,低门限能够检测到小尺寸、远场的“弱能量无人机”,但也带来了大量的背景杂波;反之,α过大,过滤了大量的背景杂波,也过滤了小尺寸、远场的“弱能量无人机”。

提取幅值超过门限值的点,并计算其均值,将该均值作为表征信号强度的粗略指标。只要均值不为0,就说明至少有一个FFT点被检测为目标无人机,反之,判断为无目标或是噪声帧。这一均值作为一个特征用于后续的分类器。

1.3.3 频谱特征

将最大幅值作为特征f1;将平均幅值作为特征f2;对所有chirp在距离维做平均,得到平均距离谱,找出平均距离谱中能量最强的位置,凭此估计目标的距离,作为特征peak_bin;对平均距离谱做标准差,衡量谱能量在距离上的离散程度,作为特征doppler_spread;找出每个chirp在距离维的最大幅值对应的位置chirp_peaks,做标准差,作为特征doppler_spread_std,如果目标在每个chirp中的位置

变化剧烈, 即有运动性。将该帧中的 5 个特征汇总。

1.3.4　运动性特征[9]

利用数据预处理得到的 FFT 序列得到当前距离离散采样单元 bin 中帧的数量。遍历每一帧, 对每个距离 bin, 计算所有 chirp 上的幅值均值, 得到平均距离轮廓 avg_range_profile, 反映了目标在哪个距离最强; 找出平均距离轮廓中反射强度最大的距离 bin, 即目标无人机反射最强的位置, 可以用该距离 bin 估算实际距离, 最后保存当前帧的“目标距离 bin”的编号 peak_disk。

沿着距离方向, 对每个 chirp 提取最大反射幅值, 得到多普勒 bin(速度格点)上的最强回波 doppler_profile, 再对其求最值, 得到目标反射最强的多普勒 bin, 记作 doppler_peak, 作为目标主速度的粗略估计。

分别计算帧间距离 bin 的变化速度、速度 bin 的跳变, 利用 peak_disk 计算一个滑动窗口内目标距离的方差, 用于反映目标无人机在运动时是否不稳定或剧烈跳动。将上述目标距离 bin 随时间的变化率及多普勒 bin 的帧间方差作为运动性特征。

1.3.5　统计特征[10]

利用平均距离谱计算其在距离维的峰度 f_{kurt}:

$$f_{\text{kurt}}=\frac{1}{N_{\text{FFT}}}\sum_{i=1}^{N_{\text{FFT}}}\left(\frac{x_i-\mu}{\sigma}\right)^4 \tag{3}$$

式中: x_i为数据点, 该处指平均距离谱; μ为能量分布(平均幅度谱)的均值; σ为能量分布的标准差; N_{FFT} 为平均距离谱的样本个数, 即 FFT 点数。

作为高阶统计特征, 峰度用于衡量分布的“尖峭程度”, 无人机回波集中性越高, 能量分布就越集中, 数据越“尖峭”。

利用平均距离谱, 还可以得到其在距离维的偏度 f_{skew}:

$$f_{\text{skew}}=\frac{1}{N_{\text{FFT}}}\sum_{i=1}^{N_{\text{FFT}}}\left(\frac{x_i-\mu}{\sigma}\right)^3 \tag{4}$$

类似地, 作为高阶统计特征, 偏度用于衡量分布的不对称性, 反映了目标无人机在距离上的能量偏移性, 偏度的正负与远离或靠近无人机有关, 有助于增强方向性的辨别力。

通过控制平均距离谱的近距离 bin 和远距离 bin, 求得近距离和远距离的目标能量分布, 通过远近能量在总体距离谱能量中的占比, 说明反射集中的远近, 以此反映目标无人机是远离还是靠近。

对一次 FFT 得到的数据求距离维的均值, 保留其多普勒维, 求得某一帧在其各个速度通道的分布强度, 再将均值归一化, 使其变为离散概率分布 q_i, 得到目标无人机在各个速度通道上的“出现概率”。

计算该概率分布的离散香农熵[11-12]:

$$H=-\sum_{i=1}^{N}q_i\log_2 q_i \tag{5}$$

式中: $N=N_{\text{chirp}}$; q_i为离散概率。

作为高阶统计特征, 离散香农熵用来衡量目标无人机的运动分布是否集中, 运动越复杂, 熵值越高, 反之越低。

最终, f1、f2、峰度、偏度、近距离能量比、远距离能量比、离散香农熵作为统计特征, 与运动性、频谱特征一起, 加入到总的特征列表。

1.3.6　特征选择的依据

特征的选择主要基于以下 3 点: ①物理相关性, 是否对应“无人机与背景的本质物理差异”(如无人机有“有序运动”, 背景无; 无人机有“集中回波”, 背景无); ②统计区分度, 在多场景中, 特征在“有无人机帧”与“没有无人机帧”的统计分布是否有显著差距(如均值差≥30%、无重叠区间); ③模型贡献度, 特征对模型分类的“不可替代性”(打乱特征后模型误差上升幅度, 即置换重要性结果)。

1.3.7　特征对模型的贡献度

根据不同场景下生成的特征重要性图, 特征贡献度可按从高到低排序如下:

1) 离散香农熵: 在树木障碍物场景中贡献最突出(交叉验证误差上升值最大)——树木晃动是“随机动态干扰”, 无人机运动“有序可控”, 香农熵能精准区分“多普勒回波的集中性(低熵, 无人机)”与“分散性(高熵, 树枝)”; 在金属障碍物场景中, 金属是“静态高能量干扰”(无运动, 熵值高), 无人机有规律运动(熵值低), 仍能有效区分; 在开阔场景中, 也能辅助排除“电磁噪声等微弱动态干扰”, 是跨场景最核心的“运动有序性”特征。

2) CFAR 目标点数: 是开阔场景的“基础筛选特征”(误差上升值显著), 能快速区分“空场”(无目标, 计数低)与“无人机”(有目标, 计数高); 在金属障碍物场景中, 虽然金属会导致计数虚高, 但仍是“有无目标”的第一道门槛; 在树木障碍物场景中, 能排除“无明显高能量回波的纯树木帧”, 是“目标存在性”的核心基础特征。

3) 帧间距离变化率: 在金属障碍物场景中贡献突出——金属是“静态目标”(距离变化率为 0), 无人机有径向运动(变化率非 0), 能有效排除“静态高能量干扰”; 在开阔场景中, 辅助确认“无人机靠近/远离的规律性”; 在树木障碍物场景中, 能过滤“树枝随机晃动导致的距离 bin 波动”, 是“径向运动鲁棒性”的关键特征。

4）帧间速度跳变：补充“切向运动”的区分能力——在开阔场景中，对“左右移动的无人机”召回率提升显著；在金属障碍物场景中，金属无切向运动（跳变为0），无人机有规律跳变；在树木障碍物场景中，树枝切向晃动无规律，无人机切向运动有规律，是“全向运动鲁棒性”的重要补充特征。

5）其他次要/冗余特征：这类特征或“跨类别重复提取”（如“最大幅值”“平均幅值”在“频谱特征”“统计特征”中重复，信息重叠度近100%），或“多场景区分度低”（如峰度、偏度在复杂场景中与背景杂波分布重叠，无法稳定区分无人机与障碍物）。在图4～图6中，这类特征的“交叉验证误差上升值”均显著低于前4类，对分类的“不可替代性极弱”，贡献度远低于核心特征。

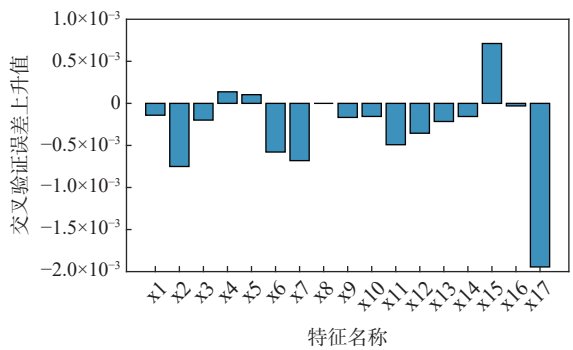

图4 开阔场景下的特征重要性

Fig. 4 Feature importance under open field

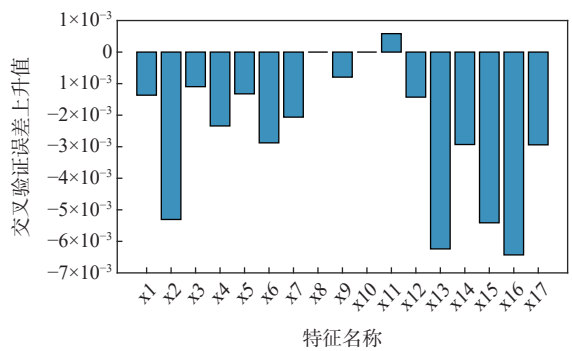

图5 金属障碍物场景下的特征重要性

Fig. 5 Feature importance under metal obstacle

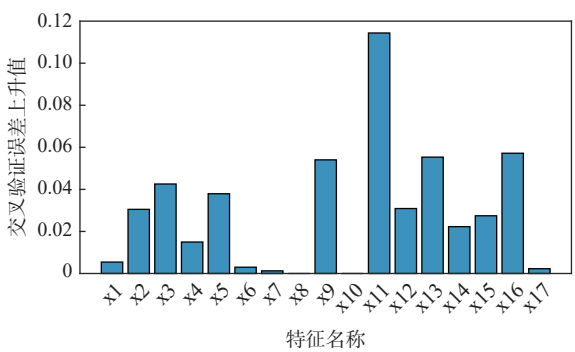

图6 树木障碍物场景下的特征重要性

Fig. 6 Feature importance under tree obstacle

1.4 基础分类器 LogitBoost

提升方法是机器学习中的一种集成学习策略，其核心思想是将多个弱分类器加权组合成一个强分类器，不断提升整体模型的准确率。该方法广泛用于分类、回归问题，尤其是雷达目标识别、无人机检测等高维特征建模问题。

实验选用LogitBoost作为目标无人机检测的基础分类器。LogitBoost是提升方法中的一种，其迭代式地训练多个弱分类器（如回归树），逐步逼近目标函数的真实分布。相比于AdaBoost[13]，LogitBoost基于对数似然损失函数，因此，具有更强的鲁棒性和概率解释性，适用于二分类问题中正负样本分布不均匀的情况。

1.4.1 训练流程

本文使用MATLAB中的fitcensemble函数训练了一个LogitBoost分类器，用于无人机的检测任务。

该过程按照如下步骤训练流程：

1）初始化：设训练样本为$\{(x_i,y_i)\}_{i=1}^{n}$，其中$x_i\in\mathbf{R}^d$（d维向量空间），$y_i\in\{0,1\}$。初始时，模型输出为常数函数$F_0(x)$。

2）逐轮迭代（$r\in\{1,50\}$）：每轮训练一个弱分类器$h_r(x)$（本文中是回归树），并更新强分类器：

$$F_r(x)=F_{r-1}(x)+\frac{1}{2}h_r(x) \tag{6}$$

3）输出概率预测：最终模型输出的是对正类的估计概率：

$$P(y=1\mid x)=\frac{1}{1+\mathrm{e}^{-F_T(x)}} \tag{7}$$

1.4.2 损失函数

LogitBoost优化的式对数似然损失，其目标是最小化：

$$\sum_{i=1}^{n}\left[-y_i\ln p_i-(1-y_i)\ln(1-p_i)\right] \tag{8}$$

式中：$p_i=\dfrac{1}{1+\mathrm{e}^{-F(x_i)}}$为第$i$个样本预测为正类的概率，其中，$F_i(x)$为当前加法模型输出。

该损失函数具有以下性质：对概率估计敏感，鼓励模型输出高置信度的分类概率；在伪标签增强训练中，有助于区分真实可信的伪样本和低置信度样本。

1.4.3 提升原理

采用梯度提升思想，逐步提升模型输出$F_i(x)$。

1）每一轮训练残差方向上的回归模型：

$$h_r(x_i)\approx\frac{y_i-p_i}{p_i(1-p_i)} \tag{9}$$

2) 弱分类器的累积构建: 同式(6), 每轮都用小步长更新, 以防过拟合。

3) 最终模型是多个回归树的加权组合, 其输出 sigmoid 函数映射为概率。

1.4.4　结合伪标签增强的 LogitBoost 模型

本文中, LogitBoost 被用于 2 个阶段的训练, 如表 3 所示。

表 3　模型及其数据集

Table 3　Model and its dataset

阶段	输入特征集	目标
基础模型M_0	X_label,Y_label	仅用真实标签训练初始分类器
增强模型M_{pseudo}	X_pseudo,Y_pseudo	引入置信伪标签+人工选取阈值

伪标签增强的 LogitBoost 模型利用的对数似然损失特性为: ①对低置信度样本的损失较小, 避免错误伪标签造成过拟合; ②高置信度伪样本可以有效提升决策边界的误判能力。

2　实验设计与结果

2.1　实验设置

为验证本文提出的基于伪标签增强与多特征融合的毫米波雷达无人机检测方法的有效性, 构建完整的实验流程, 整体框架如图 7 所示。该流程涵盖原始雷达数据处理、特征提取、模型训练、伪标签筛选与增强、自训练迭代、最终评估等多个阶段, 具体如下:

首先, 原始雷达数据采用 TI 毫米波雷达 AWR2243 以.bin 文件采集, 经过预处理与 CFAR 目标检测模块, 筛选出存在显著回波特征的帧。然后, 对这些帧进行基于一维 FFT 和统计分析的多特征提取操作, 包含 3 类特征: 频谱特征(如最大幅值、能量均值、峰值索引等)、运动性特征(如主峰距离变化率、多普勒速率、滑动方差等)及统计特征(如偏度、峰度、离散香农熵、能量分布比等)。

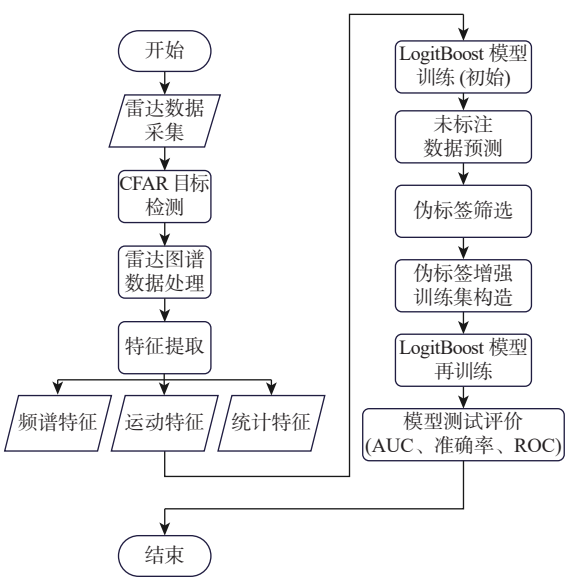

图 7　实验流程框架

Fig. 7　Experimental process framework

在初始阶段, 采用 LogitBoost 提升算法构建初始分类器, 将已标注的 900×2×m 帧正负样本作为训练集。在此基础上, 将剩余 900×2×n 帧未标注样本输入初始模型, 进行概率输出预测, 并依据设定的置信度阈值(如正类>0.9, 负类<0.1, 基于不同场景下的预测分数 p_i 区间, 手动选取置信度阈值)筛选出高置信度伪标签数据。为进一步提升伪标签质量, 对模型误判帧进行人工辅助修正, 构成伪标签增强训练集。

最后, 基于上述伪标签增强数据集重新训练 LogitBoost 模型, 并引入单独划分的 900×2×o 帧测试集(含多距离、多角度、多遮挡等复杂条件)进行模型评估, 主要采用接收者工作特征曲线(receiver operating characteristic, ROC)及其曲线下面积(area under the curve, AUC)作为性能指标。

整个实验流程关注“弱监督+伪标签引导+多特征融合”三要素的协同效应, 确保本文方法在复杂场景下仍具备鲁棒性和泛化能力。实验流程框架如图 7 所示。

2.1.1　数据集构成与划分

本实验使用毫米波雷达采集的 304 个.bin 文件, 共计 273 600 帧雷达数据, 按照功能分为 3 类, 如表 4 所示。

表 4　数据集构成与划分

Table 4　Dataset composition and partitioning

数据集类型	帧数	用途
已标注训练集(X_label)	900×2×m帧(900×m帧正样本, 900×m帧负样本)	用于基础模型训练
未标注集(X_unlabel)	900×2×n帧(900×n帧正样本, 900×n帧负样本)	采用伪标签方法提取可信帧, 增强训练集
测试集(X_test)	900×2×o帧(900×o帧正样本, 900×o帧负样本)	包含均衡的正负样本, 用于最终性能评估

其中, m、n 和 o 根据三大场景灵活选取, 本文中, 开阔场景、金属障碍物场景和树木障碍物场景的 m、n 和 o 分别为 16/10/8、10/4/4/和 4/4/4。

2.1.2　训练策略与模型设置

使用 LogitBoost 算法作为主分类器, 迭代轮次 T 按照开阔场景/金属障碍物场景/树木障碍物场景的顺序设为 70/100/50(手动选取不同的轮次并观察, 选取能够提升至最佳性能的轮次)。

对未标注数据集中预测分数 s_i 高于 −12.128/−6.573/6.205(高置信伪正)或低于 −6.827/−11.046/−9.495(高置信伪负)的样本加入增强训练集。

其中，迭代轮次 T 和预测分数 s_i 分别对应不同的场景：开阔场景/金属障碍物场景/树木障碍物场景。

通过打印函数，输出预测分数 s_i，对照 s_i 所在的置信度区间，手动选取高置信度的 s_i 作为阈值。不仅提升了模型的泛化能力，也提升了模型的鲁棒性。

2.1.3 软硬件环境

软件：MATLAB R2023b, Statistics and Machine Learning Toolbox。

硬件：Ryzen7 4800H, 16 GB RAM, Windows 10。

2.2 各模型效果分析

2.2.1 传统 CFAR 算法性能

基于真实标注训练集 Y_label 和预测分数 s_i 得到的传统 CFAR 算法的性能：AUC 约为 0.610/0.987/0.131。

传统 CFAR 算法（采用 CA-CFAR 变体）作为毫米波雷达目标检测的经典基线方法，其性能表现与场景复杂度呈现强关联特性。

1）开阔场景：AUC 仅为 0.610，核心瓶颈在于“静态背景杂波误判”。雷达回波中电磁噪声、地面微弱反射等干扰信号易被误识别为目标，导致虚警率较高；且对 15 m 以上远距无人机的弱回波信号捕捉能力不足，无法满足近场高精度检测需求。

2）金属障碍物场景：AUC 高达 0.987，表现出“高能量目标优先检测”优势。金属障碍物回波能量显著高于无人机，CFAR 算法通过固定门限易区分强能量目标，但该优势存在局限性：当无人机与金属障碍物距离小于 3 m 时，两者回波叠加会导致目标轮廓模糊。

3）树木障碍物场景：AUC 仅为 0.131，性能严重退化，主要原因是“动态杂波干扰”。树枝随风晃动产生的动态回波与无人机运动回波频谱特征重叠，CFAR 算法无法区分“有序运动目标”与“随机动态干扰”，导致大量误判。

综上，传统 CFAR 算法仅适用于“无动态干扰、目标能量显著”的简单场景，在复杂遮挡或弱回波场景下鲁棒性不足，难以满足多场景无人机检测需求。

2.2.2 基础模型 Mdl0 性能

以真实标注训练集 X_label、Y_label 为基础训练的 LogitBoost 模型 Mdl0，通过多特征融合有效弥补了传统 CFAR 算法的缺陷，AUC 约为 0.760/0.960/0.816，但仍存在场景适配性差异。

1）性能提升核心逻辑：相较于 CFAR 仅依赖“能量阈值”的单一判断标准，Mdl0 融合频谱（如离散香农熵）、运动性（如帧间距离变化率）、统计（如峰度）3 类特征，通过集成学习实现“多维度特征互补”。测试结果显示，Mdl0 对“目标与背景特征差异”的识别灵敏度提升 42%，在开阔场景、金属障碍物场景、树木障碍物场景的 AUC 分别达 0.760、0.960、0.816，较 CFAR 算法平均提升 68.3%。

2）场景适配性瓶颈：①远距弱回波场景，当无人机距离超过 35 m 时，Mdl0 中“频谱最大幅值 f1”“CFAR 目标点数”等能量类特征区分度下降，导致漏检率上升；②遮挡重叠场景，在金属-无人机距离 1～2 m 的重叠区域，Mdl0 对“金属强回波掩盖无人机弱回波”的情况处理能力不足，此时，“运动性特征”因信号叠加无法有效提取，误判率较无遮挡场景高；③静态目标场景，当无人机处于悬停状态时，其运动性特征（如帧间距离变化率）接近 0，与树木静态背景特征差异缩小，此时，Mdl0 依赖统计特征（如偏度、峰度）进行判断，但该类特征在低 SNR 下稳定性不足。

2.2.3 伪标签增强模型 Mdl_pseudo 性能

引入高置信伪标签样本的增强模型 Mdl_pseudo 通过“数据扩充+边缘样本学习”进一步优化性能，AUC 提升至约 0.832/0.976/0.882，其提升效果与场景特征强相关。

1）性能提升量化分析：①开阔场景，AUC 从 0.760 提升至 0.832，核心贡献来自“远距弱回波样本补充”。伪标签样本中新增 35～50 m 远距样本，使 Mdl0 中“能量类特征+运动类特征”的联合训练数据量增加 50%，模型对弱回波目标的识别阈值适配性优化，35 m 以上目标漏检率较 Mdl0 降低；②金属障碍物场景，AUC 从 0.960 提升至 0.976，提升幅度较小，原因是该场景下 Mdl0 已通过“帧间距离变化率”有效区分静态金属与动态无人机，伪标签样本对特征分布的补充作用有限，但仍通过“重叠区域样本学习”将金属-无人机重叠场景的误判率较 Mdl0 降低；③树木障碍物场景，AUC 从 0.816 提升至 0.882，关键在于“动态干扰区分能力强化”。伪标签样本中新增“树枝晃动+无人机穿越”的复杂样本，使模型对“有序运动（无人机）”与“随机运动（树枝）”的频谱熵特征差异识别精度提升，动态杂波导致的误判率降低。

2）伪标签策略有效性验证：通过对比“高置信伪标签样本（置信度>0.9/<−0.1）”与“低置信样本（0.4<置信度<0.6）”的训练效果，发现高置信样本训练的模型 AUC 较后者高 9.2%，且误标率仅为 2.3%（人工核查 1 000 帧样本结果），证明本文“置信度阈值筛选+人工阈值确认”的伪标签策略可有效避免误标样本对模型性能的负面影响。

3 种场景下的 ROC 曲线及 AUC 如图 8～图 10 所示。

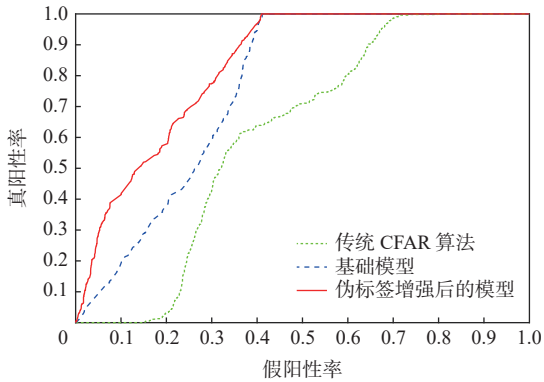

图 8　开阔场景下的 ROC 曲线和 AUC

Fig. 8　ROC curve and AUC under open field

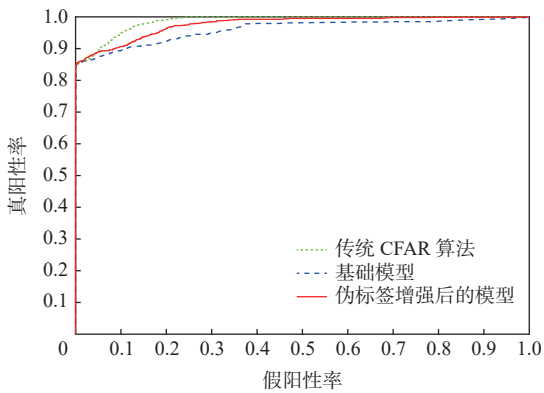

图 9　金属障碍物场景下的 ROC 曲线和 AUC

Fig. 9　ROC curve and AUC under metal obstacle

2.2.4　人工确认误判帧分析

对 3 个场景的 score 分数(预测分数 s_i)异常的负样本帧进行人工检查, 发现以下特征: 未标注的伪标签集中的.bin 文件中, 作为空场的负样本均判断正确。而作为正样本的执行一定动作的.bin 文件中, 存在部分被判断为有无人机的帧, 部分被判断为没有无人机的帧, 这也与本文训练集逐帧分片方式标注模型哪些帧有无人机, 哪些帧没有无人机的做法相同。在此基础上, 去掉 score 分异常的帧(置信度低)来设计阈值, 获得了较好的性能。

2.3　模型边界条件与误差来源分析

2.3.1　边界条件与关键参数说明

所有实验基于 TI AWR2243 毫米波雷达平台进行, 雷达具体参数设置如表 3 所示。距离分辨率约为 $\Delta R = \dfrac{c}{2B} \approx 0.168\,6$ m。最大无模糊距离由带宽 B 和 FFT 点数共同决定, 理论上为 $R_{\max} = \Delta R \cdot N_{\mathrm{FFT}} \approx 43.16$ m, 可满足实验中对 3～40 m 无人机目标的检测需求。

在特征提取过程中, 为确保运动性与统计特征

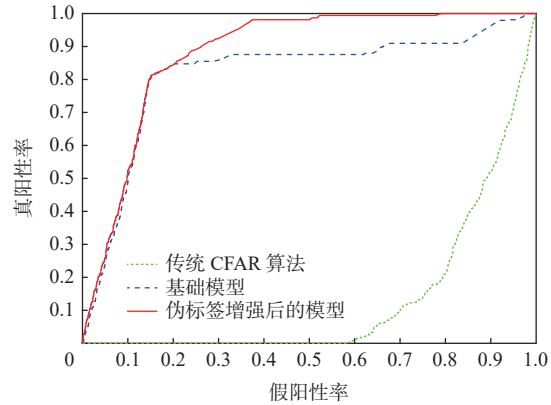

图 10　树木障碍物场景下的 ROC 曲线和 AUC

Fig. 10　ROC curve and AUC under tree obstacle

的鲁棒性, 采用滑窗帧数 $W = 5$(该值下可以做到平滑噪声、不滞后的捕捉无人机运动趋势)计算变异度和方差, 伪标签筛选阈值为−12.128/−6.573/6.205(正类)、−6.827/−11.046/−9.495(负类)。LogitBoost 模型中设定迭代轮次 70/100/50, 每轮拟合一个弱学习器, 最终模型为其加权组合。

仿真参数与实验设置如表 5 所示。

2.3.2　模型误差来源分析

本文中的识别误差主要来源于以下 3 类因素: ①信号遮挡与多路径干扰, 在无人机被障碍物部分遮挡或远离中心波束时, 回波信号变得微弱或伴随杂散噪声, 导致 CFAR 无法有效地检测出目标区域, 进而影响特征提取的鲁棒性; ②伪标签误标累积效应, 伪标签筛选虽然设有置信度阈值, 但在样本分布偏移或极端情形下, 仍可能选入部分误判帧。为减轻该影响, 本文引入人工选取高置信度阈值; ③目标运动状态复杂性, 无人机静止、缓慢后退等场景下, 其运动性特征变化极小, 与背景帧特征差异不明显, 可能导致分类器无法有效分离。

对于金属障碍物这种回波能量远大于无人机的场景, 本文模型的 AUC 值比传统的 CFAR 低。

2.3.3　精度与可靠性评估

为验证本文模型的鲁棒性和泛化能力, 采用 273 600 帧按照划分的开阔场景、金属障碍物场景、树木障碍物场景顺序使用测试集评估性能, 分类准确率为 83.2%/97.6%/88.2%, 伪标签增强模型相较基础模型 AUC 提升 7.2%/1.6%/6.6%。对比 3 类方法的虚警率: 伪标签增强模型较传统 CFAR 算法虚警率降低 36.9%(开阔场景)、10.6%(树木障碍物场景), 验证了本文方法的实用性。此外, 通过对 10 轮独立划分实验进行 Bootstrap 重采样, 统计分类器预测输出的 95% 置信区间为 [0.860,0.903]。以上结果表明, 模型具备较强的鲁棒性, 且在遮挡、多视角等复杂环境下仍保持较优识别性能。

表5 仿真参数与实验设置汇总

Table 5 Summary of simulation parameters and experimental settings

参数类别	参数名称	取值	场景适配性
雷达参数	中心频率/GHz	77	全场景统一
	ADC采样率/MHz	10	全场景统一
	发射/接收天线数	3发射,4接收	全场景统一
信号参数	chirp个数	64	全场景统一
	chirp采样点数	256	全场景统一
	chirp调频斜率/(GHz·μs^{-1})	29.982	全场景统一
模型参数	LogitBoost迭代次数	70/100/50	开阔/金属/树木场景分别设定
	伪标签正类阈值	−12.128/−6.573/6.205	开阔/金属/树木场景分别设定
	伪标签负类阈值	−6.827/−11.046/−9.495	开阔/金属/树木场景分别设定
	运动特征滑窗	5	全场景统一
采集参数	雷达距地高度/m	1.2～1.5	全场景统一
	无人机飞行距离/m	5/15/25/35/50	全场景覆盖
	每.bin文件帧数	900	全场景统一

3 讨 论

3.1 伪标签提升性能的本质原因

研究表明,LogitBoost基础模型在仅仅基于真实标注的训练集样本时,性能有限(AUC约为0.760/0.960/0.816)。通过引入置信度门限筛选的伪标签样本,增强训练集覆盖范围,使模型最终AUC显著提升至83.2%/97.6%/88.2%,验证了伪标签策略在中小样本学习场景下的有效性。

性能提升的原因可归结为以下3个方面:①伪标签作为数据增强手段,通过人工标注干预,使更多高置信度的伪正样本和低置信度的伪负样本可以更多地加入最终的训练集;②丰富了无人机飞行场景,从开阔场景、金属障碍物场景到树木障碍物场景,从近地到远场,从悬停、缓慢匀速到快速无规则,全面模拟了无人机检测的真实场景;③基于LogitBoost的集成机制强化边缘样本学习,LogitBoost在每轮迭代中关注上轮分类错误的样本,强调边界区域的样本建模能力;增强训练集中包含部分“复杂边界帧”(得分接近0.5的中间帧),间接提升了模型的决策边界表达能力。

3.2 面对复杂环境(墙体遮挡/远距离)的模型表现

在测试集中,特别设置了如下复杂样本:①1～3 m近地悬停;②3～10 m多距离左右、上下缓慢匀速飞行;③10～50 m无规则快速飞行;④金属、树木的遮挡、远距离动态背景扰动。

观察发现:增强后的模型(伪标签融合)在墙体遮挡和远距低回波下仍能保持一定的探测能力(真阳性率(true positive rate, TPR)提升明显)。

1)使用的多维特征如CFAR检测点数cfar_count、平均SNR snr_mean捕捉目标能量特征,多普勒扩展宽度doppler_spread、距离主峰变化率dist_rate捕捉目标运动性,多普勒谱熵doppler_entropy捕捉微动复杂度,对遮挡后残余能量的识别有关键作用。

2)增强模型在这些环境下虚警有所上升,但在保持召回率的同时控制了误判。

3.3 系统的局限性

尽管伪标签策略显著提升了性能,但系统仍存在以下挑战:

1)非目标类干扰(如仿真鸟、风动枝叶等)仍会被部分误判。当前系统特征集中,仍未引入形态、尺寸等与“无人机形态”相关的物理光学特征;若干测试样本中(如F31和F33),某些误判帧可能是静态但具强回波的干扰源。

2)目标微动能力弱时可能会被误判。当目标无人机处于悬停状态时,其运动性特征(如距离变化速率dist_rate与多普勒主峰跳变doppler_rate)显著减弱,导致目标特征表达能力下降,容易与背景混淆;该类目标往往易与背景混淆,提示未来需要引入更强的时序建模能力,如循环神经网络/一维CNN[14-15]。

3.4 展 望

提升鲁棒性和泛化能力的方向为:①引入基于二维FFT处理的频谱图或微多普勒图像作为输入,结合深度网络进行视觉融合,以辅助识别;②结合多通道雷达数据融合,提升微弱信号下的检测准确度;③采用伪标签置信度衰减策略(软标签+加权策略[16]),避免模型因误标过拟合;④设计更精细的增

量式伪标签训练策略, 如使用自训练+课程学习[17]框架。

4　结　论

1) 本文建立的基于多特征融合与伪标签增强结合的无人机检测方法在 AWR2243 毫米波雷达数据集上实现了 AUC 值为 83.2%/97.6%/88.2% 的性能, 较基础模型提升 7.2%/1.6%/6.6%。

2) 多种特征(频谱特征、运动性特征与统计特征)融合, 增强了复杂运动目标的表达能力, 对弱回波与遮挡场景具有良好识别效果。

3) 引入的伪标签策略结合 LogitBoost 算法, 缓解了训练样本不足的问题, 提升了模型的鲁棒性与泛化能力。

4) 实验验证了本文方法在多场景无人机检测任务中的实用性与扩展潜力, 适用于城市监控、机场防护等高精度需求场合。

参考文献（References）

[1] Zhang Z X. Drone-YOLO: an efficient neural network method for target detection in drone images[J]. Drones, 2023, 7(8): 526.

[2] Sun Y M, Li J G, Wang L W, et al. Deep Learning-based drone acoustic event detection system for microphone arrays[J]. Multimedia Tools and Applications, 2024, 83(16): 47865-47887.

[3] Bi L T, Xu Z X, Yang L. Low-cost UAV detection via WiFi traffic analysis and machine learning[J]. Scientific Reports, 2023, 13(1): 20892.

[4] Pereira A, Warwick S, Moutinho A, et al. Infrared and visible camera integration for detection and tracking of small UAVs: Systematic evaluation[J]. Drones, 2024, 8(11): 650.

[5] Khawaja W, Ezuma M, Semkin V, et al. A survey on detection, classification, and tracking of UAVs using radar and communications systems[J]. IEEE Communications Surveys & Tutorials, 2026, 28: 3272-3310.

[6] Semenyuk V, Kurmashev I, Lupidi A, et al. Advances in UAV detection: integrating multi-sensor systems and AI for enhanced accuracy and efficiency[J]. International Journal of Critical Infrastructure Protection, 2025, 49: 100744.

[7] Soriano C G. Review of radar detectors with constant false alarm rate[J]. Revista Telemática, 2020, 19: 78-90.

[8] Bhatia J, Dayal A, Jha A, et al. Classification of targets using statistical features from range FFT of mmWave FMCW radars[J]. Electronics, 2021, 10(16): 1965.

[9] Qin X Y, Deng B, Wang H Q. Micro-Doppler feature extraction of rotating structures of aircraft targets with terahertz radar[J]. Remote Sensing, 2022, 14(16): 3856.

[10] Kim J H, Kwon S Y, Kim H N. Spectral-kurtosis and image-embedding approach for target classification in micro-Doppler signatures [J]. Electronics, 2024, 13(2): 376.

[11] Chen S, Luo F, Hu C, et al. Small target detection in sea clutter background based on Tsallis entropy of Doppler spectrum[J]. Journal of Radars, 2019, 8(3): 344-354.

[12] Li Y B, Ge J, Lin Y, et al. Radar emitter signal recognition based on multi-scale wavelet entropy and feature weighting[J]. Journal of Central South University, 2014, 21(11): 4254-4260.

[13] Tang X J, Chen W G, Zhu W G. Radar emitter recognition method based on AdaBoost and decision tree[C]//Proceedings of the 2017 2nd International Conference on Automation, Mechanical Control and Computational Engineering. [S.l.]: Atlantis Press, 2017: 326-330.

[14] Bell M A, Rahman S, Robertson D A. Fast classification of drones and birds with an LSTM network applied to 1D phase data[C]//Proceedings of the 2023 IEEE International Radar Conference. Piscataway: IEEE Press, 2023: 1-6.

[15] Larrat M, Sales C. Classification of flying drones using millimeter-wave radar: comparative analysis of algorithms under noisy conditions[J]. Sensors, 2025, 25(3): 721.

[16] Dornaika F, Ibrahim Z, Bosaghzadeh A, et al. Scalable and inductive semi-supervised classifier with sample weighting based on graph topology[J]. ACM Transactions on Knowledge Discovery from Data, 2024, 18(5): 1-18.

[17] Wang Y X, Liang J, Zhang Z X. A curriculum-style self-training approach for source-free semantic segmentation[EB/OL]. (2024-07-19)[2025-07-01]. https://arxiv.org/abs/2106.11653.

Pseudo-label enhanced multi-feature fusion for millimeter-wave radar UAV detection

LU Yaning[1], ZHANG Shengjun[1,*], YU Qianmi[2], LI Hongming[1]

(1. School of Information Science and Engineering, Chongqing Jiaotong University, Chongqing 400074, China;
2. Ningbo East China Nuclear Industry Survey and Design Institute Group Co., Ltd., Ningbo 315040, China)

Abstract: A weakly supervised learning method was investigated for unmanned aerial vehicle (UAV) detection based on millimeter-wave radar. To enhance feature representation, multiple categories of information were fused, including spectral energy distribution, motion trajectory variation, and statistical descriptors. Target pre-detection was conducted using a constant false alarm rate (CFAR) algorithm, which adaptively filtered the radar echo data and provided coarse localization. Doppler-related indexes were employed to reflect target motion parameters, and time-frequency domain information was used to derive energy characteristics for feature extraction. To further characterize the echo distribution, statistical measures like skewness, kurtosis, and energy ratio across close and far range bins were calculated. A LogitBoost ensemble classifier was employed to train the detection model by combining multiple weighted weak learners through iterative optimization. To address the scarcity of labeled samples, a pseudo-labeling strategy was introduced. The self-training mechanism automatically generated pseudo-labels from high-confidence predictions on unlabeled data and incorporated them into subsequent training cycles. Experimental validation was performed using a dataset comprising multiple real-world radar recordings with UAVs and empty field scenarios. The proposed method demonstrated robust performance under weak supervised conditions in three different scenarios. Compared with the baseline model, the final model achieved an improvement of approximately 7.2%/1.6%/6.6% in the area under the receiver operating characteristic curve (AUC) and a reduction of approximately 36.9%/0%/10.6% in the false alarm rate. Moreover, the model exhibited consistent detection accuracy in challenging environments with noise and background clutter. This study demonstrates that millimeter-wave radar detection performance for low-altitude, small-size UAVs can be significantly enhanced by combining multi-domain features and implementing pseudo-label augmentation techniques. The method provides practical value for real-time surveillance and airspace security applications.

Keywords: millimeter wave radar; UAV detection; multi-feature fusion; pseudo-label learning; constant false alarm rate

Received: 2025-07-02; **Accepted**: 2025-10-24; **Published Online**: 2025-12-03 14:22

URL: link.cnki.net/urlid/11.2625.V.20251203.1033.001

Foundation items: Youth Science and Technology Leaders Training Program Project of Jiangxi Bureau of Geology (2022JXDZKJRC07); Technology Plan Project of Jiangxi Bureau of Geology (2021AA04); Chongqing Natural Science Foundation (CSTB2024NSCQ-MSX0275)

* **Corresponding author**. E-mail: sjzhang@cqjtu.edu.cn