

文章编号: 1671-7449(2026)01-0034-11

J. Test Measur. Technol., 2026, 40(1): 34-44.

基于时频多通道特征的无人机信号 智能识别方法

白建胜, 李琼怡, 姚金杰, 王黎明*

(中北大学 智能探测技术与装备山西省重点实验室, 山西 太原 030051)

摘要: 针对复杂空域环境中快速机动、型号各异的无人机目标的精准感知需求, 提出一种基于时频多通道特征的无人机信号识别方法。信号处理部分, 首先对无人机信号去趋势化去噪, 消除直流分量和低频漂移从而降低频域干扰, 然后, 利用离散傅里叶变换获取时频信息, 通过频谱拼接与振幅归一化构建能量频谱数据, 针对其空间异质性沿频域进行多特征通道处理。模型部分, 基于多通道二维卷积模型(MC-2DCNN)提出多特征通道信号张量化处理策略, 精准适配模型卷积特性。通过频域特征的空间解耦与结构化重组, 在保障特征拓扑邻接关系的同时借助通道分离机制实现了跨频段特征的层次化提取和差异化建模, 增强了模型鲁棒性和泛化性。实验表明, 所提方法在-10~10 dB噪声范围内对机型与飞行模式的识别准确率分别达到98.15%和96.32%, 在电磁噪声、梳状谱和阻塞式干扰的混叠噪声场景下识别准确率可达91.97%和90.56%, 满足军民领域无人探测系统的智能识别需求。

关键词: 射频信号感知; 多通道特征; 无人机识别; 时频变换

中图分类号: TN92

文献标识码: A

DOI: 10.62756/csjs.1671-7449.2026042

引用格式: 白建胜, 李琼怡, 姚金杰, 等. 基于时频多通道特征的无人机信号智能识别方法[J]. 测试技术学报, 2026, 40(1): 34-44.

BAI Jiansheng, LI Qiongyi, YAO Jinjie, et al. Intelligent recognition method of UAV signal based on time frequency multi channel features[J]. Journal of Test and Measurement Technology, 2026, 40(1): 34-44.

Intelligent Recognition Method of UAV Signal Based on Time Frequency Multi Channel Features

BAI Jiansheng, LI Qiongyi, YAO Jinjie, WANG Liming*

(Shanxi Key Laboratory of Intelligent Detection Technology & Equipment, North University of China, Taiyuan 030051, China)

Abstract: To address the need for precise perception of rapidly maneuvering and diverse unmanned aerial vehicle (UAV) models in complex airspace environments, a UAV signal recognition method based on time-frequency multi-channel features is proposed. In the signal processing stage, the UAV signals undergo detrending and denoising to eliminate direct current components and low-frequency drift, thereby

【收稿日期】2025-08-27

【基金项目】国家自然科学基金资助项目(62571496); 中国博士后科学基金资助项目(2024M763034, GZC20241568); 山西省基础研究计划资助项目(202403021222150); 山西省重点研发计划资助项目(202202010101009, 202402120101010); 仪器科学与动态测试教育部重点实验室基金资助项目(JYBSYSKFJJ319005)

【作者简介】白建胜(1995—), 男, 讲师, 博士, 主要从事电磁信号智能感知。E-mail: baijs95@163.com。

*【通信作者】王黎明(1974—), 男, 教授, 博士, 主要从事无损检测与图像处理研究。E-mail: wlm@nuc.edu.cn。

reducing frequency-domain interference. The discrete Fourier transform is then applied to extract time-frequency information, followed by spectrum splicing and amplitude normalization to construct energy spectrum data. To address spatial heterogeneity, multi-channel processing is performed along the frequency domain. For the model architecture, a multi-feature channel signal tensorization strategy is proposed based on an MC-2DCNN, precisely aligning with the model's multi-channel convolutional characteristics. Through spatial decoupling and structured reorganization of frequency-domain features, hierarchical extraction and differentiated modeling of cross-band features are achieved while preserving feature topological adjacency, leveraging channel separation mechanisms to enhance model robustness and generalization. Experiments demonstrate that the proposed method achieves recognition accuracies of 98.15% and 96.32% for UAV models and flight modes, respectively, within the -10 dB to 10 dB noise range. Under aliasing noise scenarios involving electromagnetic noise, comb spectrum, and blocking interference, it attains accuracies of 91.97% and 90.56%, meeting intelligent recognition requirements for UAV detection systems in both civilian and military applications.

Key words: radio frequency signal perception; multi-channel features; unmanned aerial vehicle recognition; time-frequency transform

0 引言

无人机(Unmanned Aerial Vehicle, UAV)信号识别是通过对接收信号智能处理从而实现空域“滥飞黑飞”无人机目标高效精准感知的方法^[1]。该方法相比传统雷达探测具有环境依赖性低、成本低的优势,因此,在维护电磁频谱秩序^[2]、保障低空空域安全和智慧城市管理^[3]等军民领域具有广阔前景。

目前,无人机识别可以分为基于视觉、声学、雷达和射频的检测技术。视觉检测技术通过摄像头或红外成像设备捕捉无人机图像,然后利用图像处理算法识别无人机的外形特征或运动轨迹,但是面临高速移动目标和在复杂气象干扰下性能下降明显^[4]。声学检测利用高灵敏度麦克风阵列采集无人机螺旋桨或电机产生的声音信号,通过音频特征识别无人机,但是环境噪声(如风声)严重影响信噪比,且有效信号容易被主动降噪技术滤除^[5-6]。雷达发射电磁波并接收反射信号,通过分析回波的时频特性来全天候探测无人机,但是雷达除了背景杂波干扰大和反射截面小之外,高额成本也限制了其适用范围^[7]。射频识别通过监听无人机与遥控器之间的通信链路信号(如WiFi、GPS或专用频段),分析频谱模式或数据流量特征,结合先进信号处理算法实现无人机信号的高效识别^[8-10]。随着深度学习方法的发展,射频识别融合智能算法为无人机信号智能识别提供了

新的研究思路^[11]。

基于以上研究,本文提出一种基于时频多通道特征的无人机信号智能识别方法,通过捕获和分析无人机与遥控器/手机APP之间的无线通信链路信号,实现对无人机具体机型和飞行模式的识别。该方法的核心是融合射频信号处理和智能模型,构建一个精准的信号识别方法,实现复杂空域环境中快速机动、型号各异的无人机目标精准感知,为无人机军民应用领域提供可靠的技术支持。

1 无人机射频信号智能识别方法

本文提出基于时频多通道特征的无人机信号智能识别方法,具体流程包括:1)基于软件无线电的无人机信号接收和采集方法;2)对接收信号进行预处理,通过对信号去趋势化去噪处理,消除射频信号中的直流分量和低频漂移,避免对频域干扰,利用离散傅里叶变换进行信号时频转换,并将高低频段的单边频谱进行多通道拼接,再通过振幅归一化得到多特征通道的信号能量频谱数据,之后将能量频谱沿频域维度划分连续子通道;3)设计基于多通道二维卷积神经网络模型(MC-2DCNN)对多特征通道时频特性进行跨频段特征的层次化提取和差异化建模,实现对无人机信号的高精度识别;4)采用DroneRF无人机射频数据集在不同噪声干扰下进行实验验证。所提方法流程如图1所示。




图 1 无人机射频信号智能识别方法流程
Fig. 1 Block of intelligent identification method for UAV RF signal

1.1 基于软件无线电的无人机信号获取

为实现对无人机射频信号的完整覆盖, DroneRF 数据集采用分频段接收方案, 通过 NI-USRP-2943R 软件定义无线电设备采用双通道接收模式采集射频信号(高低频段), 其最大瞬时带宽为 40 MHz, 覆盖频率范围 1.2 MHz~6 GHz, 频率步进精度 1 kHz, 设备配置动态增益范围(-10~50 dB), IQ 采样率 200 MS/s, ADC 分辨率 16 位, 以确保信号瞬态特征的完整表征。采集过程记录射频本底噪声信号, 随后对无人机的 4 个标准操作模式(包括静态、自主悬停、无视频采集飞行以及视频录制飞行)进行采集。数据采集通过基于 LabVIEW 开发的实时射频信号捕获程序实现。

1.2 无人机射频信号预处理

1.2.1 基于去趋势化的信号去噪

针对无人机采集的射频信号存在的非平稳和含趋势特性, 为消除信号中的直流分量和低频漂移, 避免其对后续频域分析造成干扰, 引入连续去趋势化(Detrended Fluctuation Analysis, DFA), 通过分段去趋势提取信号波动特性。通过量化信号在去除局部趋势后的波动强度, 更好地呈现信号内在特征。首先, 将原始信号序列 $x(i)$ 转换为随机行走过程

$y(k)$, 消除均值并减小非平稳性的影响。

$$y(k) = \sum_{i=1}^k [x(i) - \langle x \rangle]. \quad (1)$$

将积分后的序列 $y(k)$ 分成等长子区间, 为了充分利用数据, 从序列首尾分别进行分段。在每个信号子区间内, 通过局部二次多项式拟合计算出局部趋势 $Y_{fit}(k)$, 然后, 从原始积分序列中减去局部趋势 $Y_{fit}(k)$, 得到对应的波动函数。

$$F(v, s) = Y(v) - Y_{fit}(v), \quad (2)$$

式中: s 为子区间窗口大小; v 为信号分段的窗口索引。进一步通过波动函数计算每个信号子区间去趋势后信号序列的均方根值, 作为该区间的信号幅度波动强度, 并表示为

$$x(s) = \sqrt{\frac{1}{N_s} \sum_{v=1}^{N_s} [F(v, s)]^2}, \quad (3)$$

式中: $x(s)$ 为信号幅度强度; N_s 为信号段样本的总数。选择 Phantom 无人机信号进行 DFA 处理, 结果如图 2 所示。

分析可知, 图 2(a) 结果清晰呈现了低频 $x(L)$ 和低频 $x(H)$ 的信号幅度特征, 有明显的周期性调制特性及规律性脉冲结构。图 2(b) 为经过 DFA 处理后对时域数据中的杂波噪声滤除效果, 在概率分布上解决了噪声带来的分布不均

匀,能够更好地刻画无人机信号的关键信息。




图 2 DFA 处理 Phantom 无人机信号结果分析

Fig. 2 Analysis of DFA processing phantom UAV signal results

1.2.2 基于离散傅里叶变换的频谱分析

将经 DFA 处理的无人机低频和高频信号幅度强度 $x(s)$ 分割为等长子区间,按照式(4)和式(5)对各区间信号进行离散傅里叶变换,并将低频段 $y_i^{(L)}$ 和高频段 $y_i^{(H)}$ 的单边频谱数据拼接为完整频谱。

$$y_i^{(H)}(m) = \sum_{n=1}^N x_i^{(H)}(n) e^{-\frac{j2\pi m(n-1)}{N}}, \quad (4)$$

$$y_i^{(L)}(m) = \sum_{n=1}^N x_i^{(L)}(n) e^{-\frac{j2\pi m(n-1)}{N}}, \quad (5)$$

式中: $x_i^{(L)}$ 和 $x_i^{(H)}$ 分别为 DFA 处理的低、高频信号幅度强度; $y_i^{(L)}$ 和 $y_i^{(H)}$ 分别为离散傅里叶变换结果; N 为信号区间 i 中的时间样本总数; m 为频率索引; n 为时间索引。

为消除无线电设备间增益差异,确保拼接后频谱连续平滑,按照式(6)计算低频段末尾样本与高频段起始样本的能量比值 c ,通过归一化将幅度

谱化为能量谱。

$$c = \sum_{q=0}^{Q-1} y_i^{(L)}(1023-q) / \sum_{q=0}^{Q-1} y_i^{(H)}(q). \quad (6)$$

综上,噪声信号和无人机信号的频谱分析处理结果如图 3 所示。




图 3 噪声信号与 Phantom 无人机信号经处理的频谱数据

Fig. 3 Spectral data processed from noise signals and Phantom drone signals

分析图 3 结果可知,通过基于离散傅里叶变换的频谱分析得到的频谱数据能够更好地刻画无人机信号细微特征。进一步选取 AR 和 Bebob 两种无人机的 4 个标准操作模式(静态、自主悬停、无视频采集飞行和视频录制飞行)进行频谱分析,结果如图 4 和图 5 所示,证明所提方法能够凸显不同无人机信号的能量频谱空间异质性特征。

1.2.3 无人机频谱数据多特征通道处理

无人机信号频谱数据覆盖整个无人机链路带宽,若无人机信号采样频率为 F_s ,则频谱分辨率表示为 $\Delta f = F_s/n$, n 为采样点数。设完整带宽频谱为向量 $Y \in \mathbb{R}^n$,表示为 $Y = [y_0, y_1, \dots, y_n]$ 。针对无人机信号在能量频谱数据表现出的空间异质性特征,将频谱信号 Y 沿频域维度均匀划分为 8 个连续子通道频段,每个通道包含 $n/8$ 个采样点,得到含多特征通道的频谱数据表示为

$$Y_i = [y_{0 \times (n/8)}, y_{1 \times (n/8)}, \dots, y_{i \times (n/8)}], \quad (7)$$

式中: Y_i 为第 i 个频率点的幅度值; i 为通道索引; $Y \in \mathbb{R}^{n/8}$ 。为实现神经网络对多通道特征频谱数据的特征提取, 将多通道特征频谱数据组合为矩阵 $M \in \mathbb{R}^n$, 矩阵 M 每行对应一个通道数据, 表示为

$$M = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_8 \end{bmatrix} = \begin{bmatrix} y_0 & y_2 & \cdots & y_{255} \\ y_{256} & y_{257} & \cdots & y_{511} \\ \vdots & \vdots & \vdots & \vdots \\ y_{1792} & y_{1793} & \cdots & y_n \end{bmatrix} \quad (8)$$

则每个通道的带宽为 $BW_{\text{channel}} = n/8 \times \Delta f$, 各

特征通道频率范围表示为

$$\begin{aligned} f_i^{\text{start}} &= f_{\min} + (i-1) \times BW_{\text{channel}}, \\ f_i^{\text{end}} &= f_{\min} + i \times BW_{\text{channel}}, \end{aligned} \quad (9)$$

式中: f_i^{start} 和 f_i^{end} 分别为通道频谱特征的起止值。上述过程得到多特征通道的无人机信号频谱数据, 便于后续神经网络模型实现多特征通道的精确提取。




图4 AR无人机四种工作模式信号频谱数据

Fig. 4 Spectral data of signal for four working modes of AR UAV




图5 Bebop无人机四种工作模式信号频谱数据

Fig. 5 Spectral data of signal for four working modes of Bebop UAV

2 MC-2DCNN 模型设计

为实现对无人机类型和飞行模式的识别,本文设计了一种基于多通道二维卷积神经网络(MC-2DCNN)的信号识别模型,其自适应特征提取能力有效克服了传统设计方法在复杂噪声环境下特征表征不足的缺陷,引入多特征通道提取策略有效保留了信号细分频段的异质性特征,精准适配MC-2DCNN的多通道卷积特性。

2.1 多特征通道信号张量化处理策略

无人机能量频谱信号划分独立通道,结合数据维度重组形成三维张量,当 $n=2048$ 时,信号维度表示为 $1 \times 256 \times 8$,其分别代表能量、频率和通道。通过张量重塑将矩阵 M 构建为三维特征矩阵 $X_{seg} \in \mathbb{R}^{1 \times 256 \times 8}$,此过程充分考虑频谱信号的空间异质性特征,为后续特征提取与信号识别任务匹配数据结构。其中,频率维度通过局部频点序列的邻域聚合机制,有效捕获无人机信号的谐波分量、瞬态噪声等微特征的短时频域相关性,保持其局部连续性和拓扑关联性;通道维度映射多传感器观测数据的空间多样性及不同频段信号物理特性的差异分布,

$$H^{(1)}(t, f) = BN \left(ReLU \left(\sum_{C=1}^8 \sum_{k=1}^3 W^{(1)}(k, C) * X_{seg}(t, f + k - 1, C) + b^{(1)} \right) \right), \quad (10)$$

式中: X_{seg} 为输入数据; t 为能量维度,固定为1; f 和 C 分别为频点和通道索引; k 为卷积核。对于每个输出通道都有一个独立的卷积核与所有输入通道相连,在输入的8个通道上,使用 1×3 的卷积核进行加权求和,并加上偏置 $b^{(1)}$ 。卷积操作后通过ReLU激活函数引入非线性决策边界,批归一化(BN)加速训练收敛。初级卷积层输入通道数为8,输出特征图数为16,输出为 $H^{(1)} \in \mathbb{R}^{1 \times 256 \times 16}$,频率维度保持256。

最大池化层(Pool1):在初级卷积层后继续空间降采样与特征压缩,使用最大池化对特征图降采样压缩频率维度至128,池化窗口为 1×2 ,在频率维度对每个 1×2 的非重叠窗口取最大值,输出表示为

$$P^{(1)}(t, y, c) = \max_{0 \leq m < 2} H^{(1)}(t, 2y + m, c), \quad (11)$$

式中:变量 y 为池化后的新频点索引(0~127); m 为池化窗口的偏移量。该设计保留显著特征的同时抑制高频噪声,扩大后续卷积层的有效感受野,该层输出表示为 $P^{(1)} \in \mathbb{R}^{1 \times 128 \times 16}$ 。

保留各分频段的异构信息并建立跨通道特征交互的耦合关系;能量维度作为卷积核单元被固定设定为1,精准适配二维卷积核的滑动特性并可快速形成特征图。该张量化处理策略通过频域特征的空间解耦与结构化重组,在保障频域特征拓扑邻接关系的同时,借助通道分离机制实现了跨频段特征的差异化建模,为后续卷积神经网络的特征提取奠定了几何可解释性的数据基础。

2.2 MC-2DCNN 模型结构设计

MC-2DCNN采用双层二维卷积神经网络结构,实现对输入信号的层次化特征提取与分类。模型输入数据为 $1 \times 256 \times 8$ 的三维特征矩阵,分别对应能量、频率和通道。MC-2DCNN包括初级卷积层、深层卷积层、最大池化层和全连接层与结果输出层。模型各层参数传递及特征提取过程如下。

初级卷积层:配置卷积核沿频点 $1 \times 256 \times 8$ 维度滑动,卷积核 $W^{(1)} \in \mathbb{R}^{1 \times 3 \times 8 \times 16}$ 在频率维度具有局部感知能力,跨通道维度实现异质性特征融合。该层使用16个 1×3 的卷积核,沿频率维度滑动并进行特征提取,提取局部频域波动模式,表示为

深层卷积层:该层使用32个 1×3 卷积核进一步提取高阶频域特征,增强模型对跨频段特征组合的感知能力。表示为

$$H^{(2)} = BN(ReLU(W^{(2)} * P^{(1)} + b^{(2)})). \quad (12)$$

该层卷积核 $W^{(2)} \in \mathbb{R}^{1 \times 3 \times 16 \times 32}$ 的特征通道数倍增,增强模型对跨频段特征组合的提取能力。同样使用ReLU和BN进行非线性变换并增强稳定训练,输出特征图表示为 $H^{(2)} \in \mathbb{R}^{1 \times 128 \times 32}$ 。

最大池化层(Pool2):再次对特征图进行降采样,将频率维度压缩至64,进一步扩大感受野并提取更具判别性的特征。该层输出表示为 $P^{(2)} \in \mathbb{R}^{1 \times 64 \times 32}$ 。

全连接层与结果输出层:经特征提取后,模型通过全连接层实现分类识别决策。首先,将 $1 \times 64 \times 32$ 特征图展平为2048维向量,随后通过含64个ReLU神经元的隐藏层构建非线性映射,输出层使用Softmax分类器输出4个类别的概率(本底噪声、Bebop、AR、Phantom),分类概率计算公式为

$$P(y=c|h) = \frac{\exp(\mathbf{w}_c^T \mathbf{h} + b_c)}{\sum_{k=0}^3 \exp(\mathbf{w}_k^T \mathbf{h} + b_k)}, c \in \{0, 1, 2, 3\}, \quad (13)$$

式中： $\mathbf{h}$ 为隐藏层输出特征向量； c 为4个类别， $\mathbf{w}_c$ 和 b_c 表示为类别 c 的权重与偏置。

综上，MC-2DCNN模型维度传递过程如表1所示。

表1 MC-2DCNN模型维度传递过程

Tab. 1 Process of transmitting dimensions of MC-2DCNN model

层名称	输入维度	输出维度
输入层	$1 \times 256 \times 8$	$1 \times 256 \times 8$
卷积层1+BN+ReLU	$1 \times 256 \times 8$	$1 \times 256 \times 16$
最大池化层1	$1 \times 256 \times 16$	$1 \times 128 \times 16$
卷积层2+BN+ReLU	$1 \times 128 \times 16$	$1 \times 128 \times 32$
最大池化层2	$1 \times 128 \times 32$	$1 \times 64 \times 32$
全连接层1(ReLU)	$1 \times 64 \times 32$	64
全连接层2(Softmax)	64	4
分类输出	4	4

2.3 MC-2DCNN模型训练策略

采用自适应矩估计优化器(Adam)进行参数更新，交叉熵损失函数作为优化目标，表示为

$$L = - \sum_{i=1}^N \sum_{j=1}^C y_{i,j} \lg(\hat{y}_{i,j}), \quad (14)$$

式中： N 为样本数量； c 为类别数量； $y_{i,j}$ 为第 i 个样本的真实标签， $\hat{y}_{i,j}$ 为第 i 个样本预测为第 j 类别的概率。

3 实验设计

3.1 数据集介绍

本文采用DroneRF数据集，包含本底噪声信号及Parrot Bebop、Parrot AR Drone和DJI Phantom3三种不同类型无人机在干扰环境下的射频信号^[12]，每种无人机均采集了静态、自主悬停、无视频采集飞行以及视频录制飞行4种模式数据。无人机射频信号及噪声信号共22 700个样本。通过多特征通道信号预处理后，将能量频谱数据重构为三维张量矩阵，以适配MC-2DCNN网络的输入结构。采用分层随机划分策略将数据集按7:2:1比例划分为训练集、验证集和测试集，有效保持各类样本分布的均衡性，并且训练过程固定随机种子，确保模型运行时的数据划分一致。

3.2 实验环境与模型参数

本文模型训练中数据处理平台基于python3.9和Tensorflow3.0，硬件条件使用Intel(R) Gold

5188 CPU和NVIDIA Quadro P400 GPU。在模型参数部分，将学习率设置为0.01、0.001和0.000 1三个梯度，批大小Batch size设置为32、64和128三个梯度。采用Adam优化器有效防止MC-2DCNN模型训练存在过拟合现象，通过迭代训练优化模型的信号识别效果。

4 实验结果与分析

4.1 模型超参数验证

首先，对比不同模型超参数(学习率和Batch size)下MC-2DCNN模型训练效果。将模型训练轮数设置为500，训练至模型收敛，准确率和Loss曲线如图6所示。同时，实验证明在不同超参数组合下，学习率为0.001、Batch size为64的组合为最优解，在准确率与收敛速度展现出更为显著的优势。




图6 不同超参数组合模型训练效果

Fig. 6 Training effect of different hyperparameter combination models

4.2 算法核心模块性能验证

本节对无人机射频信号预处理部分采用的DFA、能量频谱分析和多特征通道处理3种核心模块对MC-2DCNN模型的信号效果进行评估。讨论了在MC-2DCNN模型训练过程中，分别采

用上述关键方法对无人机类型识别准确率的影响,

训练效果混淆矩阵如图 7 所示。




图7 信号处理核心模块对MC-2DCNN性能影响

Fig. 7 Impact of signal processing core modules on performance of MC-2DCNN

分析上图结果,图 7(a)~(c) 分别比较了模型训练过程 3 种信号处理核心模块对 MC-2DCNN 信号识别性能的影响,证明了 DFA 信号去噪方法对无人机射频信号的干扰抑制作用,同时说明多特征通道处理方案可以更好适配 MC-2DCNN 模型的特征提取机制。图 7(d) 进一步对比了上述 3 种训练方案与本文的多核心模块结合策略,结果证明通过将多种信号处理模块融合的策略有效提升了 MC-2DCNN 模型的抗噪声能力和细分频段异质性特征提取能力。

4.3 多类型无人机信号识别实验

模型评估实验分别对无人机类型及飞行模式的识别效果进行验证。其中,无人机类型识别实验验证了模型对 Parrot Bebop、Parrot AR Drone 和 DJI Phantom3 三种无人机及空间噪声的区分能力,各种类型信号选取 600 组作为测试集得到平均识别率。在此基础上,对 3 种无人机的静态、自主悬停、飞行

以及视频录制飞行 4 种模型进一步区分。表 2 为 MC-2DCNN 模型对无人机飞行模式的识别效果,图 8 为无人机信号类型识别结果混淆矩阵。

表 2 无人机类型和飞行模式识别准确率

Tab. 2 Comparison experiment of UAV type and mode recognition accuracy

无人机类型	飞行模式	识别准确率/%	平均准确率/%
Parrot Bebop	静态	95.3	96.72
	自主悬停	97.6	
	飞行	97.9	
	录制飞行	96.1	
Parrot AR Drone	静态	94.6	97.25
	自主悬停	98.2	
	飞行	97.8	
	录制飞行	98.4	
DJI Phantom3	静态	99.0	97.50
	自主悬停	96.5	
	飞行	97.7	
	录制飞行	96.8	

从表 2 结果可以得知, MC-2DCNN 模型对多类型无人机对应的飞行模式平均识别准确率均高于 95%, 结合图 7 中无人机类型识别结果得出模型对

无人机类型识别准确率高于96%，证明MC-2DCNN对无人机信号识别的高准确率和鲁棒性。




图8 无人机类型识别准确率

Fig. 8 Accuracy of UAV types recognition

4.4 模型对比实验

4.4.1 多模型训练对比实验

该节实验选取了无人机信号识别的先进方法进行对比，验证MC-2DCNN模型的先进性，参与对比的模型包括 MobileNet-DOA^[11]、ResNet-50^[13]、Inceptionv4^[14]、EfficientNet-B3^[15]和 MobileNetv4^[16]。对无人机射频数据设置信噪比区间为-10~10 dB，通过无人机型号及飞行模式识别准确率评估模型效果，结果如表3和图9所示。

表3 多模型训练效果对比结果

Tab. 3 Model comparison experiment results

模型	参数量/M	平均识别准确率/%	
		型号	飞行模式
MobileNet-DOA	7.3	96.83	94.83
ResNet-50	26.4	94.10	89.56
Inceptionv4	12.21	93.43	89.63
EfficientNet-B3	12.0	95.95	90.42
MobileNetv4	3.8	96.85	92.48
MC-2DCNN	1.334	98.15	96.32

分析表3结果可知，MC-2DCNN在所对比模型中的参数量实现了数量级的降低，同时无人机型号和飞行模式识别准确率相较最先进的MobileNet-DOA方法分别提升了1.32和1.49个百分点。从模型设计的角度分析，MC-2DCNN模型采用了自适应多特征通道数据输入设计，解决了传统模型特征表达能力不足的缺陷，同时，多通道特征提取方案有效保留了信号频域异质性特征并精准适配模型的多通道卷积特性，实现了在有限资源下的模型精度和参数量/效率的平衡。图9对比了不同信噪比下多模型的信号识别效果，MC-2DCNN相较其他先进模型在变化信噪比(-10~10 dB)场景下具有更好的识别准确率，

再次证明了所提模型抗噪声的鲁棒性。





图9 不同SNR下多模型的无人机识别准确率


Fig. 9 Accuracy of UAV recognition with multiple models under different signal-to-noise ratio

4.4.2 不同干扰强度下模型验证实验

考虑无人机实际飞行过程中受到的干扰状况，包括电磁空间噪声、人为干扰如梳状谱和阻塞式(如图10所示)，设置-15、-10、-5和0 dB共4个噪声强度，讨论不同干扰状况和干扰强度对无人机类型及飞行模式的识别影响，结果如表4所示。



(a) 梳状谱



(b) 阻塞式

图10 无人机梳状谱和阻塞式干扰信号

Fig. 10 Comb spectrum and blocking interference signal of UAV

表 4 不同干扰状况下模型识别准确率

Tab. 4 Model performance under different interference intensity

干扰类型	平均识别准确率/%	
	型号	飞行模式
高斯噪声	93.11	91.26
梳状谱干扰	90.17	89.90
阻塞式干扰	92.64	90.53

表 4 为不同干扰状况下, MC-2DCNN 对无人机型号和飞行模式的识别情况, 结果显示, 在 $-15\sim 0$ dB 的噪声范围内, 平均识别准确率基本高于 90%。图 11 进一步讨论了电磁空间噪声、梳状谱和阻塞三类型干扰混叠下模型对应的识别准确率。分析结果可知, 在混叠干扰场景下, 无人机型号和飞行模式的平均识别准确率分别可以达到 91.97% 和 90.56%, 可以认为在实际飞行场景中出现自然和人为干扰, 本文所提模型对无人机信号识别具有鲁棒性。




图 11 不同干扰强度下的模型识别准确率

Fig. 11 Accuracy of UAV recognition under different levels of interference intensity

5 结 论

本文面向复杂空域环境中无人机类型、飞行模式识别难、精度低的难题, 提出了一种基于时频多通道特征的信号智能识别模型。采用从信号预处理和去噪到能量频谱数据构建的信号识别全链路分析方法, 并提出多特征通道处理解决信号空间异质性。进一步引入多特征通道信号张量化处理策略, 精准适配 MC-2DCNN 模型卷积特性和特征提取机制, 有效提升模型识别能力。结果

表明:

1) DFA 去噪方法结合多特征通道处理能更好体现射频信号能量频谱异质性特征;

2) MC-2DCNN 提出自适应多通道特征提取策略, 传统模型特征提取维度不足的缺陷;

3) MC-2DCNN 模型在强噪声、混叠干扰场景下的信号识别效果具有鲁棒性。

本文工作为研究复杂电磁环境下无人机多模信号识别提供了切实可行的方法, 下一步将研究无人机检测识别一体化智能模型。

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] 晏行伟, 孔令轩, 刘坤, 等. 基于 MobileNet-DOA 的无人机射频信号识别方法[J]. 雷达科学与技术, 2025, 23(1): 57-66.
YAN Xingwei, KONG Lingxuan, LIU Kun, et al. Drone radio frequency signal identification method based on MobileNet-DOA [J]. Radar Science and Technology, 2025, 23(1): 57-66. (in Chinese)
- [2] 王波, 孟志鹏, 陈小庆, 等. 从无人机蜂群发展趋势看反无人机蜂群策略[J]. 国防科技, 2023, 44(3): 68-73.
WANG Bo, MENG Zhipeng, CHEN Xiaoqing, et al. Analyzing anti-UAV swarm strategies based on UAV swarm developments[J]. National Defense Technology, 2023, 44(3): 68-73. (in Chinese)
- [3] 陶文波, 倪东明, 程宇, 等. 基于 CNN-LSTM-PSA 的多特征融合无人机声目标识别方法[J]. 电声技术, 2025, 49(7): 153-159.
TAO Wenbo, NI Dongming, CHENG Yu, et al. Multi-feature fusion unmanned aerial vehicle sound target recognition method based on CNN-LSTM-PSA [J]. Audio Engineering, 2025, 49(7): 153-159. (in Chinese)
- [4] HUANG Y, QU J, WANG H, et al. An all-time detection algorithm for UAV images in urban low altitude[J]. Drones, 2024, 8(7): 332.
- [5] AL-EMADIS, AL-ALI A. Audio-based drone detection and identification using deep learning techniques with dataset enhancement through generative adversarial networks[J]. Sensors, 2021, 21(15): 4953.
- [6] AYDİN İ, KIZILAY E. Development of a new light-

- weight convolutional neural network for acoustic-based amateur drone detection[J]. *Applied Acoustics*, 2022, 193: 108773.
- [7] 夏昊, 林粤伟, 颜军, 等. 通信感知一体化低空无人机关键技术研究综述[J]. *电讯技术*, 2025, 65(6): 838-847.
- XIA Hao, LIN Yuewei, YAN Jun, et al. Research on key technologies of low altitude unmanned aerial vehicle for integrated sensing and communication: an overview[J]. *Telecommunication Engineering*, 2025, 65(6): 838-847. (in Chinese)
- [8] 孙永生, 雷宗林, 李恩特. 违规违法飞行无人机电子数据取证技术[J]. *无线电工程*, 2025, 55(9): 1887-1893.
- SUN Yongsheng, LEI Zonglin, LI Ente. Electronic data forensics technology for UAV involved in illegal and non-compliant flights [J]. *Radio Engineering*, 2025, 55(9): 1887-1893. (in Chinese)
- [9] 乔仟, 尹童, 张秋云, 等. 基于时频特性的无人机分类技术研究[J]. *兵器装备工程学报*, 2025, 46(7): 183-192.
- QIAO Qian, YIN Tong, ZHANG Qiuyun, et al. Research on UAV classification techniques based on time-frequency features[J]. *Journal of Ordnance Equipment Engineering*, 2025, 46(7): 183-192. (in Chinese)
- [10] 赵琦云, 张赫, 靳崇, 等. 基于改进YOLO11-DeepSORT模型的“低慢小”无人机识别跟踪算法[J]. *火力与指挥控制*, 2025, 50(7): 125-132.
- ZHAO Qiyun, ZHANG He, JIN Chong, et al. “Low-slow-small” UAV recognition and tracking algorithm based on improved model YOLO11-DeepSORT[J]. *Fire Control & Command Control*, 2025, 50(7): 125-132. (in Chinese)
- [11] 王曼琳, 朱修彬, 杨兰, 等. 逐级特征融合的多阶段无人机跨视图匹配方法[J/OL]. *计算机科学与探索*, 2025: 1-19. (2025-07-11). <https://kns.cnki.net/KCMS/detail/detail.aspx?filename=KXTS20250710001&dbname=CJFD&dbcode=CJFQ>.
- WANG Manlin, ZHU Xiubin, YANG Lan, et al. Multi-stage cross-view UAV image matching *via* hierarchical feature fusion[J/OL]. *Journal of Frontiers of Computer Science and Technology*, 2025: 1-19. (2025-07-11). <https://kns.cnki.net/KCMS/detail/detail.aspx?filename=KXTS20250710001&dbname=CJFD&dbcode=CJFQ>. (in Chinese)
- [12] 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.
- [13] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770-778.
- [14] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, inception-ResNet and the impact of residual connections on learning [C]//Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence, 2017: 4278-4284.
- [15] TAN M, LE Q V. EfficientNet: rethinking model scaling for convolutional neural networks [J/OL]. *Computer Science*, 2019. <https://doi.org/10.48550/arxiv.1905.11946>.
- [16] DU H, CHEN D, ZHANG X, et al. A dynamic gesture recognition method based on MobileNetV4[C]//2024 8th Asian Conference on Artificial Intelligence Technology (ACAIT), 2024: 54-60.