

文章编号: 1673-3193(XXXX)XX-0001-12

基于多路径参数注意力融合的无人机射频指纹识别算法

左 顺¹, 张彦军^{1*}, 白先民²

(1. 中北大学 仪器与电子学院, 山西 太原 030051; 2. 北京空间机电研究所, 北京 100094)

摘 要: 针对无人机射频指纹识别中存在的特征利用不充分、信息融合不足等问题, 本文提出一种多路径参数注意力融合网络架构。该方法以 DroneRF 数据集为研究对象, 分别对低频段与高频段采集的射频信号进行建模, 将原始信号同时表征为统计特征与谱图, 从而构建低频统计特征、低频谱图、高频统计特征和高频谱图等 4 条输入路径。在特征提取阶段, 针对统计特征, 引入 TabNet-SA 模型进行特征选择与深层表示学习; 针对谱图特征, 采用 EffNet-Slim 模型提取判别特征。在多路径特征融合阶段, 设计参数注意力融合策略, 通过可学习参数进行自适应加权, 增强不同模态、不同频段特征之间的互补性, 提高整体特征表征能力。为验证所提方法的有效性, 本文设计了 12 组对比实验, 包括单路径、双路径、平均融合、不同融合策略以及主干网络替换等实验。在 DroneRF 数据集上的分类结果表明, 在二分类、四分类和十分类任务中, 该方法的平均准确率分别达到 100.00%、99.70% 和 99.54%。该方法为复杂电磁环境下的无人机目标识别提供了一种解决方案。

关键词: 射频指纹识别; 无人机监管; 多路特征提取; 参数注意力融合; 深度学习

中图分类号: TN911.7; V279 文献标识码: A doi: 10.62756/jnuc.issn.1673-3193.2025.11.0022

引用格式: 左顺, 张彦军, 白先民. 基于多路径参数注意力融合的无人机射频指纹识别算法[J]. 中北大学学报(自然科学版), DOI:10.62756/jnuc.issn.1673-3193.2025.11.0022.

Zuo Shun, Zhang Yanjun, Bai Xianmin. Multi-Path Parametric Attention Fusion Network for Drone RF Fingerprint Identification[J]. Journal of North University of China(Natural Science Edition), DOI:10.62756/jnuc.issn.1673-3193.2025.11.0022.

Multi-Path Parametric Attention Fusion Network for Drone RF Fingerprint Identification

Zuo Shun¹, Zhang Yanjun^{1*}, Bai Xianmin²

(1. School of Instrument and Electronics, North University of China, Taiyuan 030051, China;

2. Beijing Institute of Space Mechanics and Electricity, Beijing 100094, China)

Abstract: To address the problems of insufficient feature exploitation and inadequate information fusion in drone radio frequency fingerprint identification, this thesis proposed a multi-path parameter attention fusion network architecture. Using the DroneRF dataset as the research object, RF signals collected in the low-frequency and high-frequency bands were modeled separately, and the original signals were represented simultaneously as statistical features and spectrograms, thereby constructing four input paths: low-frequency statistical features,

收稿日期: 2025-11-18

基金项目: 国家自然科学基金(62075199)

作者简介: 左 顺(2001—), 男, 硕士, 主要从事信号处理和深度学习的研究。

* 通信作者: 张彦军(1975—), 男, 教授, 博士, 主要从事电子信息测试技术和深度学习应用的研究。E-mail: zhangyanjun@nuc.edu.cn。

low-frequency spectrograms, high-frequency statistical features, and high-frequency spectrograms. In the feature extraction stage, the TabNet-SA model was introduced to perform feature selection and deep representation learning for statistical features, while the EffNet-Slim model was adopted to extract discriminative features from spectrograms. In the multi-path feature fusion stage, a parameter attention fusion strategy was designed to perform adaptive weighting through learnable parameters, thereby enhancing the complementarity among features of different modalities and frequency bands and improving the overall feature representation capability. To verify the effectiveness of the proposed method, twelve groups of comparative experiments were conducted, including single-path, dual-path, average-fusion, different fusion-strategy, and backbone-replacement experiments. The classification results on the DroneRF dataset demonstrate average accuracies of 100.00%, 99.70%, and 99.54% in 2-class, 4-class, and 10-class tasks, respectively. This method provides a viable solution for UAV target identification in complex electromagnetic environments.

Key words: RF fingerprint identification; drone regulation; multi-path feature extraction; parameter attention fusion; deep learning

0 引 言

近年来,无人机技术的飞速发展使其在物流、农业巡检、灾害救援和军事作战等领域得到了广泛应用^[1]。然而,非法无人机活动(如低空入侵、隐私侵犯和公共安全威胁等)对空域安全构成严峻挑战,迫切需要有效的无人机监管手段^[2]。

当前的无人机检测与识别技术主要包括雷达、视觉、声学与射频等方法^[3]。其中,基于射频信号的识别技术因其对光照和天气变化具有天然鲁棒性,兼具隐蔽性好、成本低廉等优势,已成为当前研究热点^[4-5]。研究人员将射频信号的统计特征与机器学习相结合进行无人机检测。该方法具有结构简单、计算成本低和识别速度快等优势,但在复杂环境下其鲁棒性与分类精度仍存在局限性。为此,更多研究者提出将信号谱图表征与深度学习相结合以提升分类精度,但此类方法依赖计算密集的深度网络,难以在模型轻量化与高精度识别间取得平衡^[6]。

将统计特征与机器学习相结合的方法因其计算高效、实现简单而被应用于无人机射频指纹识别。Ezuma等^[7]使用k近邻算法提取并分类了能量瞬态特征。Alipour-Fanid等^[8]从加密Wi-Fi流量的数据包大小和到达间隔时间中提取特征,可以有效地检测无人机并识别其操作模式。Nie等^[9]提出一种基于Wi-Fi的无人机射频信号识别系统,提取分形维数、轴向积分双谱与平方积分双谱等特征进行分类。Kılıç等^[10]提取功率谱密度、梅尔频率倒谱系数和线性频率倒谱系数,并结合支持向量机进行分类。Li等^[11]将瞬时振幅与分形维数相结合。Jana等^[12]提出的

CommSense系统利用长期演进信号中的信道状态信息检测无人机,并通过主成分分析进行特征提取,采用支持向量机进行判别。刘冰等^[13]提出一种利用小波熵特征和优化神经网络的无人机飞控射频分类识别方法,提升了对无人机飞行状态的监控能力,为后续无人机自主避障、路径规划等提供了技术基础保障。尽管这些方法实现简单、计算高效,但其特征表征能力有限,难以捕捉无人机射频指纹中复杂的动态变化,导致分类性能欠佳且系统鲁棒性不足。

为了增强信号特征表征能力,信号谱图与深度学习的结合成为研究重点。Kumbasar等^[14]提出融合频谱、持续谱和百分位谱的混合模型,采用VGG19网络与支持向量机进行分类。Huynh-The等^[15]利用多级跳跃连接结构提升学习效率以实现高精度识别。部分研究聚焦轻量化设计,在提升分类精度的同时优化模型效率^[16-19]。Raina等^[20]提出面向特征丰富序列数据的ConvLGBM方法,在无人机模式分类任务中取得高精度。Zhang等^[21]提出一种低成本的数据增强方法和谱图分割方法,并通过深度学习增强复杂电磁环境下的鲁棒性。Mohammed等^[22]使用梅尔谱图与YAMNet模型相结合的方法,有效提高了无人机工作模式的识别准确率。Wang等^[23]提出基于最小方差无失真响应频谱特征与混合轻量深度学习(UAV-CTNet)的无人机射频感知方法。边芮琪等^[24]提出了一种基于时频图的无人机射频信号识别方法。该方法首先对信号进行预处理,将信号通过短时傅里叶变换(STFT)转换为时频图像,并使用添加了混合注意力机制模块的ResNet18_HAM模型进行特征提取,增强了模型在低信噪比环境中的特征提取能力和泛化能力。尽管谱图与深度学习相

结合的方法在分类精度方面表现优异,但仍存在模型复杂度高、参数量冗余与计算需求大的问题。

为克服上述局限性,本文提出多路径参数注意力融合网络(MPAFNet)模型,旨在实现高效、精准且鲁棒的分类。具体而言,首先从低频段和高频段采集的射频信号中提取统计特征和时频谱,构建4个独立的输入分支;随后,采用TabNet-SA模块与EffNet-Slim模块分别处理统计特征与时频谱;最后,

提出的参数注意力融合(PAF)策略通过可学习参数自适应调整各分支重要性权重,充分发挥多路径特征的互补优势,以实现精准分类。

1 多路径参数注意力融合网络

1.1 总体框架

本研究提出的MPAFNet整体框架如图1所示。




图1 MPAFNet总体框架图

Fig.1 Overall framework of MPAFNet

首先,从低频段采集的射频信号中提取11种统计特征,构建低频统计特征数据集,随后通过TabNet-SA模块处理得到概率分布;同时,采用时频分析方法生成对应时频谱图,利用EffNet-Slim模块提取深度图像特征,得到另一组概率分布。然后,对高频段采集的射频信号采用相同处理方法,再获得两组概率分布。最后,通过PAF模块自适应调整4个分支概率分布的权重并进行加权求和,生成最终的无人机类别预测结果。

1.2 特征数据集构建

1.2.1 统计特征提取

为准确捕捉无人机射频信号的内在特性,本文从低频段和高频段采集的射频信号中提取11种统计特征。这些特征的选择依据是其能够有效表

征射频指纹在能量分布、时频特性和调制结构上的差异。具体而言,本文对数据集中10种不同类别的无人机射频信号均采用表1所列的11种统计特征计算方法进行特征提取,并得到其取值分布。基于上述计算结果,进一步采用箱线图形式对特征分布情况进行可视化展示。

图2展示了6种代表性特征的箱线图对比结果。

从图2中可以看出,所选特征呈现出明显的中位数和分布范围差异。值得注意的是,类别0与类别9在大多数特征上都表现出显著差异,而类别1~8之间在某些特征上的区分度相对较弱。这是由于类别0对应背景信号,类别9对应Phantom无人机,二者均具有高度独特的信号特征;相比之下,类别1~4和5~8分别对应AR无人机与

表 1 各统计特征的计算公式

Tab. 1 Calculation formulas for each statistical feature

特征名称	公式
$F_1(x)$: 包络均值	$\frac{1}{N} \sum_{n=1}^N x[n] + j \cdot H\{x[n]\} $
$F_2(x)$: 三阶偏度	$\frac{\frac{1}{N} \sum_{n=1}^N (x[n] - \mu)^3}{\left(\frac{1}{N} \sum_{n=1}^N (x[n] - \mu)^2\right)^{3/2}}, \quad \mu = \frac{1}{N} \sum_{n=1}^N x[n]$
$F_3(x)$: 自相关峰值比	$\frac{\max_{1 \leq k \leq N/4} \left(\sum_{n=0}^{N-k-1} x[n] \cdot x[n+k] \right)}{\sum_{n=0}^{N-1} x[n]^2 + \epsilon}$
$F_4(x)$: 频率质心	$\frac{\sum_{k=1}^K f_k \cdot P(f_k)}{\sum_{k=1}^K P(f_k) + \epsilon}$
$F_5(x)$: 有效带宽	$\frac{f_s}{K} \cdot \sum_{k=1}^K 1 \left(P(f_k) > 0.05 \cdot \max_{1 \leq j \leq K} P(f_j) \right)$
$F_6(x)$: 四阶累积量	$\left(\frac{1}{N} \sum_{n=1}^N x[n]^4 \right) - 3 \left(\frac{1}{N} \sum_{n=1}^N x[n]^2 \right)^2$
$F_7(x)$: 谱熵	$-\sum_{k=1}^K \left(\frac{P(f_k)}{\sum_{j=1}^K P(f_j) + \epsilon} \right) \cdot \log_2 \left(\frac{P(f_k)}{\sum_{j=1}^K P(f_j) + \epsilon} \right)$
$F_8(x)$: 时频峰值	$\max_{n,k} Z[n,k] , \quad Z[n,k] = \text{STFT}(x[n])$
$F_9(x)$: 小波熵	$-\sum_{i=1}^L \sum_{j=1}^{N_i} \left(\frac{ c_{i,j} }{\sum_{k=1}^{N_i} c_{i,k} + \epsilon} \right) \cdot \log_2 \left(\frac{ c_{i,j} }{\sum_{k=1}^{N_i} c_{i,k} + \epsilon} \right)$
$F_{10}(x)$: 平均瞬时频率	$\frac{1}{N-1} \sum_{n=1}^{N-1} \left \frac{f_s}{2\pi} \cdot (\angle \tilde{x}[n+1] - \angle \tilde{x}[n]) \right , \quad \tilde{x}[n] = x[n] + j \cdot H\{x[n]\}$
$F_{11}(x)$: 时频稀疏度	$\frac{\sum_{n,k} Z[n,k] }{\sqrt{\sum_{n,k} Z[n,k] ^2 + \epsilon}}, \quad Z[n,k] = \text{STFT}(x[n])$




图 2 统计特征箱线图

Fig. 2 Boxplots of statistical features

Bebop 无人机的不同工作模式, 这些模式间信号特征相对接近, 导致类间差异不够显著。

表 1 列出了每个特征的计算公式。其中, $x[n]$ 为长度为 N 的输入, $H\{x[n]\}$ 为希尔伯特变换, ϵ 为小常数, f_s 为采样率, K 为频率分量的个数, $P(f_k)$ 为频率 f_k 处的功率谱密度, $Z[n, k]$ 为短时傅里叶变换系数, $1(\cdot)$ 为指示函数, $c_{i,j}$ 为小波系数, $\angle x$ 为瞬时相位。

1.2.2 谱图生成

对信号 $x[n]$ 生成时频表示, 即

$$X_s[m, k] = \sum_{n=0}^{N-1} x[n+mH] \omega[n] \exp\left(\frac{-j2\pi kn}{N}\right), \quad (1)$$

式中: $\omega[n]$ 为长度 $N=1024$ 的窗函数; H 为跳步大小, $H=512$; m 为时间帧索引; k 为频率索引。接着利用能量校准方法优化谱图质量, 具体公式为

$$X_{dB}[m, k] = 20 \log_{10} \left(\frac{|X_s[m, k]|}{A_{\max}} \right), \quad (2)$$

$$X'_{dB}[m, k] = \frac{X_{dB}[m, k] - X_{\min}^{dB}}{X_{\max}^{dB} - X_{\min}^{dB}}, \quad (3)$$

式中: $|X_s[m, k]|$ 为时频表示的幅值; $A_{\max}$ 为信号 $x[n]$ 的最大振幅; $X_{\max}^{dB}$ 和 $X_{\min}^{dB}$ 分别为信号 $x[n]$ 的

最大和最小 dB 值。 $X'_{dB}[m, k]$ 被用于绘制特征图。

如图 3 所示, 不同类别的射频信号呈现出不同的频谱模式, 为后续的特征提取和分类任务提供了有效的区分性信息。




图 3 谱图展示

Fig. 3 Spectrogram representations

1.3 分类模型

1.3.1 TabNet-SA

为了从统计特征中提取具有区分性的表示, 设计了 TabNet-SA, 这是一种基于经典的 TabNet 模型^[25]的变体, 其中融入了稀疏注意力机制 (SA)。如图 4 所示, 其架构保留了 TabNet 的多步骤递进框架, 通过特征转换器和动态注意力掩码机制逐步提取关键的区分性信息。




图 4 TabNet-SA 模型结构

Fig. 4 Structure of the TabNet-SA model

Lite Feature Transformer 模块进行非线性映射。与经典的 TabNet 相比只保留了一个线性层、批归一化和门控线性单元 (GLU), 从而产生了更紧凑的结构。计算公式为

$$LFT(x) = GLU(BN(W_f x + b_f)), \quad (4)$$

式中: W_f 和 b_f 为可学习参数; $BN(\cdot)$ 表示批量归一化, $GLU(\cdot)$ 表示门控线性单元激活函数。

Lite Attentive Transformer 模块动态生成特征

选择掩码,将当前特征状态与先验重要性信息相结合,逐步增强有效特征维度,同时抑制冗余信息。计算公式为

$$M = \text{Softmax}(\text{BN}(W_a h + b_a) \odot P), \quad (5)$$

式中: h 为隐含特征; P 为先验重要性; W_a 和 b_a 为可学习参数。

与经典的 TabNet 不同, TabNet-SA 取消参数共享,为每个步骤分配独立的特征转换和注意力模块。虽然略微增加了模型的参数量,但提高了每个步骤的灵活性和表征能力。

1.3.2 EffNet-Slim

为了从无人机射频指纹图谱特征中学习判别表示,本文提出了 EffNet-Slim,其总体架构如图 5 所示。该模型基于经典的 EfficientNet 模型^[26]构建,保留了其核心设计原则,同时调整了网络结构,体现在对模块组成和连接方式的简化,以更好地匹配射频信号频谱图的特征分布和计算要求。具体而言,与经典 EfficientNet 相比, EffNet-Slim 去掉了压缩激励模块和残差连接,并采用了更简洁的通道配置。




图 5 EffNet-Slim 模型结构

Fig. 5 Structure of the EffNet-Slim model

EffNet-Slim 采用轻量级卷积网络,融合深度可分离卷积、通道扩展与非线性激活,兼顾了模型的表达能力与计算效率。

输入时频图通过 3×3 卷积和批归一化进行初步特征提取,并结合 SiLU 激活函数引入非线性表达。然后堆叠多个 Mobile Inverted Bottleneck Convolution (MBConv) 模块,其中每个模块包括以下计算过程:

通道扩展和深度可分离卷积提取局部特征

$$x_a = \text{DConv}(\text{SiLU}(\text{BN}(\text{Conv}_{1 \times 1}(x)))). \quad (6)$$

逐点卷积整合通道信息

$$\text{MBConv}(x) = \text{BN}(\text{Conv}_{1 \times 1}(\text{SiLU}(\text{BN}(x_a)))), \quad (7)$$

$\text{Conv}_{1 \times 1}$ 为逐点卷积, DConv 为深度可分离卷积。最后通过 1×1 卷积与批归一化整合深层特征。并使用全局平均池化压缩空间特征,并通过

全连接层输出概率分布。

这样的结构减少了对特征的过度压缩,让中间特征能够更自由地学习,从而更适应时频谱图分类任务。

1.3.3 参数注意力融合策略

针对多路径特征融合过程中不同信息来源的重要性差异,本文提出一种可学习的参数注意力融合策略,以实现多路径判别信息的自适应动态融合。具体可表示为

$$p_{\text{fused}} = \sum_{i=1}^4 \alpha_i \cdot p_i, \quad (8)$$

式中: p_i 为 4 个路径的输出概率分布; α_i 为各路径对应的融合权重,满足

$$\alpha_i = \frac{\exp(\omega_i)}{\sum_{j=1}^4 \exp(\omega_j)}, \quad i = 1, 2, 3, 4, \quad (9)$$

式中: ω_i 为可学习参数。

与传统融合策略相比, PAF 策略可以充分整合多路信息, 动态调整每条路径的贡献。

2 实验设置

2.1 数据集和预处理

DroneRF^[27]数据集包含 454 个射频信号记录, 涵盖背景信号和三种不同类型无人机的信号

(AR、Bebop 和 Phantom)。其中 AR 和 Bebop 均包含 4 种工作模式(开机并连接、悬停、飞行、录像)。信号的采样频率为 40 MHz, 每个数据段持续 0.25 s, 包含 10 000 000 个采样点。数据集被划分为两个频段: 低频段(2 400~2 440 MHz)和高频段(2 440~2 480 MHz), 每个频段包含 227 个记录, 总计 454 个记录。图 6 展示了背景信号和 3 种类型无人机样本的时域波形。




图 6 时域波形

Fig. 6 Time-domain waveforms

对于每段数据, 采用窗长为 1 000 000 点、滑动步长为 250 000 点的滑动分帧策略, 将信号划分为更小的数据帧。每帧数据经特征数据集构建, 分别获得 11 维统计特征和对应的谱图特征, 从而

得到四路特征数据集。该过程共生成 8 399 个数据帧。将其中 15% 作为测试集, 其余 85% 采用十折交叉验证进行训练与验证。具体分布如表 2 所示。

表 2 DroneRF 数据集和 4 路特征分布

Tab. 2 Distribution of records and four-path features in the DroneRF dataset

二分类	四分类	十分类	数据记录		4 路特征数据集记录			
			低频	高频	低频特征	低频谱图	高频特征	高频谱图
无人机	AR 无人机	AR 模式 1	21	21	777	777	777	777
		AR 模式 2	21	21	777	777	777	777
		AR 模式 3	21	21	777	777	777	777
		AR 模式 4	18	18	666	666	666	666
	Bebop 无人机	Bebop 模式 1	21	21	777	777	777	777
		Bebop 模式 2	21	21	777	777	777	777
		Bebop 模式 3	21	21	777	777	777	777
		Bebop 模式 4	21	21	777	777	777	777
	Phantom 无人机		Phantom 模式 1	21	21	777	777	777
非无人机	非无人机	非无人机	41	41	1 517	1 517	1 517	1 517
			227	227	8 399	8 399	8 399	8 399

2.2 训练配置

为确保实验的公平性与可重复性, 本文所有

模型的训练与评估过程均在统一配置下进行。针对任务差异, 十分类任务均未启用早停机制, 以缓解欠拟合风险; 而在二分类与四分类任务中,

为抑制过拟合，均引入早停策略。所有实验均基于验证集表现保存最优模型参数。具体参数配置如表 3 所示。

表 3 实验参数配置
Tab. 3 Experimental parameter configuration

配置项	配置选择
谱图大小	128×128×3
归一化方法	z-score
优化器	Adam
学习率	0.001
权重衰减	1×10 ⁻⁵
批次大小	32
训练轮次	50
随机种子	固定 42

为了评估模型的泛化性能，本文采用十折交叉验证与独立测试集的混合策略。首先，将数据集固定划分为 15% 的测试集和 85% 的训练-验证

集。然后，将训练-验证部分进行十折交叉验证。这种策略最大限度利用数据资源，降低过拟合风险。同时，独立的测试集模拟了实际部署情况，提供无偏的性能评估，与标准的十折交叉验证相比，其更能与实际应用相契合。

3 实验结果和对比

3.1 MPAFNet 分类性能

本节对所提出的 MPAFNet 模型在二分类、四分类和十分类任务中的分类性能进行了系统评估。所有实验均采用十折交叉验证与独立测试集双重验证策略。为避免训练过程展示冗余，本文选取每个任务中测试集表现最优的一折作为代表进行展示，全部十折详细分类性能见表 4。

表 4 MPAFNet 模型在二类、四类、十类任务中的十折详细分类性能
Tab. 4 Detailed 10-fold classification performance of MPAFNet on 2-class, 4-class, and 10-class tasks

Fold	Accuracy/%			F1 Score/%		
	二分类	四分类	十分类	二分类	四分类	十分类
1	100.00	99.52	99.60	100.00	99.56	99.57
2	100.00	99.76	99.60	100.00	99.84	99.57
3	100.00	99.92	99.21	100.00	99.95	99.14
4	100.00	99.37	99.76	100.00	99.56	99.74
5	100.00	99.44	99.68	100.00	99.54	99.66
6	100.00	99.84	99.60	100.00	99.89	99.57
7	100.00	100.00	99.44	100.00	100.00	99.39
8	100.00	99.37	99.68	100.00	99.56	99.66
9	100.00	100.00	99.44	100.00	100.00	99.40
10	100.00	99.76	99.37	100.00	99.75	99.31
Mean±Std	100.00±0.00	99.70±0.24	99.54±0.16	100.00±0.00	99.77±0.18	99.50±0.18

图 7 展示了 MPAFNet 在 3 个分类任务中训练损失曲线。可以观察到，模型在所有任务中均表现

出良好的收敛性，损失值随训练轮次整体呈下降趋势，模型训练过程稳定，且具有良好的收敛性。




图 7 训练 loss 曲线

Fig. 7 Training loss curves

图 8 展示了训练过程中的准确率曲线。可以看出，模型在各分类任务中训练准确率整体稳步上升，在训练后期趋于收敛。并且未表现出明显的过拟合或不稳定现象，说明其在复杂任务下同样具备较强的拟合能力与鲁棒性。

图 9 展示了 3 个任务下测试集的混淆矩阵。可以明显看出，在各分类任务中，MPAFNet 均表现出较强的类别区分能力，尤其在二分类和四分类任务中，模型几乎达到完全区分。在十分类任务中，尽管类别数量增多，模型依然保持了较高

的识别准确率。




图8 训练accuracy曲线
Fig. 8 Training accuracy curves




图9 测试混淆矩阵
Fig. 9 Testing confusion matrices

表4汇总了MPAFNet模型在3个任务中所有十折的测试集分类准确率(Accuracy)与 $F1$ 值。可以看出,所提出的模型在各任务中均取得了较高且稳定的分类性能,尤其在十分类这一更具挑战性的任务中,模型也能展现出良好的泛化能力和稳定性。

3.2 消融实验

为深入分析各特征通路、网络结构及融合策略对模型性能的影响,本文设计了12组消融与对比实验,涵盖单路径、双路径及四路径不同配置

结果显示,单一路径模型在各任务中的分类性能整体较低,尤其在四分类和十分类任务下,难以充分提取无人机射频信号的特征。相比之下,双路径模型在性能上有显著提升,表明低频与高频、统计特征与谱图之间均存在互补关系。

图11展示了不同融合框架在各任务中测试结果表明,经典TabNet与EfficientNet由于网络结构复杂,限制了模型在本任务中的实际表现。相比之下,本文提出的TabNet-SA与EffNet-Slim结构更为简洁,且具有针对性设计,能够在

等。为便于表格展示,对各对比方法命名采用如下缩写方式:其中,LF表示低频特征,HF表示高频特征,TSA表示TabNet-SA架构,ESlim表示EffNet-Slim架构。TClassic为经典TabNet,ETClassic为经典EfficientNet,AvgF表示普通平均融合,PAF表示参数注意力融合。

表4汇总了8个不同路径组合在各任务中测试集的十折平均准确率与 $F1$ 值。图10展示了8个不同路径组合在各任务中测试集的所有十折的准确率对比折线。

所提出的MPAFNet在所有任务中均取得最优表现,进一步验证了4路特征融合机制在特征表达与分类能力方面的优势。表5给出了4路特征完整融合框架下,不同网络结构与融合策略的对比实验。

集的所有十折的准确率对比折线。

保持表达能力的同时有效简化网络结构。在进一步引入参数注意力融合策略后,MPAFNet在各类任务中均取得最优性能。上述12组消融与对比实验验证了所提出的关键结构在提升无人机射频指




图 10 不同路径组合的所有十折准确率比较
Fig. 10 Comparison of test accuracy across all 10 folds for different path combinations
表 5 不同路径组合的分类性能比较

Tab. 5 Comparison of classification performance under different path combinations

模型	Accuracy/%			F1 Score/%		
	二分类	四分类	十分类	二分类	四分类	十分类
LF-TSA	99.71	93.06	90.21	99.50	93.69	89.29
HF-TSA	93.41	80.42	79.21	88.05	83.53	77.91
LF-ESlim	99.96	96.30	94.33	99.93	96.81	93.73
HF-ESlim	99.91	92.64	94.09	99.85	94.39	93.63
LFHF-TSA	99.83	96.67	97.87	99.70	97.40	97.70
LFHF-ESlim	100.00	98.34	98.48	100.00	98.68	98.35
LF-TSA+ESlim	99.93	99.51	98.01	99.88	99.53	97.82
HF-TSA+ESlim	99.92	98.58	98.29	99.87	98.98	98.16
MPAFNet	100.00	99.70	99.54	100.00	99.77	99.50




图 11 不同融合框架的所有十折准确率比较

Fig. 11 Comparison of test accuracy across all 10 folds for different network architectures

纹识别性能方面的有效性与必要性。

3.3 与现有方法的对比

本文选取了多种在 DroneRF 数据集上开展无

从表 7 可以看出, 所提出的 MPAFNet 在各任务中的表现均优于现有方法, 特别是在十分类

4 结 论

本研究介绍了一种用于无人机射频指纹识别的 MPAFNet。该模型通过 TabNet-SA 和 EffNet-Slim

人机射频指纹识别的代表性方法作为对比对象。

表 6 给出了不同方法在各分类任务下的分类准确率与 F1 值对比结果。

任务中展现出显著的性能优势, 进一步验证了该方法的有效性。

架构, 在保持计算效率的同时增强特征表达。并采用 PAF 策略来实现多路径信息的动态融合。为全面评估所提出的方法, 本文进行了大量对比消融实验。结果表明, MPAFNet 在准确率和 F1 得分方面都取

表 6 不同网络结构与融合策略的分类性能比较

Tab. 6 Comparison of classification performance under different network architectures and fusion strategies

模型	Accuracy/%			F1 Score/%		
	二分类	四分类	十分类	二分类	四分类	十分类
TSA+ESlim-AvgF	99.99	99.74	99.34	99.99	99.80	99.29
TSA+EClassic-PAF	99.97	99.63	99.41	99.97	99.69	99.36
TClassic+ESlim-PAF	100.00	98.35	96.37	100.00	98.73	95.99
TClassic+EClassic-PAF	99.99	97.39	88.66	99.99	97.97	87.54
MPAFNet	100.00	99.70	99.54	100.00	99.77	99.50

表 7 不同方法在各分类任务中的分类性能对比

Tab. 7 The classification performance of the selected existing methods in different classification tasks

模型	Accuracy/%			F1 Score/%		
	二分类	四分类	十分类	二分类	四分类	十分类
LFCC ^[10]	100.00	98.67	95.15	100.00	98.70	94.72
HMFFNet ^[14]	100.00	99.55	97.75	100.00	99.69	97.57
RF-UAVNet ^[15]	99.85	98.55	95.33	99.75	98.48	95.06
ConvLGBM ^[20]	99.95	95.50	85.10	99.9	96.7	82.8
DNN ^[28]	99.70	84.50	46.80	99.50	78.80	43.00
MPAFNet	100.00	99.70	99.54	100.00	99.77	99.50

得了优异的性能,并且在具有挑战性的十类分类任务中取得了显著优势。结果充分验证了所提出的网络架构和融合策略的有效性。综上,本文所提出的MPAFNet在提高无人机射频指纹识别的准确性和鲁棒性方面显示出巨大的潜力。未来的研究将探索更通用的特征提取与融合策略,并引入自监督与开放集识别机制,以提升模型在复杂环境下的泛化能力和对未知无人机的识别能力。

利益冲突声明/Conflict of Interests

所有作者声明不存在利益冲突。

All authors declare no relevant conflict of interests.

参考文献:

- [1] AL-LQUBAYDHI N, ALENEZI A, ALANAZI T, et al. Deep learning for unmanned aerial vehicles detection: A review[J]. Computer Science Review, 2024, 51: 100614.
- [2] BISIO I, GARIBOTTO C, HALEEM H, et al. RF/WiFi-based UAV surveillance systems: A systematic literature review[J]. Internet of Things, 2024, 26: 101201.
- [3] 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.
- [4] XIE Y L, JIANG P, GU Y, et al. Dual-source detection and identification system based on UAV radio frequency signal[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 2006215.

- [5] 王豪, 罗俊松, 王惠明, 等. 无人机射频指纹识别方法综述[J]. 无线电工程, 2024, 54(11): 2672-2684.
WANG Hao, LUO Junsong, WANG Huiming, et al. A survey of UAV radio frequency fingerprint recognition methods[J]. Radio Engineering, 2024, 54(11): 2672-2684. (in Chinese)
- [6] XU L, LUO Z Q. Anti-UAV detection and identification technology: Fundamentals, methods and challenges [J]. Physical Communication, 2025, 71: 102676.
- [7] EZUMA M, ERDEN F, ANJINAPPA C K, et al. Detection and classification of UAVs using RF fingerprints in the presence of Wi-Fi and Bluetooth interference[J]. IEEE Open Journal of the Communications Society, 2020, 1: 60-76.
- [8] ALIPOUR-FANID A, DABAGHCHIAN M, WANG N, et al. Machine learning-based delay-aware UAV detection and operation mode identification over encrypted Wi-Fi traffic[J]. IEEE Transactions on Information Forensics and Security, 2020, 15: 2346-2360.
- [9] NIE W, HAN Z C, ZHOU M, et al. UAV detection and identification based on WiFi signal and RF fingerprint[J]. IEEE Sensors Journal, 2021, 21(12): 13540-13550.
- [10] KILİÇ R, KUMBASAR N, ORAL E A, et al. Drone classification using RF signal based spectral features [J]. Engineering Science and Technology, an International Journal, 2022, 28: 101028.
- [11] LI Q L, WANG F S, ZHANG Y B, et al. Novel micro-UAV identification approach assisted by combined RF fingerprint [J]. IEEE Sensors Journal, 2024, 24(16): 26802-26813.
- [12] JANA S, MISHRA A K, ALI KHAN M Z. Opportu-

- nistic drone detection using comm sense [J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 5501715.
- [13] 刘冰, 时明心, 刘佳琪. 基于小波熵特征的无人机射频信号识别算法研究[J]. 电子与信息学报, 2025, 47(8): 2736-2745.
LIU Bing, SHI Mingxin, LIU Jiaqi. Research on unmanned aircraft radio frequency signal recognition algorithm based on wavelet entropy features[J]. Journal of Electronics & Information Technology, 2025, 47(8): 2736-2745. (in Chinese)
- [14] KUMBASAR N, KILİÇ R, ORAL E A, et al. Comparison of spectrogram, persistence spectrum and percentile spectrum based image representation performances in drone detection and classification using novel HMFFNet: Hybrid Model with Feature Fusion Network [J]. Expert Systems with Applications, 2022, 206: 117654.
- [15] HUYNH-THE T, PHAM Q V, NGUYEN T V, et al. RF-UAVNet: High-performance convolutional network for RF-based drone surveillance systems[J]. IEEE Access, 2022, 10: 49696-49707.
- [16] BASAK S, RAJENDRAN S, POLLIN S, et al. Combined RF-based drone detection and classification [J]. IEEE Transactions on Cognitive Communications and Networking, 2022, 8(1): 111-120.
- [17] BREMNES K, MOEN R, YEDURI S R, et al. Classification of UAVs utilizing fixed boundary empirical wavelet sub-bands of RF fingerprints and deep convolutional neural network [J]. IEEE Sensors Journal, 2022, 22(21): 21248-21256.
- [18] CAI Z X, WANG Y, JIANG Q, et al. Toward intelligent lightweight and efficient UAV identification with RF fingerprinting [J]. IEEE Internet of Things Journal, 2024, 11(15): 26329-26339.
- [19] AKTER R, DOAN V S, ZAINUDIN A, et al. Sparsely connected low complexity cnn for unmanned vehicles detection-sensing RF signal[J]. IEEE Transactions on Vehicular Technology, 2024, 73(10): 14236-14251.
- [20] RAINA K, ALLADI T, CHAMOLA V, et al. Detecting UAV presence using convolution feature vectors in light gradient boosting machine [J]. IEEE Transactions on Vehicular Technology, 2023, 72(4): 4332-4341.
- [21] ZHANG H S, LI T, LI Y Z, et al. RF-based drone classification under complex electromagnetic environments using deep learning[J]. IEEE Sensors Journal, 2023, 23(6): 6099-6108.
- [22] MOHAMMED K K, EL-LATIF E I A, EL-SAYAD N E, et al. Radio frequency fingerprint-based drone identification and classification using Mel spectrograms and pre-trained YAMNet neural [J]. Internet of Things, 2023, 23: 100879.
- [23] WANG Q, YANG P F, YAN X, et al. Radio frequency-based UAV sensing using novel hybrid lightweight learning network [J]. IEEE Sensors Journal, 2024, 24(4): 4841-4850.
- [24] 边芮琪, 高振斌, 晏行伟, 等. 基于改进残差神经网络的无人机射频信号识别[J]. 电光与控制, 2025, 32(6): 86-93.
BIAN Ruiqi, GAO Zhenbin, YAN Xingwei, et al. Identification of UAV RF signals based on improved residual neural network[J]. Electronics Optics & Control, 2025, 32(6): 86-93. (in Chinese)
- [25] ARIK S Ö, PFISTER T. Tabnet: Attentive interpretable tabular learning [J]. Proceedings of the AAAI conference on artificial intelligence, 2021, 35(8): 6679-6687.
- [26] TAN M X, LE Q V. Efficientnet: Rethinking model scaling for convolutional neural networks[C]//International conference on machine learning (PMLR), 2019: 6105-6114.
- [27] ALLAHHAM M S, AL-SA'D M F, AL-ALI A, et al. DroneRF dataset: A dataset of drones for RF-based detection, classification and identification [J]. Data in Brief, 2019, 26: 104313.
- [28] AL-SA'D M F, AL-ALI A, MOHAMED A, et al. RF-based drone detection and identification using deep learning approaches: An initiative towards a large open source drone database [J]. Future Generation Computer Systems, 2019, 100: 86-97.