

基于瞬态包络调制谱图的轻量级无人机射频身份识别方法

阿依努尔·努尔太^{1,2}, 张品昌^{3,4}, 董建阔⁵, 沈元章¹, 樊卫北¹, 肖甫¹

(1.南京邮电大学计算机学院、软件学院、网络空间安全学院, 江苏 南京 210023; 2.新疆警察学院信息安全与工程系, 新疆 乌鲁木齐 830011; 3.塔里木大学网络安全学院, 新疆 阿拉尔 843399; 4.数字空间安全兵团重点实验室, 新疆 阿拉尔 843399; 5.中国科学技术大学网络空间安全学院, 安徽 合肥 230026)

摘要: 面向低空无人机非合作监管中身份识别的准确性、实时性与边缘推理效率需求, 提出基于瞬态包络调制谱图 (Transient Envelope Modulation Spectrogram Image, TEMSI) 的轻量级射频身份识别方法。针对完整射频信号中稳态载荷、环境噪声与信道扰动对硬件瞬态特征的掩盖问题, 采用二阶 Haar 小波完成信号去噪, 并结合短时傅里叶变换、能量轨迹分析与样本级全局自适应阈值检测, 实现瞬态片段自适应定位; 进一步利用 Welch 谱估计提取瞬态能量包络的调制谱, 构建二维 TEMSI 表征, 增强不同型号及工作状态下的可分性。随后结合迁移学习与分层微调, 采用轻量级卷积网络实现十类无人机“型号—状态”射频身份识别。基于 DroneRF 数据集实验结果表明, EfficientNet-B0 识别准确率与 F1 分数均达 99.99%, SqueezeNet 在通用 CPU 环境下单样本推理时间为 10.34 ms。实验结果表明, 所提方法能够在保持较高识别精度的同时有效降低推理开销, 为无人机射频身份识别的边缘侧部署提供参考。

关键词: 无人机; 身份识别; 射频指纹; 射频瞬态; 瞬态包络调制谱图; 轻量级网络

中图分类号: TP309

文献标志码: A

A Lightweight UAV RF Identification Method Based on Transient Envelope Modulation Spectrogram Images

AYINUER Nuertai^{1,2}, ZHANG Pinchang^{3,4}, DONG Jiankuo⁵, SHEN Yuanzhang¹, FAN Weibei¹, XIAO Fu¹

1. School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

2. Department of Information Security Engineering, Xinjiang Police College, Wulumuqi 830011, China

3. College of Cyber Security, Tarim University, Alaer 843399, China

4. XPCC Key Laboratory of Digital Space Security, Alaer 843399, China

5. School of Cyber Science and Technology, University of Science and Technology of China, Hefei 230026, China

Abstract: In response to the requirements of accuracy, real-time performance, and edge inference efficiency for identity recognition in non-cooperative low-altitude UAV surveillance, this paper proposes a lightweight RF identity recognition

收稿日期: XXXX-XX-XX; 修回日期: XXXX-XX-XX

通信作者: 张品昌, zpcap0505238@163.com

基金项目: 国家杰出青年科学基金 (No. 62125203); 国家重大科研仪器研制项目 (No. 62427809); 江苏省基础研究计划项目 (No. BK20251877); 新疆领军人才引进计划项目 (No. XJRC-2025-BTJY-YJ-GX-QNQZ-005); 胡杨英才-引进人才科研启动金 (博士) 项目 (No. TDZKBS202684); 自治区自然科学基金项目 (No. 2026D01A62); 新疆警察学院科技创新团队 (No. XJKYKJTD202402); 新疆警察学院科技应用创新研究项目一般项目 (No. 2026JYYYCXBY01)

Foundation Items: The National Science Fund for Distinguished Young Scholars (No. 62125203), The National Major Scientific Research Instrument Development Project (No. 62427809), The Jiangsu Provincial Basic Research Program (No. BK20251877), The Xinjiang Leading Talent Introduction Program (No. XJRC-2025-BTJY-YJ-GX-QNQZ-005), The “Huyang Talent” Introduced Talent Research Start-up Fund (Doctoral) Project, Xinjiang Autonomous Region Natural Science Foundation (No. 2026D01A62), Science and Technology Innovation Team Project of Xinjiang Police College (No. XJKYKJTD202402), General Project of Science and Technology Application Innovation Research Project of Xinjiang Police College (No. 2026JYYYCXBY01)

method based on Transient Envelope Modulation Spectrogram Images (TEMSI). To address the problem that steady-state payload components, environmental noise, and channel impairments in the complete RF signal obscure hardware transient features, a second-order Haar wavelet is employed for signal denoising. In addition, transient segments are adaptively localized by combining short-time Fourier transform (STFT), energy-trajectory analysis, and sample-level global adaptive threshold detection. Furthermore, a modulation spectrum is extracted from the transient energy envelope using Welch spectral estimation, and a two-dimensional TEMSI representation is constructed to improve discriminability across different UAV models and operating states. Then, by leveraging transfer learning and hierarchical fine-tuning, a lightweight convolutional network is used to accomplish “model–state” RF identity recognition for ten classes of UAVs. Experimental results on the DroneRF dataset show that EfficientNet-B0 achieves both 99.99% recognition accuracy and F1 score, while SqueezeNet requires 10.34 ms for single-sample inference in a general CPU environment. The results indicate that the proposed method maintains high recognition accuracy while effectively reducing inference overhead, providing a reference for edge-side deployment of RF-based UAV identity recognition.

Key words: unmanned aerial vehicle, device identification, radio-frequency fingerprinting, RF transient, transient envelope modulation spectrogram image, lightweight neural network

0 引言

无人机 (Unmanned Aerial Vehicle, UAV) 在物流配送、应急救援、公共安全、基础设施巡检和低空经济等场景中得到广泛应用, 但非法入侵、隐私侵犯、干扰民航运行和越界飞行等问题也随之增加^[1-3]。在非合作监管场景下, 监管系统不仅需要发现无人机目标, 还需要进一步判别其型号及工作状态, 从而为低空空域管控、风险溯源和反制决策提供依据。因此, 面向无人机的快速、准确和可部署身份识别方法已成为低空安全监管中的重要研究问题。

现有无人机探测与识别技术主要包括视觉、声学、雷达和射频 (Radio Frequency, RF) 等。视觉方法易受光照、遮挡和复杂背景影响。声学方法探测距离有限, 且在城市噪声环境中鲁棒性不足。雷达方法具备一定远距离探测能力, 但设备成本较高, 且微小无人机与鸟类等弱小目标之间容易混淆^[4]。相比之下, 基于射频信号的识别方法可通过被动截获无人机与地面控制站之间的通信信号实现非接触式感知, 具有非视距、全天候和无需主动照射等优势^[5-6]。射频指纹 (Radio Frequency Fingerprinting, RFF) 利用射频前端硬件制造误差和电路非理想性所形成的个体差异作为身份标识, 具有难以完全伪造和无需解码协议内容等特点, 因而成为无人机身份识别和物理层安全认证领域的重要研究方向^[7-8]。根据识别标签的粒度, 无人机射频识别可分为型号识别、状态识别和个体级身份识别。型号识别用于区分不同产品型号, 状态识别用于区分

无人机在不同运行或通信状态下的射频活动。严格意义上的射频指纹身份识别则通常指同型号不同物理设备之间的个体辨识。本文使用的 DroneRF 十类标签同时包含无人机型号、工作状态及无无人机背景, 属于无人机型号-状态组合类别的射频身份识别, 不等同于个体级身份识别。

近年来, 基于射频指纹的无人机识别方法已由人工特征提取逐步发展到深度特征学习, 识别精度不断提高^[8] (见相关工作)。然而, 在低空边缘监测场景中, 现有方法仍面临三方面限制。首先, 直接利用完整通信片段或全局时频图进行识别, 长时信号中的稳态协议载荷、信道扰动和背景噪声占比较高, 容易掩盖射频前端启动阶段的微弱瞬态硬件差异。其次, 已有瞬态特征提取方法多依赖固定窗口或经验阈值, 难以适应不同射频样本之间的信号强度、噪声水平及瞬态位置差异。最后, 高精度深度模型通常依赖较大参数规模或复杂网络结构, 推理时延和计算开销较高, 难以满足资源受限边缘节点的低时延推理需求。

针对上述问题, 本文从射频前端启动瞬态响应机理出发, 提出一种“瞬态片段自适应提取—瞬态包络调制谱图表征—轻量级迁移识别”协同建模方法。该方法并非仅依赖更换分类网络提升性能, 而是在前端特征表征层面优先剥离稳态通信载荷和环境噪声对硬件瞬态指纹的干扰, 再通过轻量级深度网络完成判别建模, 从而兼顾识别性能和边缘侧推理阶段的计算效率。主要工作如下。

(1) 针对长时射频信号中瞬态硬件特征易被稳态通信载荷和环境噪声淹没的问题, 提出一种基于

二阶 Haar 小波降噪、时频能量轨迹和样本级全局自适应阈值检测的瞬态片段自适应提取方法,实现射频瞬态区域的自动定位。

(2) 针对传统时频图难以突出射频前端启动阶段低频能量波动的问题,构建瞬态包络调制谱图 TEMSI。该表征利用 Welch 谱估计刻画瞬态能量包络的调制特征,将一维硬件瞬态响应映射为二维图像表示,以增强不同无人机硬件差异的可学习性。

(3) 针对无人机射频身份识别在资源受限边缘侧中面临的精度与复杂度折中问题,设计轻量级迁移识别框架,并在 DroneRF 十类无人机射频身份识别任务上系统评估准确率、F1 分数、AUC 和 CPU 推理时延,验证所提 TEMSI 特征表征与轻量模型协同设计的有效性。

1 相关工作

1.1 射频信号表征与瞬态特征提取

射频信号表征方式直接影响指纹信息的利用效率。现有方法大致可分为稳态信号表征和瞬态信号表征两类。稳态表征方法通常利用完整通信帧、长时序列或全局时频图提取设备特征。Fu 等人^[9]将频域 Gramian Angular Field 图像与 CNN 结合用于无人机分类。Swinney 等人^[10]采用深度残差网络提取不同工作模式下的稳态特征。Mandal 等人^[11]提出时频多尺度 CNN 以融合时域与频域信息。这类方法实现相对直接,但完整信号中包含大量协议结构、信道扰动和环境噪声,容易削弱硬件瞬态差异的判别作用^[12-13]。与稳态信号不同,设备开机或状态切换阶段的瞬态响应更能反映射频前端的动态行为和硬件差异^[7,14]。Baldini 与 Gentile^[14]表明,基于瞬态信号的时频表征在低信噪比和衰落信道下具有较好的识别能力。然而,现有瞬态提取方法多依赖固定阈值、人工检测窗口或先验触发条件,自适应能力不足。因此,如何从长时射频片段中稳定定位高判别性瞬态区域,仍是无人机射频指纹识别中的关键问题。

1.2 射频指纹特征构建方法

射频指纹特征构建方法主要包括人工特征提取和深度特征学习两类。人工特征方法通过领域知识设计统计量、谱特征或瞬态参数。Ezuma 等人^[15]从无人机控制链路中提取偏度、方差和熵等统计特征并结合 SVM 分类。He 等人^[16]提出矩统计特征提

取器,通过频谱商序列构建设备指纹。He 与 Wang^[17]从模型驱动角度提出基于稀疏贝叶斯学习的指纹提取方法。人工特征通常具有较明确的物理意义,但依赖专家经验,且难以刻画射频瞬态响应中的复杂非线性结构。深度学习通过端到端训练自动学习判别特征,能够提升复杂场景下的分类性能。Yang 等人^[18]采用复值 CNN 保留相位信息以增强噪声鲁棒性。Tanveer 等人^[19]结合集成学习与传感融合策略提升检测性能。Zhao 等人^[20]构建 UAVSig 数据集并研究无人机个体识别问题。此外,已有研究从数据采集粒度出发分析了不同数据表示对特征信息维度及后续检测性能的影响^[21]。深度特征学习虽然表达能力较强,但也可能学习到与设备身份无关的信道或协议冗余,且对数据规模和训练条件较为敏感。因此,仍需构建一种兼具物理解释性和深度模型可学习性的中间表征,以稳定突出射频硬件差异。

1.3 轻量化识别与边缘侧推理效率

识别模型设计关系到识别精度与部署效率。高精度方法通常采用深层网络、多模型集成或 Transformer 结构。Shang 等人^[22]提出深度集成学习框架,融合 CNN、MLP 与 Transformer 等异构网络。Deng 等人^[23]将 Transformer 引入特定辐射源识别任务,以捕获信号长程依赖。这类方法具有较强的特征建模能力,但参数量和计算量较大,难以在资源受限边缘侧满足计算与实时性约束。为降低部署成本,研究者进一步探索轻量化模型。Huynh 等人^[24]提出 RF-UAVNet,通过分组卷积和跳跃连接控制参数规模。Zhou 等人^[25]设计轻量高效的混合网络结构以兼顾性能和效率。Deng 等人^[23]进一步通过门控局部注意力降低 Transformer 计算复杂度。面向资源受限终端,已有研究通过轻量化 Swin Transformer 与资源自适应压缩机制,实现了对终端算力和链路带宽约束的适配^[26]。然而,现有轻量化研究多聚焦于网络结构压缩,对前端信号表征中的冗余抑制关注不足。对于无人机射频身份识别而言,轻量化不应仅依赖模型压缩,还应通过瞬态特征提取与输入表征优化减少无关信息输入,从而实现识别精度与边缘侧推理效率的协同提升。

综上所述,现有研究虽然推动了无人机射频识别性能提升,但仍存在以下不足:(1) 长时稳态信号中的协议载荷、信道扰动和环境噪声容易稀释硬

件瞬态指纹；(2) 现有瞬态提取方法对不同样本之间的信号强度、噪声水平和瞬态位置差异适应能力不足；(3) 轻量化识别多集中在网络结构层面，缺少与前端瞬态表征的协同设计。本文围绕上述问题，构建 TEMSI 表征与轻量级迁移识别框架，可以提升无人机射频身份识别的判别性、并降低网络推理阶段的计算开销，从而为边缘端实现提供计算效率基础。

2 系统模型与问题阐述

2.1 网络场景

本文考虑一个典型的低空无人机非合作监管场景，由无人机节点、无线信道以及地面监测节点组成。如图1所示，监测区域内存在多个合法无人机以及未经授权的未知无人机目标。无人机在执行通信、巡检或任务飞行过程中，会持续向地面控制端发送无线射频信号。由于无人机射频前端中的功率放大器、晶振、频率合成器、滤波器以及射频链路器件存在不可避免的制造偏差和电路非理想性，不同无人机在信号启动和传输过程中会产生具有设备特异性的射频响应特征，即射频指纹 (Radio Frequency Fingerprint, RFF)。地面监测节点采用被动监听方式获取空域内无人机辐射信号，并根据接收信号中的设备相关特征完成无人机型号及其工作状态所对应的无人机身份判别。相比依赖协议字段或人工身份标识的传统身份识别方式，本文关注从基于射频指纹的身份识别无需解析通信内容，可在非合作条件下实现无人机目标的身份确认。

在实际监测环境中，接收机截获的离散基带信号可表示为：

$$r[n] = h[n] * s[n] + v[n], \quad (1)$$

其中， $n = 1, 2, \dots, L$ ， $s[n]$ 表示无人机发射端输出的原始离散基带信号，其波形由通信协议、调制方式和射频前端硬件非理想特性共同决定。 $h[n]$ 表示无人机与监测接收机之间的离散信道冲激响应，包含路径损耗、多径衰落和多普勒扰动。 $v[n]$ 表示环境噪声及其它非目标干扰。“*”表示离散卷积运算。本文后续信号处理流程均基于离散采样序列展开，因此统一采用 n 作为时间索引。

由于信道和环境因素会导致接收信号产生随机变化，而射频前端硬件差异具有相对稳定性，本文关注从接收信号中分离并提取与无人机型号、工作




图1 系统模型

状态及射频前端动态响应相关的瞬态特征。特别地，无人机射频启动阶段经历由关闭状态到稳定工作状态的动态过渡过程，其中包含功率放大器非线性响应、锁相环频率收敛以及瞬态幅相扰动等硬件特有行为。因此，瞬态射频响应可为无人机型号与工作状态相关的射频身份识别提供特征依据。

本文研究目标是在非合作低空环境下，根据地面监测节点截获的无人机射频信号，实现未知无人机身份识别。设无人机射频活动类别集合为 $C = \{1, 2, \dots, K\}$ ，其中 K 为类别数。给定训练样本集 $D = \{(r_i, c_i)\}$ ，其中 r_i 为第 i 个接收信号样本， $c_i \in C$ 为其真实类别标签。无人机射频指纹识别可形式化为学习一个映射函数 $f_\theta(\cdot)$ (θ 为模型参数)，使其根据接收信号输出预测类别：

$$\hat{c}_i = f_\theta(r_i) \quad (2)$$

其中， $\hat{c}_i \in C$ 为第 i 个样本的预测类别。本文的优化目标是在提高分类准确率和 F1 分数的同时，降低 CPU 侧单样本推理时延，从而满足边缘监测场景的低时延推理需求。然而，在实际低空监管环境中，身份识别面临以下挑战：(1) 弱身份特征与强环境干扰耦合问题。无人机长时间通信信号中包含大量协议载荷、环境噪声和信道扰动，而真正反映设备差异的瞬态硬件响应持续时间短、能量弱，容易被非身份相关信息淹没。(2) 动态电磁环境下身份特征稳定表征问题。无人机运动、传播衰落以及背景电磁变化会导致接收信号发生动态变化，需要提取对环境扰动具有鲁棒性的设备本征特征。(3) 边缘部署下识别性能与计算复杂度平衡问题。低空监管节点通常计算资源有限，需要在保证识别准确率的同时降低模型计算开销和推理时延。因此，本

文的目标是在复杂低空环境中,构建一种基于射频瞬态指纹的轻量级无人机身份识别方法,通过提取设备相关瞬态响应特征,学习无人机身份与射频观测信号之间的映射关系,实现高准确率、低时延的非合作无人机身份识别。

2.2 射频瞬态指纹机理与有效性验证

2.2.1 射频前端的瞬态响应机制

射频指纹识别的物理基础在于无线设备制造过程中不可避免的器件公差与电路非理想特性。在实际通信中,接收信号通常由极短的瞬态开启阶段与较长的稳态传输阶段共同组成。与主要受协议和调制方式约束的稳态信号不同,瞬态信号反映射频前端从关断静默状态向稳定工作点过渡的动态响应,更接近设备底层硬件特性的直接表征。

无线设备启动传输时,其射频前端会经历由非稳态向稳定工作点收敛的动态过程,该过程通常伴随锁相环频率合成、功率放大器功率爬升和短时幅相扰动等瞬态响应^[27]。由于不同设备在晶振稳定性、寄生参数、器件工艺和电路布局等方面存在细微差异,其状态收敛轨迹通常并不完全一致。瞬态过程在全局信号时间轴上占比很小,但其携带的硬件差异信息更集中,因此需要从长时信号中单独定位和提取。

2.2.2 基于非线性动力学的指纹增强机理

瞬态信号之所以具有较强的设备区分能力,其原因之一在于硬件非线性效应在启动阶段更易集中显现。功率放大器的非线性记忆效应:在信号开启瞬间,功率放大器通常处于动态偏置和非线性过渡状态。由于器件非理想性和记忆效应的存在,不同设备的输出包络可能表现出不同的上升过程和短时波动。如果直接将全局信号输入模型,这类短时非线性差异容易被占比更大的稳态信号所平滑,从而难以凸显。而如果将瞬态区单独剥离,并将功率上升阶段的低频波动进一步表征为包络调制谱,则更有利于突出由硬件差异引起的特征。

频率合成器的瞬态抖动:锁相环入锁过程中,环路尚未达到锁定状态时,压控振荡器控制电压存在短时起伏波动,造成输出信号瞬时频率、相位产生瞬态偏移^[28]。这种瞬时频率和相位变化与设备内部环路参数、本振稳定度等硬件差异有关。因此,从全局信号中精准截取瞬态片段,有助于减少稳态区域对特征表征的稀释作用,提升对本征硬件

差异的刻画能力。

2.2.3 瞬态片段有效性验证

为验证瞬态片段相较全局信号的有效性,本文基于 DroneRF 数据集对全局信号与对应瞬态片段进行配对统计分析。考虑到瞬态信号长度较短,不适合直接计算长时间序列多尺度复杂度指标,本文选取信号强度和谱熵两个代表性指标,分别表征能量规模和频谱复杂度,并采用配对 t 检验评估二者差异,具体如表 1 和图 2 所示。

表 1 全局信号与瞬态片段特征差异的配对 t 检验结果

特征指标	全局均值	全局标准差	瞬态均值	瞬态标准差	p 值
信号强度	2749.6	112.18	788.4	26.345	$p < 0.001$
谱熵	0.999	0.0001	0.9965	0.0006	$p < 0.001$




图 2 全局信号与瞬态片段特征分布箱线图

表 1 和图 2 表明,瞬态片段在能量规模和谱复杂度上均与全局信号存在显著差异,说明瞬态提取并非简单裁剪,而是在一定程度上剥离了冗余稳态成分并突出硬件相关响应。

1) 冗余能量剥离:全局信号平均强度较高,而瞬态片段强度显著下降,表明长时背景能量和稳态载荷被有效削弱。

2) 指纹集中度提升:瞬态片段的谱熵低于全局信号,说明其频谱结构更加集中,有利于后续模型聚焦设备启动阶段的硬件差异。

3 无人机身份识别方法设计

本文所提身份识别方法主要包括四个环节:信号预处理、瞬态片段定位、TEMSI 表征生成以及轻量级深度识别。其总体架构如图 3 所示。该流程的核心思想是在信号层面去除冗余与噪声,提取更

接近硬件本征差异的瞬态能量包络,将瞬态包络映射为二维 TEMSI 谱图,随后将其输入轻量化 CNN 网络完成无人机射频指纹识别。整个架构依托四层模块化结构实现,后端附加模型评估模块完成各项性能指标测算。

信号预处理:对原始 RF 组合信号进行带通滤波和幅值归一化,并通过二阶 Haar 小波分解抑制直流漂移与高频噪声,得到尺度一致、局部突变特征较清晰的时域序列。

TEMSI 表征:基于短时傅里叶变换、能量轨迹和样本级全局自适应阈值检测定位瞬态片段。随后提取瞬态能量包络,利用 Welch 方法估计包络调制谱,并将其映射为二维 TEMSI 图像,用于刻画射频前端启动阶段的低频能量波动。

轻量级识别:将 TEMSI 输入 EfficientNet-B0、MobileNetV2、ShuffleNet 和 SqueezeNet 等轻量级主干网络,结合迁移学习和分层微调策略完成多类别无人机身份识别。

3.1 关键参数选择

3.1.1 二阶 Haar 小波变换的选择

在基于多分辨率分析 (Multiresolution Analysis, MRA) 的预处理阶段,小波基函数与分解阶数的选择直接决定了特征提取的信噪比与计算效率。根据 Mallat 理论^[29]及轻量级部署需求,制定了如下参数选择策略:

1) 小波基函数的选择。采用 Haar 小波而非高

阶 Daubechies 小波,主要基于形态匹配与计算复杂度的双重考量。从物理特性上看,无人机射频信号的瞬态起始段表现为功率的阶跃突变。根据匹配滤波理论,Haar 小波的不连续方波基函数天然契合这一阶跃特征,能够对信号奇异点产生较强响应,有效避免高阶平滑小波在突变点处引入吉布斯振铃伪影,从而保证起始点定位的时域精度^[29]。从计算资源来看,Haar 小波具有最短的紧支撑长度 (Length = 2),其变换过程仅涉及加减法与移位运算,无需复杂的浮点乘法。相比传统方法,其较低的算力开销与“轻量级”边缘侧识别的系统定位较为契合。

2) 分解阶数的确定。分解阶数的确定需要在噪声抑制与细节保留之间寻求平衡。根据 Mallat 的多分辨率分析理论^[29],分解过程实质上是将信号投影到不同尺度的正交子空间中。如图 4 所示,一阶分解虽然保留了最高的时间分辨率,但残留了较多高频噪声,容易导致能量检测算法产生虚警。三阶分解则因过度平滑导致瞬态信号陡峭上升沿模糊化,破坏了携带指纹信息的细微结构。相比之下,二阶分解在有效滤除高斯白噪声基底的同时,能够较完整地保留瞬态信号的边缘几何特征,因此被确定为算法的最优预处理参数。

3.1.2 瞬态检测阈值的选择

针对不同射频样本在信号强度和背景噪声水平等方面的整体统计差异,本文采用基于能量变化率




图3 基于瞬态包络调制谱图的轻量级无人机射频身份识别方法总体架构

的样本级全局自适应阈值检测策略。该阈值由当前样本全部能量变化量的均值和标准差共同确定。其中,均值项用于表征能量变化量的整体平均水平,标准差项用于描述其整体波动程度。当某一位置的信号变化幅度超过阈值时,将其确定为候选突变位置。

为验证该方法对样本间统计差异的适应能力,首先根据参考样本的能量变化统计量计算阈值,并将其作为固定阈值直接应用于测试样本。同时,根据测试样本自身的能量变化统计量重新计算全局自适应阈值。两种方法在同一测试样本上的检测结果如图5所示。

图5(a)采用参考固定阈值0.0504进行检测,在保留参考突变位置的同时,参考区域外产生了295个候选点。图5(b)采用测试样本自身计算得到的全局自适应阈值0.0868进行检测,同样保留了参考突变位置,参考区域外候选点减少至165个,较固定阈值减少44.07%。结果表明,该方法能够根据不同样本的整体统计特性调整检测阈值,抑制部分低幅值候选响应,提高样本间的统计适应能力。

3.2 信号预处理

(1) 信号组合: DroneRF数据集通过两台 NI-USRP2943R 接收器分别采集 2.4 GHz 频段的低频部分 $r_L[n]$ 和 高频部分 $r_H[n]$ ^[30]。在组合前,对两路信号进行时间对齐与相位补偿。随后按线性叠加方式得到完整接收序列^[31]:

$$r[n] = r_L[n] + r_H[n] \quad (3)$$

(2) 滤波和归一化: 对组合信号 $r[n]$ 进行带通滤波,通带设置为 100 kHz 至 6 MHz,以抑制低频直流偏置和高频稳态通信成分。随后采用最大绝对值归一化,将幅值缩放至 $[-1,1]$:

$$\tilde{r}[n] = \frac{r[n]}{\max_n |r[n]|} \quad (4)$$

(3) 小波变换: 以归一化信号 $\tilde{r}[n]$ 为输入,采用二阶 Haar 小波分解提取局部细节分量。一级近似系数和细节系数分别为:

$$a^{(1)}[n] = \sum_m \tilde{r}[2n+m] h_L[m] \quad (5)$$

$$b^{(1)}[n] = \sum_m \tilde{r}[2n+m] h_H[m] \quad (6)$$

对一级近似系数 $a^{(1)}[n]$ 继续分解,得到二级近

似系数和二级细节系数:

$$a^{(2)}[n] = \sum_m a^{(1)}[2n+m] h_L[m] \quad (7)$$

$$b^{(2)}[n] = \sum_m a^{(1)}[2n+m] h_H[m] \quad (8)$$

其中, $h_L[m]$ 和 $h_H[m]$ 分别表示 Haar 小波低通和高通滤波器。二级细节分量 $b^{(2)}[n]$ 保留较丰富的局部突变信息,本文将其记为 $r_L[n]$, 用于后续频谱分析与瞬态片段定位。




图4 基于DroneRF真实数据的Haar小波消融实验对比




图5 参考固定阈值与样本级全局自适应阈值检测结果对比

3.3 瞬态包络调制谱图(TEMSI)表征

3.3.1 时频谱图(Spectrogram)

为了分析射频信号在时间-频率域中的瞬态能量分布, 本文对小波处理后的高通序列 $r_i[n]$ 计算短时傅里叶变换(STFT)。设 $q[\cdot]$ 为分析窗函数, N_f 为离散傅里叶变换点数, 则STFT可表示为^[32]:

$$S[k, n] = \sum_m r_i[m] q[m - n] \exp\left(\frac{-j2\pi km}{N_f}\right) \quad (9)$$

$$E[k, n] = 10 \log_{10}(|S[k, n]|^2 + \varepsilon) \quad (10)$$

其中, $S[k, n]$ 表示频率索引 k 、时间索引 n 处的复频谱值。 $E[k, n]$ 为对数能量谱。 ε 为用于规避零幅值引发的对数奇异问题的极小常数。本文窗长设置为 5120, N_f 设置为 2560。

3.3.2 归一化频谱能量

为消除不同无人机型号和传输距离造成的绝对能量差异, 对对数能量矩阵 $E[k, n]$ 进行 min-max 归一化:

$$E_N[k, n] = \frac{E[k, n] - E_{\min}}{E_{\max} - E_{\min}} \quad (11)$$

其中, $E_{\max}$ 和 $E_{\min}$ 分别为能量矩阵的最大值和最小值, $E_N[k, n]$ 为归一化后的时频能量。

3.3.3 能量轨迹的计算

沿频域维度对归一化时频能量矩阵求和, 得到表征信号时域能量演变的能量轨迹 $E_i[n]$, 用于后续样本级全局自适应阈值检测, 以定位射频瞬态区间:

$$E_i[n] = \sum_{k=1}^{K_f} E_N[k, n] \quad (12)$$

其中, N_f 为STFT频点总数量, n 为离散时间索引。

3.3.4 瞬态片段的检测

$$\Delta E[n] = E_i[n] - E_i[n - 1] \quad (13)$$

其中, $\Delta E[n]$ 表示时刻 n 的能量变化量。基于其均值和标准差, 样本级全局自适应动态检测阈值定义为:

$$\theta = \mu_{\Delta E} + \sigma_{\Delta E} \quad (14)$$

其中, $\mu_{\Delta E}$ 和 $\sigma_{\Delta E}$ 分别为 $\Delta E[n]$ 的均值与标准差:

$$\mu_{\Delta E} = \frac{1}{T-1} \sum_{n=2}^T \Delta E[n] \quad (15)$$

$$\sigma_{\Delta E} = \sqrt{\frac{1}{T-2} \sum_{n=2}^T (\Delta E[n] - \mu_{\Delta E})^2} \quad (16)$$

其中, T 为当前样本分帧后的总帧数, 该阈值根据当前样本全部能量变化量的统计特性计算, 在单个样本内部保持不变。基于样本级全局自适应阈值 θ , 瞬态片段的起始点和终点定义为: 瞬态起始点为能量变化率首次超过阈值的位置:

$$n_s = \min\{n | \Delta E[n] > \theta\} \quad (17)$$

从 n_s 向后搜索, 瞬态终点定义为能量变化率回落至阈值以下的位置:

$$n_e = \min\{n > n_s | \Delta E[n] < \theta\} \quad (18)$$

最终, 根据时间索引区间 $[n_s, n_e]$, 从归一化时频矩阵中截取瞬态时频子矩阵, 用于后续 TEMSI 生成。

3.3.5 瞬态包络调制谱图(TEMSI)生成

传统的频域分析方法通常直接对原始射频时间序列进行傅里叶变换。然而, 为了更精准地刻画无人机射频前端开启时的低频能量振荡特性, 本文提出了一种基于时频能量包络的二次特征提取与图像映射机制, 即生成瞬态包络调制谱图(TEMSI)。

对于截取得到的二维瞬态归一化能量矩阵 $E_N[k, n]$, 沿频域维度取算术平均, 得到一维瞬态能量包络序列 $e[n]$:

$$e[n] = \frac{1}{K_f} \sum_{k=1}^{K_f} E_N[k, n] \quad (19)$$

式中, $n_s \leq n \leq n_e$, n 为原始时频矩阵的全局时间索引。

在实际采集中, 信道衰落或硬件抖动可能导致少量无效值。为保证序列连续性, 对 $e[n]$ 中的无效点采用相邻有效样本的线性插值或外推进行修正。随后, 对平滑后的能量包络 $e[n]$ 采用 Welch 方法估计包络调制谱。设窗口长度为 L_w , 重叠长度为 L_o , 相邻片段步进为 $S = L_w - L_o$ 。为兼顾频率分辨率与估计方差, 本文令 $L_w = \min(|L_e/2|, 1024)$, 其中包络序列长 $L_e = n_e - n_s + 1$, 并设置 $L_o = |L_w/2|$ 。第 q 个重叠数据段可表示为:

$$e_q[m] = e[qS + m] \quad (20)$$

其中, $m = 0, 1, \dots, L_w - 1$ 。对每个数据段施加 Hamming 窗 $u[m]$ 后, 计算其修正周期图:

$$P_q[f] = \frac{1}{F_s U} \left| \sum_{m=0}^{L_w-1} e_q[m] u[m] \exp\left(-\frac{j2\pi f m}{L_w}\right) \right|^2 \quad (21)$$

其中, F_s 为采样频率, U 为窗函数能量归一化因子, 定义为:

$$U = \left(\frac{1}{L_w} \right) \sum_{m=0}^{L_w-1} u^2[m] \quad (22)$$

最后, 对所有 Q 个重叠数据段的周期图求平均, 得到平滑包络调制谱估计:

$$P_{TEMSI}[f] = \frac{1}{Q} \sum_{q=1}^Q P_q[f] \quad (23)$$

获得一维包络调制谱后, 将频率作为横坐标, 将对数功率谱密度作为纵坐标, 绘制平滑二维曲线并去除多余留白, 生成 RGB 格式的瞬态包络调制谱图 (TEMSI)。该过程将射频前端启动阶段的低频能量波动转化为可由轻量级 CNN 学习的视觉纹理特征。

图6展示了10类射频信号 (包含1类背景噪声及3类无人机的9种工作状态) 的 TEMSI 特征。为便于比较, 图中纵坐标 (功率谱密度) 统一限定在 $[-160, -40]$ dB/Hz, 横坐标 (包络调制频率) 截取 0 - 2000 Hz 频段。结合图谱特征, 可从以下三个方面分析:

(1) 无人机信号的能量级差: 如图6(a)所示, 纯净背景环境下的射频能量基底较低, 曲线呈现较为平缓的衰减趋势, 无明显的调制特征。相比之下, 当无人机处于开机或飞行状态时, 受飞控指令、图传数据包及内部电路辐射的综合影响, 信号频域能量显著提升 (例如 DJI Phantom 的低频段逼近 -40 dB/Hz), 与背景噪声在绝对能量维度上形成

了明显的阶梯差异。

(2) 不同目标机型的频谱轮廓异构性: 由于各型号无人机采用了不同的射频前端架构、基带芯片及底层通信协议, 其 TEMSI 特征展现出明显的物理异构性。对比图6中 AR 系列、Parrot Bebop 系列以及 DJI Phantom 的特征谱线, 可以清晰观察到三者整体能量基准线及高频段衰减斜率上存在固有差异。这种跨机型的粗粒度轮廓特征, 为网络实现目标品牌级分类提供了基础。

(3) 同机型不同工作状态的细粒度特征: 除宏观能量差异外, TEMSI 能够有效刻画同一无人机在不同状态下的射频瞬变细节。以 AR 无人机为例, 从开机图6(b)、悬停图6(c)到飞行状态图6(d)、图6(e), 随着电机负载变化及图传数据吞吐量的波动, 其包络调制谱在 500~1500 Hz 频段内呈现出不同程度的局部能量陷波与起伏。这类细粒度的纹理特征, 构成了区分具体飞行模式的核心射频指纹。

综上, 与传统瞬态频谱、包络谱及时频谱相比, TEMSI 的差异首先体现在表征对象与谱估计路径上。传统瞬态频谱侧重刻画瞬态能量在载频轴上的分布, 包络谱通常分析幅值随时间变化所对应的频率成分, 时频谱则更容易呈现时间一载频能量的联合分布, 其中可能混入稳态载荷与背景信息。相对而言, TEMSI 在已定位的瞬态区间内对时频能量进行聚合, 形成能量包络, 并进一步采用 Welch 方法估计其调制功率谱, 从而使表征对象由“载频能量分布”转向“射频启动阶段能量包络的调制结构”。在此设计下, 稳态相关成分在聚合阶段被弱化的同时, 有限时长瞬态的谱估计波动也可




图6 10类无人机射频活动的瞬态包络调制谱图(TEMSI)特征对比

在一定程度上被 Welch 的平滑/平均机制缓解。从非理想射频前端角度看,启动阶段的增益建立过程、滤波器过渡响应以及相噪与幅度噪声会使能量包络随时间呈现低频调制与形态差异。TEMSI 将这种“调制规律”以二维表征的形式显式编码,使模型能够在更接近物理机理的表征空间中学习型号—状态相关的差异。

3.4 特征提取与主干网络

为比较不同轻量级网络在 TEMSI 输入下的适用性,本文选取 EfficientNet-B0、MobileNetV2、ShuffleNet 和 SqueezeNet 作为主干模型。四种网络在参数量、卷积结构和推理速度方面具有差异,能够较全面地评估 TEMSI 表征在不同轻量级 CNN 上的泛化能力。

3.4.1 特征提取

在输入主干网络之前,所有 TEMSI 图像均统一转换为三通道格式,并按网络输入要求统一缩放:EfficientNet-B0、MobileNetV2 和 ShuffleNet 输入尺寸为 $224 \times 224 \times 3$,SqueezeNet 输入尺寸为 $227 \times 227 \times 3$ 。实验采用 ImageNet-1k 预训练权重进行迁移学习,保留预训练网络原有的输入尺寸与归一化配置,仅替换输出类别层以完成类别数的任务适配。尽管 ImageNet 预训练与 TEMSI 的物理来源不同,但卷积网络前几层学习的对比度、局部边缘/纹理等低级表征具有一定跨任务通用性。TEMSI 虽然对应射频启动阶段的能量分布,但在局部尺度上同样表现为可学习的结构性纹理与形态变化,因此采用 ImageNet 预训练作为初始化在机制上是合理的。同时,考虑到任务标注数据有限,从头训练可能带来较大的优化不稳定性与过拟合风险。本文通过对预训练层与新增分类层施加差异化学习率的分层微调策略,逐步适配 TEMSI 所反映的射频调制差异。需要说明的是,迁移学习在本文主要用于特征初始化与训练稳定性保障,其对最终性能的实际贡献已在 4.2 节通过随机初始化对照实验量化验证。

(1) 主干网络加载:保留预训练网络的卷积层、归一化层和激活层,实现 TEMSI 图谱局部纹理、高层语义基础特征的提取。

(2) 分类层替换:根据无人机射频活动类别数 K 重构原分类头。EfficientNet-B0、MobileNetV2 和 ShuffleNet 更换末端的全连接层及其后的分类输

出层。SqueezeNet 更换末端的 1×1 卷积分类层。

(3) 判别特征学习:网络通过多层卷积和非线性映射逐级提取 TEMSI 的边缘、局部起伏和频谱纹理结构,最终输出具有类别区分能力的深层 TEMSI 特征。

3.4.2 微调策略

(1) 新分类层快速适配:将新加入分类层的权重和偏置学习率因子设置为 10,使其能够较快适应无人机射频活动类别分布。

(2) 主干层低速微调:主干网络保持较低学习率,以保留预训练模型的通用特征表达能力,并降低小样本场景下的过拟合风险。

上述分层微调策略在保持迁移特征稳定性的同时,提升了新任务分类层的适配效率。

4 实验与结果分析

4.1 实验设置

本文采用公开 DroneRF 数据集进行实验评估,输入样本为由原始 RF 信号生成的 TEMSI 图像,任务包含 10 类无人机射频活动。DroneRF 十类标签同时包含无人机型号和工作状态差异,并包含无人机背景类别。本文沿用该数据集的标签设置,将实验任务定义为型号-状态相关的射频身份识别,而非同型号不同物理设备之间的个体级射频指纹识别。在模型训练过程中,EfficientNet-B0、MobileNetV2、ShuffleNet 和 SqueezeNet 均采用统一的参数配置与验证策略。训练集、验证集和测试集分别包含 15405、3303 和 3303 个 TEMSI 样本,优化器采用 Adam,初始学习率设为 1×10^{-4} ,除新替换的分类层外,其余各层学习率均等于基准学习率,即主干网络学习率系数为 1.0,分类层的权重与偏置学习率因子均设为 10,故分类层有效学习率为 $10 \times 1 \times 10^{-4} = 1 \times 10^{-3}$,学习率在训练全程保持恒定。训练批量大小为 32,最大训练轮数为 10,损失函数采用多分类交叉熵。主干网络与分类层全部参数均参与更新,迁移策略为全网络参数微调结合分类层加速适配。训练过程中每隔 10 次迭代利用验证集评估模型性能,并选取验证集表现最佳的网络权重用于测试。实验在单台通用 PC 上完成,硬件配置为 64 位处理器和 16GB 内存,软件环境为 Windows Server2019、MATLAB R2024b 及 Deep Learning Toolbox。所有推理实验均在通用 CPU 环境下完成,

以模拟边缘监测设备无 GPU 加速的部署条件。为客观比较不同网络的边缘推理效率，测试阶段在 batch size 为 32、64、96 和 128 的设置下分别统计总推理时间，并选取各模型在 CPU 上耗时最短的 batch size 作为最终测速配置。实验结果表明，ShuffleNet 模型在 Batch Size 为 96 时达到了最佳的并行推理速度。而 EfficientNet-B0、MobileNetV2 与 SqueezeNet 三种模型则在 Batch Size 达到最大值 128 时才展现出最优的推理时延。后续所有精度指标和单样本推理时延均基于相同测试集和相应最优 batch size 得到。

4.2 结果分析

本文从类别级和整体级两个层面评估 EfficientNet-B0、MobileNetV2、ShuffleNet 和 SqueezeNet 的识别性能。类别级指标包括精确率、召回率、F1 分数。整体指标包括准确率、宏平均 F1、宏平均 AUC、Kappa、MCC 和 CPU 单样本推理时延。AUC 由各类别的 softmax 输出概率计算，而非由硬分类标签直接计算，以避免阈值无关指标失真。表 2 给出了四种模型在各类别上的识别结果。总体来看，EfficientNet-B0、MobileNetV2 和 ShuffleNet 在多数类别上保持较高精确率和召回率，说明 TEMSI 特征能够为轻量级网络提供较稳定的判别信息。SqueezeNet 参数量较小、推理速度较快，但在部分边界类别上的分类结果波动明显，反映出极轻量模型在细粒度射频指纹学习方面仍存在表达能力限制。


图7和图8分别给出了 EfficientNet-B0、MobileNetV2、ShuffleNet 和 SqueezeNet 四种主流轻量级模型的混淆矩阵和宏平均 ROC 曲线。

从图 7 和图 8 可以看出, EfficientNet-B0 的混淆矩阵最接近对角线, 各类别区分能力较强。MobileNetV2 和 ShuffleNet 也保持较好的整体识别效果, 但在少数相近工作状态之间存在误判。SqueezeNet 的混淆更明显, 说明其在复杂类别边界上的判别能力不足。ROC/AUC 结果进一步表明, 高层特征表达能力更强的模型更易充分利用 TEMSI 中的细粒度频谱纹理。对于个别类别出现精确率、召回率较高但 AUC 偏低的情况, 其主要原因在于 one-vs-rest 概率排序与最终最大概率类别判决并不完全等价, 因此本文同时报告混淆矩阵、F1 和 AUC, 以避免单一指标造成片面判断。


表3给出了四种轻量网络整体性能指标与CPU环境下的单样本推理耗时对比。可以看出，各模型在精度方面均保持较高水平，其中 EfficientNet-B0 表现最优。在计算开销方面，不同网络结构对应的前向推理耗时存在差异。需要说明的是，本表“单样本推理时延（ms）”统计口径为网络CNN前向推理阶段的耗时，用于表征模型计算效率。该结果不包含射频前端预处理与 TEMSI 图像生成等环节的耗时。因此，表3主要反映CNN阶段的计算负担与轻量化优势，而关于端到端实时性/边缘部署的完整可行性仍需在同一硬件平台上进一步开展端到端时延测量与分析。

表2 四种主流轻量级模型在每个类别中的表现


[illegible]




(a) EfficientNet-B0




(a) EfficientNet-B0




(b) MobileNetV2




(b) MobileNetV2




(c) ShuffleNet



(c) ShuffleNet



(d) SqueezeNet



(d) SqueezeNet

图7 四种主流轻量级模型的混淆矩阵

图8 四种主流轻量级模型宏平均ROC曲线

为验证 TEMSI 表征的贡献并量化迁移学习作用, 本文基于 DroneRF 源数据另行划分构建补充消融实验, 采用 PyTorch 在 GPU 环境下、以 EfficientNet-B0 为统一分类器训练。输入表征设置为随机裁剪时频谱、完整时频谱、瞬态时频谱、瞬态包络谱与 TEMSI 五种, 共享同一预处理与瞬态定位流程。结果如表 4 所示。

由表 4 可见: 其一, 瞬态时频谱相较完整时频谱准确率提升约 0.25 个百分点, 验证了瞬态片段定位对剔除稳态载荷与背景干扰的有效性。其二, 随机裁剪时频谱的准确率仅为 61.86%, 远低于瞬态时频谱, 说明增益并非来自“任意裁剪”, 而来自基于能量轨迹与自适应阈值的瞬态定位。其三, TEMSI 取得最高准确率 (99.88%) 与最高 Macro-F1 (99.91%), 说明将包络调制谱映射为二维图像表征有利于轻量级网络提取细粒度射频差异。此外, 四种表征的 Macro-F1 与准确率基本一致, 表明各类别识别性能较为均衡。上述结果与 2.2.3 节的配对 t 检验相互印证, 表明统计分布上的差异确实转化为分类性能的提升。

在迁移学习贡献方面, 本文另设随机初始化对照组, 其余配置与预训练组完全一致, 两种初始化方式在 TEMSI 表征下的对比如表 5 所示。

由表 5 可见, 采用 TEMSI 表征时, ImageNet 预训练相较随机初始化的准确率由 93.19% 提升至 99.88%, Macro-F1 由 93.10% 提升至 99.91%, 提升约 6.69 个百分点, 表明迁移学习对最终识别性能具有实质贡献, 且在提升整体精度的同时改善了各类别识别的均衡性。

4.3 相关工作性能比较

为进一步评估所提方法的有效性, 本文在

DroneRF 十类无人机射频活动识别任务上选取三类代表性方法进行对比, 包括基于迁移学习的 TL-VGG16^[33]、基于时频多尺度卷积结构的 TFMS-CNN^[11] 以及基于集成学习与传感融合的 EN-Net^[19]。对比结果如表 6 所示。

从准确率看, 本文方法整体优于对比方法。其中, EfficientNet-B0 达到 99.99%, 较 EN-Net、TL-VGG16 和 TFMS-CNN 分别提高 7.51、9.79 和 12.32 个百分点。ShuffleNet 和 MobileNetV2 也分别达到 99.76% 和 97.94%。这说明 TEMSI 表征与轻量级 CNN 的结合能够有效支撑多类别无人机射频活动识别。

从 F1 分数看, 本文方法同样表现较好。EfficientNet-B0 的 F1 分数为 99.99%, 较 TL-VGG16 和 EN-Net 分别提高 10.79 和 32.70 个百分点。需要注意的是, 不同文献在数据划分、类别定义、预处理方式和训练策略上可能存在差异, 因此表 6 主要用于体现本文方法在 DroneRF 十类任务设置下的相对竞争力, 而非作为跨论文绝对泛化能力的唯一证据。

综合来看, TEMSI 特征能够增强射频瞬态硬件差异的表征能力, 并与多种轻量级 CNN 形成较好适配关系。

5 结束语

本文提出一种基于瞬态包络调制谱图 (TEMSI) 的轻量级无人机射频身份识别方法。该方法通过瞬态片段定位、包络调制谱估计和轻量级 CNN 迁移学习, 增强了射频启动瞬态中硬件相关特征的表达能力。基于 DroneRF 数据集的实验结果表明, TEMSI 能够有效支撑十类无人机射频身

表 3 四种主流轻量级模型的表现

指标	EfficientNet-B0	MobileNetV2	ShuffleNet	SqueezeNet
准确率/%	99.99	97.94	99.76	76.58
精确率/%	99.99	97.87	99.71	71.78
召回率/%	99.99	98.36	99.75	67.56
F1 分数/%	99.99	97.91	99.73	67.61
宏平均 AUC	1	1	0.99	0.59
Kappa 系数	1	0.98	0.99	0.74
MCC	1	0.98	0.99	0.74
单样本推理时延 (ms)	23.37	13.62	16.91	10.34

表4 不同输入表征下的性能对比

输入表征	准确率/%	Macro-F1/%
随机裁剪 时频谱	61.86	61.84
完整时频谱	99.60	99.41
瞬态时频谱	99.85	99.89
瞬态包络谱	99.86	99.89
TEMSI	99.88	99.91

表5 ImageNet 预训练与随机初始化的性能对比

方法	ImageNet 预训练		随机初始化	
	准确率/%	Macro-F1/%	准确率/%	Macro-F1/%
TEMSI	99.88	99.91	93.19	93.10

份识别，并在精度与 CPU 推理时延之间取得较好平衡。需要指出的是，本文实验仍主要依赖公开数据集，复杂电磁干扰、跨设备域迁移、跨距离采集和开放集未知无人机识别仍需进一步研究。

表6 本文方法与代表性方法性能对比

方法	特征/模型范式	评估 协议	准确率/%	F1 /%
本文 EfficientNet-B0	TEMSI+轻量 CNN 迁移	十类	99.99	99.99
本文 MobileNetV2	TEMSI+轻量 CNN 迁移	十类	97.94	97.91
本文 ShuffleNet	TEMSI+轻量 CNN 迁移	十类	99.76	99.73
TL-VGG16 [33]	CWT 谱图+VGG-16 迁移	十类	90.2	89.2
TFMS-CNN [11]	时/频并联多尺度 1D-CNN	十类	87.67	86.82
EN-Net[19]	1D+2D 融（RF-Net+SP-Net）	十类	92.48	67.29

参考文献:

- [1] 肖振宇, 刘珂, 朱立鹏. 无人机间毫米波阵列通信技术[J]. 通信学报, 2022, 43(10): 196-209.
Xiao Z, Liu K, Zhu L. Millimeter-wave array enabled UAV-to-UAV communication technology[J]. Journal on Communications, 2022, 43 (10): 196 - 209.
- [2] Mohsan S A H, Othman N Q H, Li Y, et al. Unmanned aerial vehicles (UAVs): Practical aspects, applications, open challenges, security issues, and future trends[J]. Intelligent Service Robotics, 2023, 16: 109-137.
- [3] 何道敬, 杜晓, 乔银荣, 等. 无人机信息安全研究综述[J]. 计算机学报, 2019, 42(5): 1076-1094.
He D. J., Du X., Qiao Y. R., et al. A survey on cyber security of unmanned aerial vehicles[J]. Chinese Journal of Computers, 42(5), 1076 - 1094.
- [4] Aldemir M H, Akgün Ö, Gürkan G, et al. Ground-Based UAV Detection and Tracking: A Comparative Analysis[J]. Journal of Aeronautics & Space Technologies/Havacilik ve Uzay Teknolojileri Dergisi, 2025, 18 (2): 120-155.
- [5] Zamri F N M, Gunawan T S, Kartiwi M, et al. Deep learning techniques for advanced drone detection systems: A comprehensive review of techniques, challenges and future directions[J]. Indonesian Journal of Electrical Engineering and Informatics (IJEI), 2024, 12(4): 818-857.
- [6] Seidaliyeva U, Ilipbayeva L, Taissariyeva K, et al. Advances and challenges in drone detection and classification techniques: A state-of-the-art review[J]. Sensors, 2024, 24(1): 125.
- [7] Soltanich N, Norouzi Y, Yang Y, et al. A review of radio frequency fingerprinting techniques[J]. IEEE Journal of Radio Frequency Identification, 2020, 4(3): 222-233.
- [8] Zhang J, Shen G, Saad W, et al. Radio frequency fingerprint identification for device authentication in the Internet of Things[J]. IEEE Communications Magazine, 2023, 61(10): 110-115.
- [9] Fu Y, He Z. Radio frequency signal-based drone classification with frequency domain Gramian angular field and convolutional neural network [J]. Drones, 2024, 8(9): 511.
- [10] Swinney C J, Woods J C. Unmanned aerial vehicle operating mode classification using deep residual learning feature extraction[J]. Aerospace, 2021, 8(3): 79.
- [11] Mandal S, Satija U. Time-frequency multiscale convolutional neural network for RF-based drone detection and identification[J]. IEEE Sensors Letters, 2023, 7(7): 1-4.
- [12] Ozturk E, Erden F, Guvenc I. RF-based low-SNR classification of UAVs using convolutional neural networks[J]. ITU Journal on Future and Evolving Technologies, 2021, 2(5): 39 - 52.
- [13] Soltani N, Reus-Muns G, Salehi B, et al. RF fingerprinting unmanned aerial vehicles with non-standard transmitter waveforms[J]. IEEE Transactions on Vehicular Technology, 2020, 69(12): 15518-15531.
- [14] Baldini G, Gentile C. Transient-based Internet of Things emitter identification using convolutional neural networks and optimized general linear chirplet transform[J]. IEEE Communications Letters, 2020, 24(7): 1482-1486.
- [15] Ezuma M, Erden F, Anjinappa C K, et al. Micro-UAV detection and classification from RF fingerprints using machine learning techniques [C]//2019 IEEE Aerospace Conference. IEEE, 2019: 1-13.
- [16] He J, Huang S, Yang Z, et al. Channel-agnostic radio frequency fingerprint identification using spectral quotient constellation errors[J]. IEEE Transactions on Wireless Communications, 2024, 23(1): 158-170.
- [17] He B, Wang F. Specific emitter identification via sparse Bayesian learning versus model-agnostic meta-learning[J]. IEEE Transactions on Information Forensics and Security, 2023, 18: 3677-3691.
- [18] Yang J, Gu H, Hu C, et al. Deep complex-valued convolutional neural network for drone recognition based on RF fingerprinting[J]. Drones, 2022, 6(12): 374.
- [19] Tanveer L, Alam M Z, Misbah M, et al. Optimizing RF-sensing for drone detection: The synergy of ensemble learning and sensor fusion [C]//2024 20th International Conference on Distributed Computing in Smart Systems and the Internet of Things (DCOSS-IoT). IEEE, 2024: 308-314.
- [20] Zhao T, Domae B W, Steigerwald C, et al. Drone RF signal detection and fingerprinting: UAVSig dataset and deep learning approach[C]// MILCOM 2024-2024 IEEE Military Communications Conference (MILCOM). IEEE, 2024: 431-436.
- [21] 孙剑文, 张斌, 常禾雨. 网络异常检测中的流量表示研究 [J]. 通信学报, 2025, 46 (1): 192-209.
Sun J W, Zhang B, Chang H Y. Research on traffic representation in network anomaly detection [J]. Journal on Communications, 2025, 46 (1): 192-209.
- [22] Shang P, Guo L, Zou D, et al. An Adaptive Deep Ensemble Learning for Specific Emitter Identification[J]. Sensors, 2025, 25(19): 6245.
- [23] Deng P, Hong S, Qi J, et al. A lightweight transformer-based approach of specific emitter identification for the automatic identification system [J]. IEEE Transactions on Information Forensics and Security, 2023, 18: 2303-2317.
- [24] 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.
- [25] Zhou K, Li Q, Cao P, et al. Lightweight and efficient hybrid network for UAV identification using radio frequency fingerprinting[J]. IEEE Internet of Things Journal, 2025, 12(20): 42728 - 42740.
- [26] 郑飞, 吴东颖, 李世超, 等. 基于轻量化 Swin Transformer的资源自适应语义压缩策略[J]. 通信学报, 2026, 47 (6): 146-159.
Zheng F., Wu D., Li S., et al. Lightweight Swin Transformer-based resource-adaptive semantic compression strategy[J]. Journal on Communications, 47(6), 146 - 159.
- [27] Danev B, Čapkun S. Transient-based identification of wireless sensor nodes[C]// Proceedings of the 2009 International Conference on Information Processing in Sensor Networks (IPSN). San Francisco, USA, 2009: 25-36.
- [28] Hall J, Barbeau M, Kranakis E. Detection of transient in radio frequency fingerprinting using signal phase[C]//Proceedings of the 3rd IASTED International Conference on Wireless and Optical Communications (WOC 2003). Banff, Canada: ACTA Press, 2003: 13 - 18.
- [29] Mallat S. A wavelet tour of signal processing: The sparse way[M]. Oxford: Academic Press, 2009.
- [30] Allahham M H D 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.
- [31] Oppenheim A V, Schaffer R W. Discrete-time signal processing[M]. 3rd

ed. Upper Saddle River, NJ: Prentice Hall, 2010.

- [32] 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.
- [33] He Z, Huang J, Qian G. UAV detection and identification based on radio frequency using transfer learning[C]//2022 IEEE 8th International Conference on Computer and Communications (ICCC). IEEE, 2022: 1812-1817.

樊卫北(1987-), 男, 河南开封人, 博士, 南京邮电大学教授, 主要研究方向为数据中心网络、智能物联网。



阿依努尔·努尔太(1986-), 女, 博士, 南京邮电大学博士生、新疆警察学院副教授, 主要研究方向为无人机安全和无线网络安全。



肖甫(1980-), 男, 湖南邵阳人, 博士, 南京邮电大学教授、博士生导师, 主要研究方向为物联网感知计算、物联网安全技术、数据中心网络。



张品昌(1985-), 男, 安徽阜阳人, 博士, 塔里木大学特聘教授、硕士生导师, 主要研究方向为 6G 无线网络安全、物理层安全认证、无人机通信安全、人工智能安全等。



董建阔(1992-), 男, 博士, 中国科学技术大学特任研究员, 主要研究方向为密码工程、网络空间安全。



沈元章(2002-), 男, 江苏淮安人, 南京邮电大学硕士生, 主要研究方向为物理层安全、同态加密。