



XXXX

面向无人机型号分选的图传信号时频与循环谱融合识别方法

崔亚民¹, 王首斌², 沈雷¹

(1. 杭州电子科技大学通信工程学院, 浙江 杭州 310018;

2. 中国电子科技集团公司第三十六研究所, 浙江 嘉兴 314033)

摘要: 为解决多无人机飞行场景下识别准确率低的问题, 提出一种基于图传信号的多域特征融合识别方法。图传信号具有连续、高带宽与硬件依赖性强等特点, 更适合作为稳定信号源。为克服单一特征局限性, 融合短时傅里叶变换 (Short-Time Fourier Transform, STFT) 与循环谱分析 (Cyclic Spectral Analysis, CSA) 进行多域建模。STFT 从时频动态中提取功放非线性、本振频偏等硬件指纹; CSA 利用信号周期平稳性挖掘 I/Q 失配、载波泄漏等谱相关特征, 从而全面表征细微身份差异。为充分挖掘融合特征形成的高维多域射频指纹表征中的复杂非线性相关性, 设计了 Effiv2KAN 模型 (EfficientNetV2-based Network with KAN Classifier)。该模型前端以 EfficientNetV2 对融合特征进行多尺度特征提取, 后端采用 KAN 分类器, 通过可学习样条函数替代固定激活函数, 以灵活拟合特征间复杂非线性关系, 提升对细微指纹的判别能力。实验结果表明, 该模型在不同信噪比下均优于经典深度学习模型, 对信号高度相似的无人机型号具有更强的抗噪鲁棒性。

关键词: 无人机射频指纹; 图传信号; 时频-循环谱特征融合; Effiv2KAN 模型

中图分类号: TN911.7

文献标志码: A

doi: 10.11959/j.issn.1000-0801.

A fusion recognition method of video transmission signal time-frequency and cyclic spectrum for uav model classification

CUI Yamin¹, WANG Shoubin², SHEN Lei¹

1. School of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China

2. The 36th Research Institute of China Electronics Technology Group Corporation, Jiaxing 314033, China

Abstract: To address the issue of low recognition accuracy in multi-UAV flight scenarios, a multi-domain feature fusion recognition method based on video transmission signals was proposed. The video transmission signal, characterized by its continuity, high bandwidth, and strong hardware dependence, was considered a more suitable stable signal source. To overcome the limitations of a single feature, short-time Fourier transform (STFT) and cyclic spectral analysis (CSA) were integrated for multi-domain modeling. STFT was employed to extract hardware fingerprints, such as power amplifier nonlinearity and local oscillator frequency offset, from time-frequency dynamics. CSA was utilized

收稿日期: XXXX-XX-XX; 修回日期: XXXX-XX-XX

通信作者: 王首斌, 357513989@qq.com



to mine spectral correlation features, including I/Q mismatch and carrier leakage, by leveraging the cyclostationarity of the signal, thereby comprehensively characterizing subtle identity differences. To fully exploit the complex nonlinear correlations within the high-dimensional multi-domain radio frequency fingerprint representation formed by the fused features, an Effiv2KAN model (EfficientNetV2-based Network with KAN Classifier) was designed. In this model, EfficientNetV2 was adopted at the front end for multi-scale feature extraction from the fused features, and a KAN classifier was employed at the back end. By replacing fixed activation functions with learnable spline functions, the model flexibly fit the complex nonlinear relationships among features, enhancing the discriminative capability for subtle fingerprints. Experimental results demonstrated that the proposed model outperformed classical deep learning models under different signal-to-noise ratios and exhibited stronger noise-robustness for discriminating UAV models with highly similar signals.

Key words: UAV RF Fingerprint, Video Transmission Signal, Time-Frequency and Cyclic Spectral Feature Fusion, Effiv2KAN Model

0 引言

近年来,小型无人机在众多应用领域受到前所未有的广泛关注,其应用范围从航拍、灾害管理到农业、通信和军事领域等多个方面,但它们也对军事、民用环境的安全构成了巨大威胁^{[1]-[3]}。种种恶意事件表明,研究能够快速精准识别非法无人机的系统已迫在眉睫^[4]。

传统的无人机识别方法主要是通过接收无人机射频信号,在时域或变换域提取信号的物理参数特征及统计特征,选取较为单一的特征构成射频指纹,再利用分类器实现无人机型号分类^[5]。文献[6]采用离散傅里叶变换(Discrete Fourier Transform,DFT)提取频域特征,并评估了不同传统机器学习模型的分类性能。最终,XGBoost模型在识别任务中表现最优。然而,该方法仅依赖频域信息,未能充分捕捉射频信号的时频动态特性,从而限制了其对细微硬件指纹差异的表征能力。文献[7]进一步通过短时傅里叶变换(STFT)获取无人机遥控器射频信号的时频谱,并提取能量瞬态特征,结合K近邻算法实现分类识别。虽然该方法在识别率上表现出色,在信噪比为20dB时达到98.19%,但其依赖于单一的短时傅里叶变换特征,未能对信号的其他物理属性或复杂非线性特征进行深入挖掘,这可能导致其在低信噪条

件下性能下降。

传统机器学习方法依赖预设特征空间,表征能力有限,难以刻画细微的硬件指纹差异,因而在低信噪比、多无人机共存环境下面临泛化性与鲁棒性挑战。与传统机器学习方法相比,深度学习模型因其能够自动学习高维特征和复杂模式的能力,逐渐成为无人机识别中的主流方法。文献[8]通过提取功率谱密度(Power Spectral Density, PSD)和时频图特征,并采用卷积神经网络(Convolutional Neural Network,CNN)进一步提取深层特征,最终结合传统机器学习模型完成无人机分类。然而,PSD与DFT变换类似,主要反映信号的频域能量分布,难以捕捉时频动态特性及细微的硬件指纹差异,尤其是高相似度无人机之间的微小差异。为提升在噪声和干扰环境下的识别鲁棒性,文献[9]利用正交频分复用(Orthogonal Frequency Division Multiplexing,OFDM)信号的归一化循环前缀相关谱,结合CNN完成了对无人机的鲁棒性识别。该方法所依赖的循环前缀相关谱,本质上仅利用了OFDM信号结构中循环前缀与数据部分的相关特性。与循环谱特征相比,其信息维度有限,未能充分利用信号内在的完整循环平稳特性。为提升实际场景下的识别性能,文献[10]采用实际采集信号的STFT特征,并结合ResNet18进行分类,取得了97.73%的准

确率。

此外，前文提到的“CNN提取特征+传统机器学习分类”的分离式架构，虽然能够在一定程度上提取无人机的深层特征，但由于传统分类器对高维非线性复杂特征的拟合能力有限，整体模型在低信噪比和高相似度无人机的判别性能仍然受到制约。值得注意的是，即便是采用端到端训练的深层CNN，其依赖逐层特征传递，随着网络深度的增加，容易出现梯度消失和网络退化等问题，从而限制了其对复杂非线性指纹模式的深层拟合能力。相比之下，ResNet18通过跳跃连接缓解了深度网络的训练问题，但其所有残差块均采用固定尺寸的卷积核进行同质化堆叠，导致网络只能在单一尺度上进行局部特征提取。此外，ResNet18均质的局部感受野与固定尺度的卷积操作，难以自适应地捕捉拼接图中跨区域、跨模式的全局上下文依赖，因此无法有效建立两类特征间的关联，制约了对完整硬件指纹的辨识能力。

与此同时，现有方法通常直接利用包含控制信号、图传成分及背景噪声的混合射频信号，在低信噪比条件下，各类信号成分相互交织，导致所提特征易受干扰、区分度下降。针对这一瓶颈，研究可转向更具结构性与持续性的OFDM图传信号。该信号帧结构中的循环前缀在时域上形成了一组稳定、可测且设备相关的物理层参数，可视为一种对噪声相对鲁棒的设备“指纹”，为在复杂电磁环境与低信噪比条件下实现高鲁棒性的无人机身份识别提供了理想的载体^[9]。

基于对现有研究局限性的分析，本文提出了一种基于图传信号多域特征融合的无人机识别方法。核心创新在于：特征层面，选用信息丰富的无人机图传信号融合时频谱与循环谱，构建时频-循环谱多域融合特征，以同时捕获信号的调制特性和射频指纹特征；模型层面，设计EfficientNetV2模型，通过EfficientNetV2骨干网络提取多尺度特征，以同时提取信号中包含的射频指纹

特征与调制信息，并以可学习的Kolmogorov-Arnold网络作为分类器，实现对复杂指纹模式的高效非线性建模；优化层面，引入多层次特征融合与自适应归一化机制，提升模型在低信噪比环境下的识别性能。该方案为多无人机场景下的无人机身份鉴别提供了新的解决途径。

1 基于时频-循环谱特征融合的方法

1.1 方法概述

本文通过将短时傅里叶变换时频谱与循环谱在空间维度上进行上下拼接，构建融合两种互补特征的图像表示，以更全面地涵盖调制和射频指纹信息，供后续深度学习模型使用。

无人机的图传信号通常采用正交频分复用技术调制^[10]，OFDM调制信号的表达式为：

$$s(t) = \sum_{i=0}^{N-1} y(i)e^{j2\pi f_i t}, 0 \leq t \leq T \quad (1)$$

其中，N为系统中子信道数，y(i)为第i个调制码元， f_i 表示第i个载波的频率，T为码元周期与保护时间之和。

1.2 时频特征提取

STFT是分析非平稳信号时频特性的经典方法。对于无人机图传信号的STFT定义为：

$$STFT(t_0, f) = \sum_{i=0}^{N-1} y(i)W(f-f_i)e^{j2\pi(f_i-f)t_0} \quad (2)$$

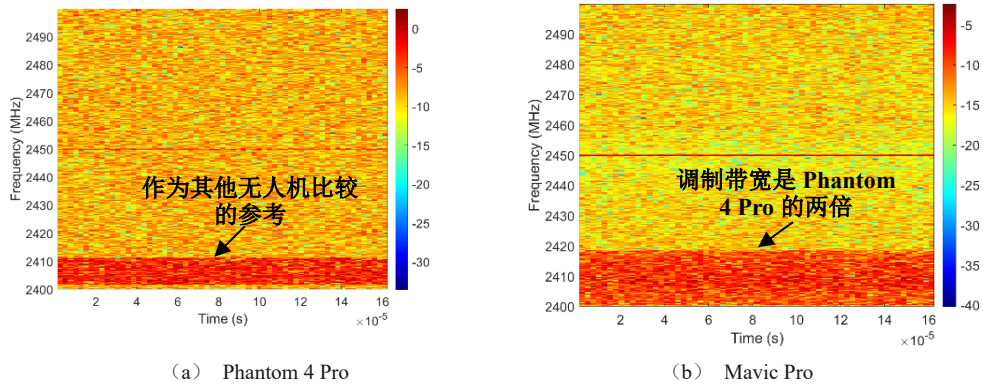
其中， $W(f-f_i)$ 表示分析窗函数的频域响应，本文采用长度为512的汉明窗对信号进行加窗，以减少频谱泄露效应。

1.3 循环谱特征提取

CSA基于信号的循环平稳理论，能够揭示信号中隐含的周期特性。对于无人机图传信号的循环自相关函数，可通过其标准定义计算：



$$S_{TF}(t, f) \in \mathbb{R}^{H \times W}$$



(a) Phantom 4 Pro (b) Mavic Pro

通过 STFT 变换, 将一维时域信号转换为二维时频谱图, STFT 时频谱图如图 1 所示, 该图谱能够直观展示信号能量在时频平面上的分布特征, 有效刻画瞬时能量分布及其随时间演化特性, 并可反映功放非线性、本振频偏及滤波器等硬件非理想性引入的动态指纹, 从而为无人机型号识别提供了重要依据。从分析可以看出, Mavic Pro 和 MATRICE 600 Pro 在带宽、中心频率等调制特征上与 Phantom 4 Pro 存在明显差异, 而 MATRICE 200 的 STFT 图从整体视觉上与 Phantom 4 Pro 较为接近, 仅凭时频谱图特征难以有效区分这两种型号。




图1 不同型号无人机 STFT 特征对比图

$$R_s^\alpha(\tau) = \sum_{i,k} E\{y(i)y^*(k)\} e^{j\pi(f_i+f_k)\tau} \lim_{T_0 \rightarrow \infty} \frac{1}{T_0} \int e^{j2\pi(f_i-f_k-\alpha)t} dt \quad (3)$$

对循环自相关函数进一步进行傅里叶变换, 可得到谱相关密度函数:

$$S_s^\alpha(f) = \sum_{i,k} E\{y(i)y^*(k)\} \lim_{T_0 \rightarrow \infty} \frac{1}{T_0} \int e^{i2\pi(f_i-f_k-\alpha)t} dt \times \int_{-\infty}^{\infty} e^{j2\pi(\frac{f_i+f_k}{2}-f)\tau} d\tau \quad (4)$$

其中, α 为循环频率, 用于表征信号中隐含的周期性调制信息。

OFDM 信号因循环前缀与周期导频而在循环

频率 $\alpha = k \cdot \Delta f$ (其中, Δf 为子载波间隔, k 为整数) 及 $\alpha = k/T_u$ (T_u 为有用符号周期) 处呈现特殊谱线。本文通过计算 $S_s^a(f)$ 生成循环谱图 $S_{CS}(\alpha, f) \in R^{H \times W}$ 如图 1 循环谱图部分所示。该图谱可有效表征信号的调制方式、参数配置, 并能够反映 I/Q 失配、载波泄漏和采样抖动等硬件非理想性引入的谱相关特征。

从图 2 循环谱特征可以看出, Mavic Pro 和 MATRICE 600 Pro 因调制信息与参数配置不同, 其循环谱图与 Phantom 4 Pro 存在明显差异, 因此可用于区分这些型号。而 MATRICE 200 虽在调制特征上与 Phantom 4 Pro 相近, 但由于硬件差异所引入的独特指纹特征 (表现为纹理差异), 其循环谱图仍可与 Phantom 4 Pro 有效区分。

1.4 特征融合策略

为充分利用时频分析和循环谱分析的互补优势, 本文采用特征级融合策略, 将两种特征表示在空间维度进行拼接, 构建多域特征张量:

$$F_{fused} = Concat_{Spatial}(S_{TF}, S_{CS}) \quad (5)$$

其中, F_{fused} 表示融合后的特征张量。

在具体实现中, 本文采用分步处理策略, 首先生成无人机的时频图和循环谱图两种互补特征表示, 随后将两种特征图通过尺寸变换统一调整为 $224 \times 224 \times 3$ 的标准格式, 并采用上下拼接方式融合成 $448 \times 224 \times 3$ 的多域特征图。为适配本文提出的 Effiv2KAN 模型中 EfficientNetV2-S 骨干网络的输入规范, 通过双线性插值下采样将融合图统一缩放至 $224 \times 224 \times 3$ 的最终尺寸。该尺寸虽略小于 EfficientNetV2-S 默认的 384×384 输入, 但在计算效率与特征保持之间取得了良好平衡, 如图 3 多域特征融合图所示, 展示了两种型号无人机的融合特征。这一处理流程既保留了各自特征的独立性, 又通过尺寸标准化和空间重组实现了时频特性与循环平稳特性的有效结合, 同时确保了与 Effiv2KAN 模型架构的完全兼容。

2 基于 Effiv2KAN 的无人机射频指纹识别

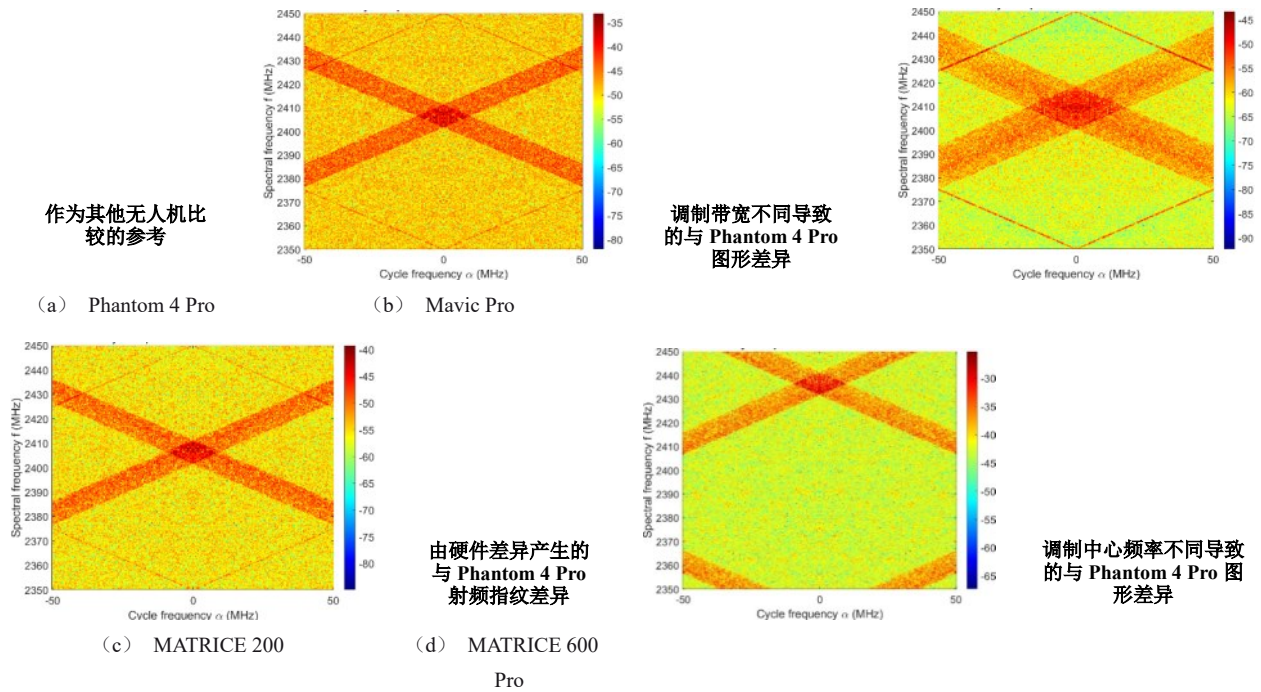


图2 不同型号无人机CSA特征对比

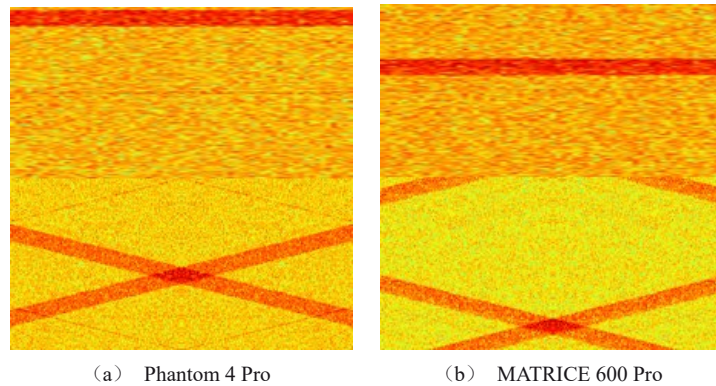


图3 多域特征融合图

算法

本文以 EfficientNetV2-S 模型为基础，借鉴多尺度特征融合的思想，将骨干网络中四个不同层级的特征图进行提取与融合，并在特征融合和分类器中引入 KAN 线性层。Effiv2KAN 模型结构如图 4 所示。

首先，输入为 $224 \times 224 \times 3$ 的射频信号多域特征融合图，该图像由短时傅里叶变换与循环谱分析融合生成，涵盖信号的时频动态特性与调制结构周期性。随后，该图输入至 EfficientNetV2-S 骨干网络进行层级特征提取。网络进一步构建多尺度特征金字塔，从 Stage2、Stage4、Stage5 和 Stage6 提取不同感受野的特征，分别对应信号中的细节纹理、语义信息及全局上下文特征。然后，通过 KAN 特征融合模块对这些多尺度特征进行非线性变换与增强。该模块基于 Kolmogorov-Arnold 表示定理，以可学习的样条函数替代传统多层感知机 (Multilayer Perceptron, MLP) 的固定激活函数，理论上能以更少参数逼近任意高维非线性映射。考虑到不同型号无人机的硬件差异 (功放、晶振等) 会产生高度复杂且

型号特异的高维非线性失真，KAN 通过逐维可学习的非线性函数，能够更精细地建模此类“型号级”非线性特征，从而有效提升不同型号无人机间的区分能力。最后，经由双层 KAN 分类器完成分类决策，输出最终的无人机型号类别概率，进一步发挥 KAN 在非线性和拟合方面的优势。

EfficientNetV2-S 骨干网络通过复合缩放与渐进学习策略，在效率与表达能力之间取得平衡。为兼顾预训练视觉知识的迁移与对射频特征的适配，我们冻结其浅层参数，仅对深层进行微调，以防止过拟合并提升模型泛化能力。引入的 KAN 结构通过样条基函数与可学习缩放因子，增强了对细微射频指纹特征的刻画能力，从而实现多尺度特征的自适应融合与高层次判别特征提取。

2.1 多尺度特征提取模块

多尺度特征提取模块如图 5 所示。该模块以 EfficientNetV2-S 作为骨干网络，从其不同层级提取多层次特征，旨在融合信号中从局部细微差异到全局调制模式的完整信息。具体地，模块分别从 Stage2 (浅层)、Stage4 (中层)、Stage5 和 Stage6 (深层) 提取特征图，对应通道数分别为




图4 Effiv2KAN 模型结构

48、128、160 和 256。浅层特征侧重于刻画时频能量分布等基础动态指纹；中层与深层特征则逐步捕获由硬件非线性、I/Q 失配及符号结构周期性等引入的复杂射频指纹与调制信息。每个特征图经全局平均池化后转换为特征向量，最终拼接构成一个 592 维的融合特征向量，输入后续分类器进行身份判别。该设计实现了对信号多维度、多尺度特性的统一表征，为区分高度相似的无人机射频指纹提供了丰富的特征支持。

2.1.1 EfficientNetV2-S 骨干网络

本算法选用 EfficientNetV2-S 作为特征提取骨干网络，该网络通过复合缩放策略和渐进式学习机制，在计算效率和特征表达能力之间取得了良好平衡。EfficientNetV2 在原有 EfficientNet 的基础上，引入了融合 MBConv 和 Fused-MBConv 的混合架构，通过神经架构搜索技术优化了网络结构，显著提升了训练速度和推理效率^[12]。

针对射频信号多域特征融合图（由 STFT 与 CSA 融合生成）的特点，本文采用多层级特征捕获机制，从网络中间层提取 4 个不同尺度的特征图，其通道数分别为 48、128、160、256。这些特征层分别对应于网络的不同深度，能够从局部瞬态特征到全局调制模式全面捕获信号的多层次信息。

为防止在小规模射频数据集上的过拟合现象，本文采用分层训练策略，对网络前 3 个特征层进行参数冻结，仅对深层特征进行微调训练。这种策略不仅有效利用了 ImageNet 预训练模型的通用视觉知识，还显著减少了可训练参数数量，提升了模型的收敛速度和泛化能力。

特征提取过程可形式化表示为：

$$F_i = \varepsilon_i(X), i \in \{2, 4, 5, 6\} \quad (6)$$

其中， ε_i 表示 EfficientNetV2 的第 i 个特征提取层， F_i 为对应的特征图输出， X 为输入的多域特征融合图像。

2.1.2 特征金字塔构建

为构建兼顾局部细节与全局语义的多尺度特征表示，本文系统性地从 EfficientNetV2-S 骨干网络的不同层级提取特征图，形成层次化的特征金字塔结构。具体地，选取 Stage2、Stage4、Stage5 和 Stage6 作为特征提取层。选择依据如下：

舍弃 Stage1 与 Stage3：Stage1 为网络最浅层，特征图分辨率最高但语义信息极为有限，主要包含边缘、纹理等底层视觉信息，对射频指纹中硬件非线性等高级判别特征的贡献较小，且引入后会显著增加计算冗余；Stage3 在特征层级上与 Stage2 和 Stage4 存在较高的信息重叠，为避免特征冗余并控制融合维度，将其舍弃。

层级互补性设计：所选四个层级在语义层次上形成清晰递进关系，共同构成从微观到宏观的完整特征谱系：

浅层特征（Stage2）通道数 48，包含丰富的空间细节与局部纹理信息。该层特征对捕获时频分量的瞬时能量变化及循环谱中的细微周期模式具有关键作用，为无人机类型识别提供基础判别依据。

中层特征（Stage4）：通道数 128，兼顾局部细节与区域语义信息。该层级在保留必要空间信息的同时，开始形成更具判别性的语义概念，能有效表征调制特性及循环平稳特征中的统计规律。

深层特征（Stage5-Stage6）：通道数分别为 160 与 256，包含高级语义信息与全局上下文特征。虽然空间分辨率较低，但具有最强的语义表达能力，能从宏观上整合融合图像的整体模式，捕获不同无人机射频指纹的确定性判别特征。

2.1.3 特征聚合策略

为实现多尺度特征的有效融合，本文设计了层次化的特征聚合策略。该策略通过全局平均池化操作将空间特征转换为通道特征向量，并采用通道拼接方式构建统一的特征表示。



对于从 EfficientNetV2 骨干网络提取的第 i 个特征图，其全局平均池化过程定义为：

$$f_i = GAP(F_i) = \frac{1}{H \times W} \sum_{h=1}^H \sum_{w=1}^W F_i(h, w) \quad (7)$$

其中， F_i 表示第 i 个输入特征图， H 和 W 分别表示特征图的高度和宽度尺寸， h 和 w 分别为特征图高度和宽度方向的索引变量， GAP 表示平均池化算子。

在获得四个层级 ($i=2, 4, 5, 6$) 的特征向量后，采用通道拼接策略进行特征融合：

$$f_{fused} = Concat(f_2, f_4, f_5, f_6) \in R^{592} \quad (8)$$

该融合过程将浅层细节特征（48 维）、中层语义特征（128 维）以及深层上下文特征（160 维和 256 维）在通道维度上进行集成，构建出包含 592 个特征的复合表征向量。这种特征聚合策略不仅保留了各尺度特征的判别信息，还通过跨层级的特征交互增强了射频指纹特征的表达能力，为后续的 KAN 非线性变换提供了丰富的输入基础。

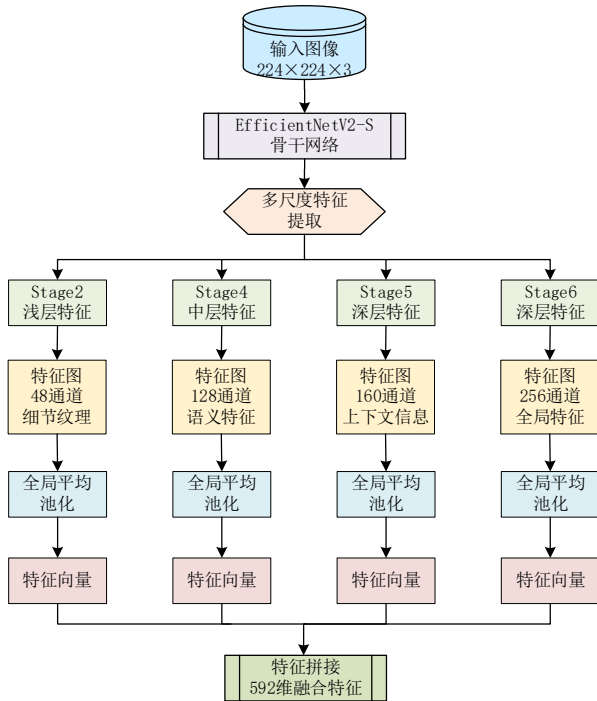


图5 多尺度特征提取模块

2.2 特征融合模块

特征融合模块如图 6 所示，在通过拼接获得多尺度融合特征 f_{fused} 后，需对该特征进行非线性变换与增强，以提炼出更具判别性的高级表征。本文设计了一个特征融合模块，其核心是基于 Kolmogorov-Arnold 表示定理的 KAN 线性层。

该模块的变换过程可形式化表示为：

$$h = KANLinear_{592 \rightarrow 1024}(f_{fused}) \quad (9)$$

其中，表示从 592 维到 1024 维的 KAN 线性变换。

KAN 线性层通过结合基础线性变换与可学习的样条函数，提供了强大的非线性拟合能力。其核心计算机制如下：

$$KANLinear(x) = BaseOutput + SplineOutput \quad (10)$$

具体而言：

$$BaseOutput = SiLU(x) \cdot W_{base} \quad (11)$$

$$SplineOutput = BSplines(x) \cdot W_{spline} \cdot S_{spline} \quad (12)$$

其中， W_{base} 表示基础权重矩阵， W_{spline} 为样条权重张量， S_{spline} 为样条缩放因子， $SiLU$ 为 Sigmoid 线性单元激活函数， $BSplines$ 表示 B 样条基函数计算模块

为进一步提升特征质量与模型鲁棒性，在 KAN 线性变换后，本模块依次引入了层归一化 (LayerNorm)、ReLU 激活函数以及丢弃率为 0.3 的 Dropout 正则化。层归一化确保特征分布的稳定性，ReLU 激活进一步增强非线性，Dropout 机制则有效抑制过拟合。

该特征融合模块通过对拼接后的多尺度特征进行非线性变换与正则化处理，实现了特征的深度整合与升华，为后续分类器提供了判别性更强的输入特征。

2.3 分类决策模块

分类决策模块如图 7 所示，该模块为 EfficNetV2KAN 模型的最终处理阶段，负责将经过特征融合的高维特征映射到具体的类别空间。本文采用双层 KAN 结构构建分类器，充分利用




图6 特征融合模块

Kolmogorov-Arnold 网络的强大非线性拟合能力，显著提升了模型对复杂射频指纹特征的分类性能。

第一层 KAN 变换的主要功能是对 1024 维输入特征进行降维和初步非线性变换，经过变换后的特征向量为：

$$z_1 = \text{LayerNorm}(\text{ReLU}(\text{KANLinear}_{1024 \rightarrow 512}(h))) \quad (13)$$

其中， h 表示特征融合模块输出的高级特征向量， $\text{KANLinear}_{1024 \rightarrow 512}$ 表示从 1024 维到 512 维的 KAN 线性变换层，ReLU 修正线性单元激活函数，引入非线性变换，LayerNorm 为层归一化操作，稳定特征分布。

第二层 KAN 分类直接将 512 维特征映射到最终的类别概率分布，完成分类决策：

$$\hat{y} = \text{KANLinear}_{512 \rightarrow N}(z_1) \quad (14)$$

其中， $\text{KANLinear}_{512 \rightarrow N}$ 表示从 512 维到 N 维的 KAN 线性分类层， \hat{y} 表示输出的概率分布， N 为无人机类别数量。

该分类层直接输出每个类别的原始分数，后续通过 Softmax 函数转换为概率分布：

$$p_i = \frac{\exp(\hat{y}_i)}{\sum_{j=1}^N \exp(\hat{y}_j)}, i = 1, 2, \dots, N \quad (15)$$

该双层 KAN 分类结构能灵活拟合射频指纹中的复杂非线性模式，显著增强模型在信噪比变化及型号相似场景下的判别鲁棒性。

3 实验结果与分析

3.1 数据集与实验环境

实验所用服务器 GPU 为 NVIDIA GEFORCE RTX 3090，Ubuntu 版本为 22.04.4，深度学习框架为 Pytorch，训练采用 AdamW 优化器，初始学习率为 0.0001，批量大小设置为 64，共训练 30 个 epoch。针对数据集类别不平衡问题，采用逆频率加权交叉熵损失函数，并在特征融合层和分类器层分别设置 0.3 和 0.4 的 Dropout 率以防止过拟合。

实验数据集联合源自 DroneRFa^[10] 与 RFUAV^[11] 两个公开数据集。我们从中共同筛选出 19 架包含图传信号的无人机作为信号源，信号采样频率为 100MHz。数据的预处理流程如下：首先，从原始录制信号中截取出仅包含有效 OFDM 调制信号的纯净片段；随后，估计该片段的原始信噪比，并以此为基础，通过添加高斯白噪声，将信号精确调整至目标信噪比等级，其范围覆盖 -20 dB 至 10 dB（步进为 5 dB）。接着，将加噪后的连续信号以不重叠的方式，分割为长度均为 16384 个采样点的样本。对这些样本进行 STFT 分析和 CSA 分析后，构建成最终数据集。最终，为保障数据分布的均衡性，我们在每一个信噪比等级下，将全部样本按 8:1:1 的比例随机划分为训练集、验证集和测试集。

本文信号预处理及特征提取过程均在 MATLAB 2022a 仿真平台上进行，STFT 分析采用 Hamming 窗，窗口长度为 512，重叠长度为




图7 分类决策模块



256, FFT长度为4096; CSA分析采用循环周期图法, 循环频率分辨率为256, FFT长度为1024, 分析窗口选用Hamming窗, 窗口长度为256, 循环频率范围为 $[-50, 50]$ MHz, 通过频移信号的STFT乘积计算循环周期图, 最终生成 224×224 像素的彩色时频图和循环谱图用于后续深度学习模型训练。

3.2 特征可视化分析

在信噪比为10dB的环境下, 对本文提出的Effiv2KAN网络进行特征注意力图的可视化

分析, 以直观展现模型对射频指纹特征的学习与关注模式。将该可视化结果与原始EfficientNetV2网络和ResNet18网络进行对比, 如图8所示。热力图中的深色(高激活)区域表征模型在分类决策过程中重点关注的时频或循环谱特征区域, 这些区域反映了模型从信号中提取的关键身

份判别信息。

图8(a)为时频-循环谱融合特征图, 直观展示了从原始射频信号中提取的多域特征表示。图(b)、图(c)、图(d)分别为基于该融合特征图在Effiv2KAN、EfficientNetV2以及VGG19模型下生成的特征注意力热力图。通过对比三个模型的热力图可视化结果, 可以分析不同网络架构对多域特征的关注模式差异。从矩形框标注的关键区域可以看出, EfficientNetV2模型(图c)存在注意力偏移问题, 大部分关注点落在非特征区域; VGG19模型(图d)的关注点主要集中在循环谱特征部分, 对时频特征的关注相对不足。相比之下, 本文提出的Effiv2KAN模型(图b)展现出更加均衡的特征关注模式, 其注意力同时覆盖了时频特征和循环谱特征两个关键区域, 体现了多域特征融合的优势。这种全面的关注模式

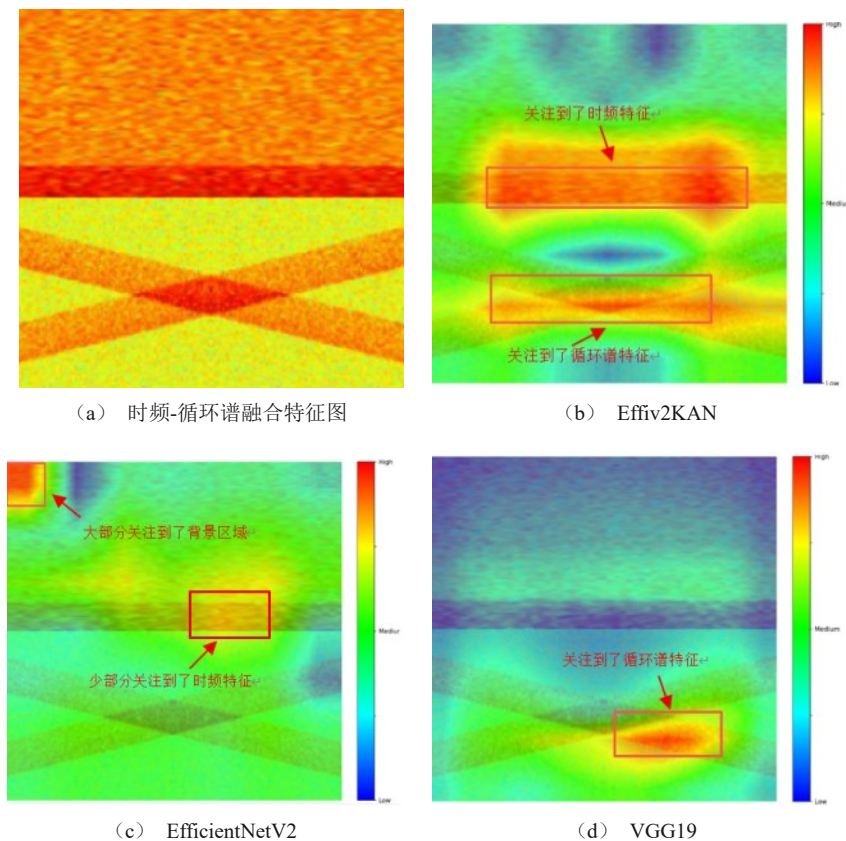


图8 特征可视化对比

减少了单一特征域导致的注意力偏移，使模型能够更准确地捕捉到设备的身份判别信息，从而提升了识别性能。

3.3 特征提取对比实验结果与分析

为评估所提算法的性能，本文设计了系统的对比实验。我们将所提出的时频-循环谱融合特征 (STFT+CSA) 与 Effiv2KAN 模型相结合的方法，与现有文献中采用的典型方法 (STFT+ResNet18^[10]与 STFT+VGG16-LR^[8]) 进行对比。同时，为分别验证特征融合与模型改进的独立贡献，增设了单一特征结合本模型 (STFT+Effiv2KAN、CSA+Effiv2KAN) 作为对照。

图9详细展示了不同方法在-20dB至10dB信噪比范围内的识别准确率对比。综合分析实验数据，可以得出以下结论：首先，本文所提出的 (STFT+CSA)融合特征与 Effiv2KAN 模型相结合的方法，在所有测试信噪比条件下均取得了最优性能，尤其在-5dB及以上高信噪比环境下，准确率显著领先于其他对比方法，并于10dB时达到99.33%的最高准确率，充分证明了其卓越的识别能力。其次，通过特征有效性的纵向对比发现，在相同 Effiv2KAN 模型下，采用融合特征 (STFT+CSA) 的准确率全程明显高于仅使用

STFT或CSA单一特征的方法，这证实了时频域与循环谱域特征融合对于捕捉更全面、更鲁棒的调制特征和射频指纹具有关键作用。最后，与传统方法相比，本文提出的 (STFT+CSA)+Effiv2KAN方法在所有信噪比条件下均展现出绝对性能优势。这充分证明，本文所提出的融合特征与改进模型相结合的策略，有效解决了传统方法在多无人机场景下辨识能力不足的核心痛点，展现出显著的实用价值。

3.4 模型对比实验结果与分析

为公平评估模型架构的性能，在相同的 (STFT+CSA) 融合特征输入下，将本文的 Effiv2KAN 模型与多种主流深度学习模型进行对比，包括：EfficientNetV2^[12]，Vision Transformer (ViT)^[13]，Swin Transformer (Swin)^[14]，VGG19^[15]，ResNet18^[16]与 MobileNet^[17]。实验统计了各模型在不同信噪比下的平均识别率。

不同信噪比下各模型对比如图10所示，综合分析可知，本文提出的 Effiv2KAN 模型在所有测试信噪比条件下均展现出显著的性能优势，其识别准确率全面且大幅领先于所有对比模型。在低信噪比条件下，Effiv2KAN的识别率远高于其他模型，在-10dB时已达40.77%，而多数对比模型




图9 不同方法在不同信噪比下的对比



仍低于20%，随着信噪比提升，该模型性能持续领先，并在10dB时达到了99.33%的最高准确率，展现出对微弱指纹特征卓越的辨识能力与鲁棒性。在对比模型中，VGG19表现相对最佳，但与其与Effiv2KAN的差距仍显著，在10dB时仍相差约6.43个百分点。EfficientNetV2与MobileNet等轻量化模型在本任务中表现较差，在-10dB及更低的信噪比环境下识别率始终低于5%，直至0dB以后才逐步提升，反映出其在低信噪比复杂电磁环境中识别能力的不足。该结果充分证明，在多无人机的识别场景下，本文所设计的Effiv2KAN模型相较于现有主流模型具有更优的识别性能。

3.5 复杂电磁环境下的对比实验

为了验证模型在复杂电磁环境中的适应能力，在原始信号中分别引入多径效应（两径模型）和同频干扰（WiFi信号）开展对比实验。结果表明，采用多域融合特征并结合Effiv2KAN的模型在两种环境下均表现最优。在多径环境中（图11），该模型在各信噪比下准确率均领先，0dB以上保持高位，抗多径能力突出；而使用相同特征的VGG19模型虽在中高信噪比有所提升，但低信噪比稳定性较差。在同频干扰环境中（图12），Effiv2KAN同样展现最佳鲁棒性，性能始

终优于其他对比模型；仅依赖STFT时频图的ResNet18和VGG16-LR模型则性能明显偏低，低信噪比下准确率不足0.1，说明单一时频特征难以应对复杂电磁环境。综上，多域融合特征增强了信号判别信息，Effiv2KAN具备更强的非线性建模能力，使所提方法在多径和同频干扰下仍能保持高而稳定的识别准确率，验证了其在多无人机型号识别中的有效性与鲁棒性。

3.6 消融实验

为了验证所提方法的可行性，并分析改进结构在性能改善中的作用，选择10dB作为典型信噪比条件进行消融实验，实验结果见表1。

从表1可以看出，基线模型的识别准确率为51.71%，性能相对较低。其原因主要在于：EfficientNetV2作为通用图像分类网络，其设计初衷是针对自然图像的语义特征，而射频信号的多域融合图像具有高度抽象且非线性耦合的特性。仅依赖网络末端的单层高层特征，难以充分捕获射频指纹中从局部瞬时能量变化到全局调制周期模式的多尺度信息，尤其对于不同型号无人机硬件非线性带来的细微但关键的判别特征，单尺度特征表达能力不足。此外，基线模型采用MLP分类器，其固定激活函数在拟合射频指纹复杂高维非

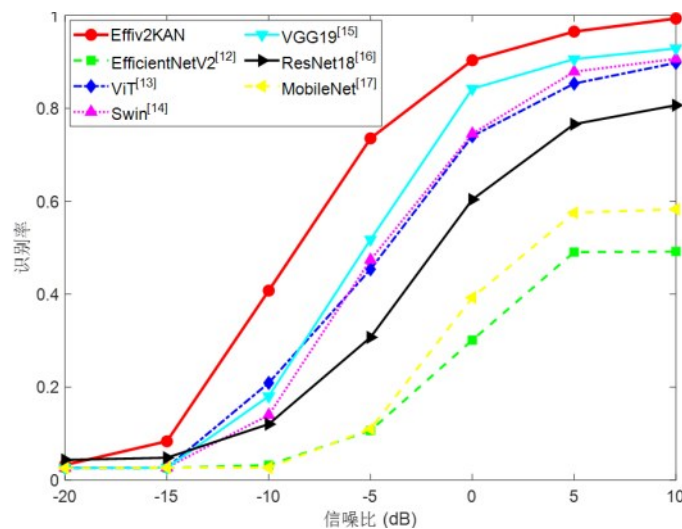


图10 不同信噪比下各模型对比




图11 不同方法多径环境下的对比




图12 不同方法在同频干扰环境下的对比

线性分布时存在局限性，进一步限制了识别性能。

表1 各改进模块消融实验结果

EfficientNetV2	多尺度特征融合	KAN分类器	准确率
√	—	—	51.71% (基线模型)
√	—	√	52.38%
√	√	—	98.55%
√	√	√	99.33% (Effiv2KAN)

为验证层级选择的合理性，本文设计了10 dB信噪比下的特征层级消融实验，对比不同层级组合下的识别性能与参数量，结果见表2。实验结果表明，本文所选组合在准确率与参数量之间取得了最佳平衡。增加Stage1或Stage3虽然略微提升参数量，但准确率均出现下降，说明浅层特

征引入了冗余信息，干扰了深层判别特征的学习；而全部6层组合参数量最大，准确率最低，进一步印证了信息冗余的负面影响。相比之下，仅保留深层特征虽参数量略低，但准确率显著低于本文方案，表明缺少中层语义特征Stage2导致细节信息丢失。因此，本文所选的Stage2、Stage4、Stage5、Stage6四层特征组合在精度与效率间达到了最优权衡。

表2 特征层级选择消融实验

层级组合	参数量 (M)	准确率
Stage2 + Stage4 + Stage5 + Stage6 (本文)	30.44	99.33%
Stage1 + Stage2 + Stage4 + Stage5 + Stage6	30.66	98.65%
Stage1 + Stage3 + Stage4 + Stage5 + Stage6	30.81	98.29%
全部6层 (Stage1-6)	31.47	97.88%
Stage4 + Stage5 + Stage6 (无浅层)	30.00	98.13%

为探究特征融合层与分类器层中Dropout率对模型泛化能力的影响，本文在0dB信噪比条件下设计了多组对比实验，如表3所示。实验结果表明，当特征融合层Dropout率为0.3、分类器层Dropout率为0.4时，模型在验证集上取得了最高的准确率和F1值，同时训练-验证差距最小，说明该组合在防止过拟合与保持模型拟合能力之间达到了最佳平衡。相比之下，过低的Dropout率或过高的Dropout率均会导致验证性能下降或训练-验证差距增大，验证了本文所选参数在0dB信噪比环境下的有效性。

3.7 不同模型性能与效率对比

在0 dB条件下对Effiv2KAN与主流模型进

表3 不同Dropout率组合的消融实验

特征融合层Dropout	分类器层Dropout	验证集准确率	验证集F1	训练-验证差距
0.2	0.3	0.9219	0.9257	0.0140
0.3	0.3	0.9223	0.9264	0.0153
0.3(本文)	0.4(本文)	0.9242	0.9274	0.0041
0.4	0.4	0.9195	0.9233	0.0197
0.4	0.5	0.9200	0.9233	0.0160



行了系统对比，如表4所示。Effiv2KAN表现优异：Top-1 Acc 达 92.73%，显著高于其他模型；Macro/Micro F1 分别为 0.9308 和 0.9273，均居首位，表明其抗噪声能力强且分类均衡。值得注意的是，Effiv2KAN 和 VGG19 的 Top-5 Acc 均达到 100%，说明在噪声环境下，尽管模型对最高置信度类别的判断可能存在不确定性，但正确答案始终位于前 5 个预测中，反映出两类模型均具备较强的预测鲁棒性和容错能力。参数量方面，Effiv2KAN 略高于 EfficientNetV2，但仍显著低于 VGG19 和 ViT；FLOPs 与 EfficientNetV2 基本持平，远低于 VGG19 和 Swin。推理速度上，Effiv2KAN 优于 VGG19 和 ViT，与 Swin 相当。轻量模型如 ResNet18 虽速度更快，但精度远低于 Effiv2KAN，无法在噪声环境中可靠工作。综上，Effiv2KAN 实现了精度、效率与实时性的最佳平衡，满足多无人机型号实时识别需求，具备工程部署潜力。

0dB 信噪比条件下，混淆矩阵如图 13 所示，本文 19 类无人机识别模型取得 90.36% 的总体准确率，整体性能良好，但归一化混淆矩阵显示，部分型号间仍存在显著特征混淆，这类误判源于信号内在相似性。

误判主要集中在：DJI MAVIC3 PRO 有 35% 样本被误判为 Mini 2，Mini 2 仅 47% 样本被正确识别、51% 被误判为 Phantom 4 Pro，同时存在 Phantom 4 Pro 与 MATRICE 200、Air 2S 与 Mini 3

Pro 的双向交叉误判。这类混淆的本质原因是：在低信噪比下，混淆型号的调制参数，如 OFDM 配置、信号带宽等高度接近，加之同源射频硬件带来的射频指纹差异极小，进一步削弱了模型的判别能力。

4 结束语

针对多无人机场景下，单一特征域难以全面、稳健表征设备身份的根本局限，本文提出一种融合时频与循环谱特征并采用 Effiv2KAN 模型的多无人机型号识别方法。通过构建多域融合特征图像，克服了单一特征在低信噪比条件下表征不完整、区分度不足的局限；设计以 EfficientNetV2 为骨干网络、Kolmogorov-Arnold 网络为分类器的 Effiv2KAN 模型，增强了对细微指纹特性的非线性建模能力；结合多层次特征融合与自适应归一化机制，提升了模型在噪声环境下的特征鉴别力。实验表明，该方法在不同信噪比下均优于现有主流模型，在保持较高推理效率的同时，显著提升了识别准确率与泛化能力，为复杂电磁环境下的无人机身份认证提供了有效的技术途径。

表4 不同模型在 0 dB 条件下的性能与效率对比

模型	Top-1 Acc	Top-5 Acc	Macro F1	Micro F1	参数量(M)	FLOPs (G)	推理时间(ms/img)	FPS
Effiv2KAN	92.73%	100.00%	0.9308	0.9273	30.44	2.91	2.61	383.14
EfficientNetV2	29.31%	71.64%	0.2823	0.2931	21.46	2.90	2.67	374.32
VGG19	83.99%	100.00%	0.8452	0.8399	143.67	19.63	3.78	264.82
ViT	74.20%	98.95%	0.7405	0.7420	86.42	16.86	3.5	285.51
Swin	74.58%	99.67%	0.7473	0.7458	28.27	4.37	2.51	397.70
ResNet18	61.40%	95.20%	0.6057	0.6140	11.69	1.82	1.78	560.60
MobileNet	37.43%	82.47%	0.3470	0.3743	5.48	0.23	2.22	449.82

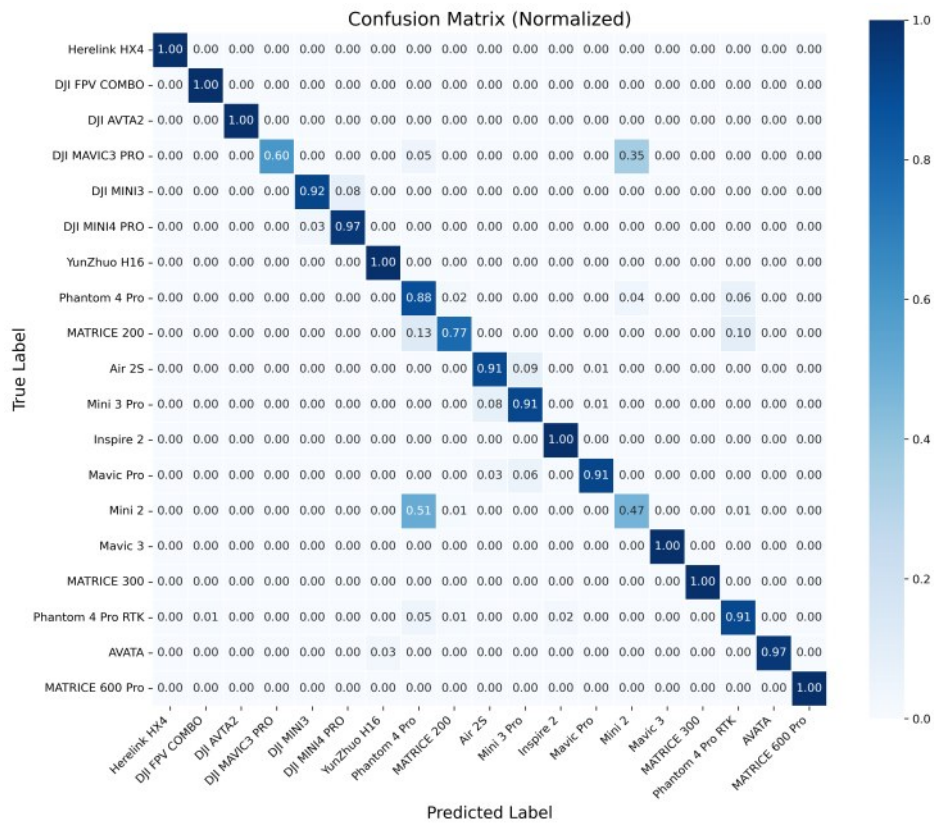


图13 混淆矩阵

参考文献:

[1] Hussain S, Chaudhry S A, Alomari O A, et al. Amassing the security: An ECC-based authentication scheme for Internet of Drones[J]. IEEE Systems Journal, 2021, 15(3): 4431-4438.

[2] Pham Q V, Huynh-The T, Alazab M, et al. Sum-rate maximization for UAV-assisted visible light communications using NOMA: Swarm intelligence meets machine learning[J]. IEEE Internet of Things Journal, 2020, 7(10): 10375-10387.

[3] Yaacoub J P, Noura H, Salman O, et al. Security analysis of drones systems: Attacks, limitations, and recommendations[J]. Internet of Things, 2020, 11: 100218.

[4] 王豪, 罗俊松, 王惠明. 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 H, LUO J S, WANG H M. Review of UAV RF Fingerprint Identification Methods[J]. Radio Engineering, 2024, 54 (11): 2672-2684.

[5] 邓涵方. 基于深度学习的射频指纹识别技术研究[D]. 桂林电子科技大学, 2022.

DENG H F. Research on RF fingerprint identification technology based on deep learning[D]. Guilin: Guilin University of

Electronic Technology, 2022.

[6] Zhang Y. RF-based drone detection using machine learning[C]// 2021 2nd International Conference on Computing and Data Science (CDS). IEEE, 2021: 425-428.

[7] 李超群, 王金明. 基于短时傅里叶变换的无人机射频指纹分类识别[J]. 通信技术, 2022, 55(9): 1202-1207.

LI C Q, WANG J M. Classification and Identification of UAV RF Fingerprints Based on Short-Time Fourier Transform[J]. Communication Technology, 2022, 55(9): 1202-1207.

[8] Swinney C J, Woods J C. Unmanned aerial vehicle flight mode classification using convolutional neural network and transfer learning[C]// 2020 16th International Computer Engineering Conference (ICENCO). IEEE, 2020: 83-87.

[9] Zhang H, Li T, Su N, et al. Drone identification based on normalized cyclic prefix correlation spectrum[J]. IEEE Transactions on Cognitive Communications and Networking, 2024, 10 (4): 1241-1252.

[10] 俞宁宁, 毛盛健, 周成伟, 等. DroneRFa: 用于侦测低空无人机的大规模无人机射频信号数据集[J]. 电子与信息学报, 2024, 46(4): 1147-1156.

YU N N, MAO S J, ZHOU C W, et al. DroneRFa: A Large-



- Scale UAV RF Signal Dataset for Low-Altitude Drone Detection[J]. Journal of Electronics & Information Technology, 2024, 46(4): 1147-1156.
- [11] Shi R, Yu X, Wang S, et al. RFUAV: A Benchmark Dataset for Unmanned Aerial Vehicle Detection and Identification[J]. arXiv preprint arXiv:2503.09033, 2025.
- [12] Tan M, Le Q. Efficientnetv2: Smaller models and faster training [C]//International conference on machine learning. PMLR, 2021: 10096-10106.
- [13] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16x16 words: Transformers for image recognition at scale[J]. arXiv preprint arXiv:2010.11929, 2020.
- [14] Liu Z, Lin Y, Cao Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]//Proceedings of the IEEE/CVF international conference on computer vision. 2021: 10012-10022.
- [15] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J]. arXiv preprint arXiv:1409.1556, 2014.
- [16] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2016: 770-778.
- [17] Howard A, Sandler M, Chu G, et al. Searching for mobilenetv3 [C]//Proceedings of the IEEE/CVF international conference on computer vision. 2019: 1314-1324.

[作者简介]



崔亚民（1995—），男，研究生，杭州电子科技大学，学生，主要研究方向为信号处理。



王首斌（1984—），男，博士，中国电子科技集团公司第三十六研究所，高级工程师，主要研究方向为电子战系统总体技术。



沈雷（1979—），男，博士，杭州电子科技大学，教授，主要研究方向为图像处理和信号处理。