



XXXX

# 基于复数多尺度融合的无人机射频信号双任务识别

姜晨希, 陈永毅, 张丹

(浙江工业大学信息工程学院 杭州 310023)

**摘 要:** 无人机 (unmanned aerial vehicles, UAVs) 的广泛应用带来了侵犯隐私、侵入空域甚至威胁关键基础设施等安全风险, 亟须有效的识别手段以支撑空域监管。现有基于深度学习的无人机射频信号识别方法多直接采用图像领域的2D神经网络建模, 忽略了同向/正交 (In-phase/Quadrature, I/Q) 分量的相位相关性, 时频特征提取能力与可解释性受限, 且缺乏对无人机型号与飞行状态的双任务协同识别。针对上述问题, 本文提出一种复数多尺度融合双任务网络。首先, 通过复数多尺度融合模块耦合 I/Q 信号时频图, 在保留相位信息的同时提取多尺度时频特征。其次, 采用轻量化双向特征金字塔网络实现高效特征融合。最后, 设计级联指导双任务分类结构, 并结合自适应损失加权策略, 实现型号与飞行状态的协同识别。实验结果表明, 所提方法在低信噪比 (signal-to-noise ratio, SNR) 条件下的识别精度优于现有方法, 且对时频分辨率降低具有良好鲁棒性。

**关键词:** 无人机; 射频信号; 深度学习; 复数多尺度融合; 自适应双任务学习

**中图分类号:** TN975

**文献标志码:** A

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

## Dual-Task Identification of UAV Radio Frequency Signals Based on Complex Multi-Scale Fusion

Jiang Chenxi, Chen Yongyi, Zhang Dan

School of Information Engineering, Zhejiang University of Technology, Hangzhou 310023, China

**Abstract:** The widespread application of unmanned aerial vehicles (UAVs) has introduced security risks including privacy infringement, airspace intrusion, and even threats to critical infrastructure, making effective identification methods urgently needed to support airspace regulation. Existing deep learning-based UAV radio frequency signal identification methods mostly directly employed 2D neural networks from the image domain for modeling, which ignored the phase correlation between In-phase/Quadrature (I/Q) components, resulting in limited time-frequency feature extraction capability and interpretability, and lacked dual-task collaborative recognition of UAV model and flight status. To address the above issues, a complex multi-scale fusion dual-task network (CMS-DTN) was proposed in this paper.

收稿日期: XXXX-XX-XX; 修回日期: XXXX-XX-XX

通信作者: 陈永毅 woosa1997@foxmail.com

基金项目: 国家自然科学基金(U2541213)

**Foundation Items:** the National Natural Science Foundation of China (U2541213)



Firstly, a complex multi-scale fusion module was designed to couple I/Q signal time-frequency spectrograms, extracting multi-scale time-frequency features while preserving phase information. Secondly, a lightweight bidirectional feature pyramid network was adopted to achieve efficient feature fusion. Finally, a cascaded guidance dual-task classification structure was designed, combined with an adaptive loss weighting strategy, to realize collaborative recognition of UAV model and flight status. Experimental results demonstrated that the proposed method achieved higher recognition accuracy than existing methods under low signal-to-noise ratio (SNR) conditions, and exhibited better robustness to time-frequency resolution reduction.

**Key words:** UAVs, radio frequency signal, deep learning, complex multi-scale fusion, adaptive dual-task learning

## 1 引言

近年来,无人机技术迅速发展,其应用已扩展到民用及农商业领域<sup>[1]</sup>。然而,随着无人机数量的指数级增长,其带来的安全问题也日益凸显,无人机可被用于非法侵入,威胁公共事业安全,甚至发动恐怖袭击<sup>[2]</sup>。针对此类目标,快速识别其型号并判断当前飞行状态(如起降、悬停、水平移动等),是评估威胁等级、制定差异化反制策略的关键前提。因此,发展兼具设备识别与行为感知能力的无人机监测技术,已成为构建智能化低空安全防护体系的迫切需求。当前无人机探测技术仍存在固有局限性,雷达探测在复杂环境中易受杂波干扰<sup>[3]</sup>,同时因成本过高而难以规模化部署。声学探测作用距离较近且易受环境噪声影响<sup>[4]</sup>。光学探测受光照条件和视野环境影响过大<sup>[5]</sup>。相比之下,尤其在复杂的城市环境中,射频信号探测则具备不受光照影响,识别范围广和被动探测等诸多优势<sup>[6]</sup>。

射频信号分析为无人机监测提供了独特的技术途径。一方面,不同型号无人机的射频前端架构、调制参数及协议实现存在系统性差异,这些差异会在发射信号中形成可区分的型号特征,可用于设备类型辨识;另一方面,无人机在不同飞行状态下,其通信指令存在显著差异,这些差异会反映在射频信号的调制特征与时频分布中,形成不同的信号特征。因此,无人机射频信号蕴含了设备类型与行为状态的双重信息,为型号与状

态的联合监测提供了天然条件<sup>[7]</sup>。该方法无需解析高层通信协议,且具备较强的隐蔽性。

传统的无人机射频信号分析主要依赖信号处理与专家特征提取,如基于时频分析、高阶统计量或瞬时特征等特征工程,并结合支持向量机、决策树等浅层分类模型进行识别<sup>[8],[9]</sup>。该类方法具有一定的可解释性且计算复杂度较低,但由于特征依赖人工设计,往往难以充分刻画复杂射频信号中的判别性信息,同时对信号质量和分类器选择较为敏感<sup>[10]</sup>。尤其在低信噪比和多径干扰等复杂信道条件下,其特征稳定性和泛化能力受到显著限制,难以满足复杂电磁环境下的精细化识别需求。

目前深度学习因其强大的特征提取和模式识别能力在无人机射频信号识别领域展现出显著优势<sup>[11]</sup>。其中,卷积神经网络(Convolutional Neural Network, CNN)因其优秀的局部特征捕获能力而获得了广泛应用。针对原始无人机射频信号的同向/正交(In-phase/Quadrature, I/Q)时序数据,文献[12]提出了一种基于多通道1D CNN的型号、飞行状态识别方法。同时,文献[13]也提出了一种由5个1D卷积层,1D池化层和Dropout层的CNN架构。而文献[14]则将I/Q信号拆分得到双通道一维时序输入,并使用VGG16<sup>[15]</sup>、ResNet<sup>[16]</sup>等网络仅对型号识别进行了验证。但随着近年来无人机跳频扩频(Frequency Hopping Spread Spectrum, FHSS)技术的普遍应用,其射频信号呈现出离散的跳频序列,具有明显的时变

结构。基于 I/Q 时序的神经网络方法仅能提取时域局部波形特征，缺乏显式的时频联合建模能力，难以有效刻画跳频信号的时频分布规律。

针对上述问题，时频分析技术与 2D 神经网络的结合逐渐成为主流。文献[17]在时频图的基础上，系统性地评估了多种不同形式的 VGG 模型在型号识别任务中的性能。针对实际部署对方法轻量化的要求，文献[18]基于时频图提出了一种受 Res2Net 启发而来的轻量级多尺度卷积 (Lightweight Multiscale Convolution, LMSC) 模块。文献[19]则基于 MobileNetV3<sup>[20]</sup>提出了一种轻量级神经网络，并采用增强型压缩激励 (Squeeze-and-Excitation, SE) 模块与软阈值机制来抑制信道噪声。二者虽然在轻量化上取得了突破，但都缺乏有效的特征融合过程，难以同时关注无人机跳频信号的局部跳变和全局规律。对此，文献[21]和文献[22]分别提出了 MC-CNN 和 CNN|Triplet-DNN，通过多尺度多分支深度融合，进一步提升了模型对于跳频机制的识别能力，但其特征融合仍为单向或简单拼接，全局特征学习能力有限，且计算复杂度倍增，并不利于实际部署。

通过对现有基于深度学习的无人机射频信号分类方法的综述，当前研究存在以下局限性：

1) 现有 2D 神经网络方法大多沿用图像领域的范式，将 I/Q 信号变换得到的双通道时频图直接输入实值卷积神经网络。这类方法忽略了 I/Q 分量的正交性与相位耦合关系，难以充分挖掘射频信号中的深层判别特征，且缺乏实际可解释性。

2) 现有方法虽引入多尺度设计，但特征融合方式多为单向融合，缺乏双向交互的动态校正能力，难以同时关注跳频信号的局部瞬变细节与全局时序规律，且难以兼顾融合深度与计算复杂度。

3) 当前研究几乎聚焦于无人机型号识别任

务，而缺乏对其飞行状态的关注。实际上，由于不同型号的无人机在调制方式和射频特征上已存在显著差异，故相比于型号识别，跨型号、跨特征分布的飞行状态识别具有更高的不确定性，却又与型号高度相关。常规并联多任务结构易忽略这种内在关联，限制了识别精度的进一步提升。

综上所述，本文旨在设计一个能够自适应提取复杂非平稳时频特征，并有效协同多尺度信息与跨任务知识的无人机型号与飞行状态联合识别模型，以实现复杂电磁环境下无人机射频信号的高精度、细粒度识别。针对上述问题，本文提出复数多尺度双任务识别网络 (Complex Multi-Scale Dual-Task Network, CMS-DTN) 实现基于射频信号的无人机型号及飞行状态鲁棒精细识别。本文的主要贡献如下：

1) 针对现有 2D CNN 方法忽略 I/Q 信号相位耦合的问题，设计复数多尺度 (Complex Multi-Scale, CMS) 模块，通过复数卷积在特征提取初始阶段保持 I/Q 分量的正交耦合关系，抑制电磁干扰信号，并融合多尺度时频特征；

2) 针对现有方法多尺度特征融合效率低，难以协同捕获跳频信号瞬变细节与长期规律的问题，设计轻量化双向特征金字塔网络 (Bidirectional Feature Pyramid Network-light, BiFPN-light)，精简特征传导路径，实现多尺度特征的高效、轻量融合；

3) 针对无人机型号与飞行状态存在层次依赖关系，而传统并联多任务结构难以有效利用任务关联的问题，设计级联指导的双流分类头，将型号识别输出作为嵌入向量辅助指导飞行状态识别任务，同时引入难度感知自适应加权算法动态平衡双任务损失，实时稳定训练过程，提升飞行状态识别精度。



## 2 信号模型与问题描述

### 2.1 接收信号模型

通过伪随机跳变载波频率, FHSS 技术能有效规避窄带干扰和恶意阻塞, 从而在现代无人机系统的控制链路中得到了广泛应用, 以确保关键指令在复杂电磁环境下的可靠传输。而 FHSS 信号耦合了型号与状态控制特征, 这为从单一信号流中同时进行型号与飞行状态的识别提供了物理基础。基于此背景, 本研究聚焦于对无人机 FHSS 控制信号的研究分析。

针对采用 FHSS 调制技术的无人机系统, 其控制信号在基带等效复数形式下可表征为

$$s(t) = \left[ \sum_k d_k \cdot g(t - kT_s) \right] \cdot \sum_n e^{j(2\pi f_n t + \theta_n)} \cdot \text{rect}_{T_h}(t - nT_h) \quad (1)$$

其中,  $d_k$  为第  $k$  个传输的数据符号;  $g(t)$  为基带成形脉冲;  $T_s$  为  $d_k$  的持续时间;  $f_n$  为第  $n$  跳对应的载波频率偏移;  $\theta_n$  为第  $n$  跳的载波初始相位;  $\text{rect}_{T_h}(t)$  为矩形时间窗函数;  $T_h$  为跳频驻留时间。

在接收端, 经过下变频和初步同步后, 得到的基带 I/Q 控制信号为

$$r(t) = h_{\text{ch}}(t) * s(t) + n(t) \quad (2)$$

其中,  $h_{\text{ch}}(t)$  为控制信号的信道冲激响应;  $n(t)$  为设备固有噪声; 遵循加性高斯白噪声 (Additive White Gaussian Noise, AWGN) 的分布。需要说明的是, 式(2)中主要采用 AWGN 信道对接收过程进行建模, 其目的在于突出无人机跳频控制信号本身的时频结构特性, 便于分析模型对 I/Q 相位关系与跳频模式的学习能力。实际复杂无线干扰环境中的非理想因素, 则后续主要通过数据集集中的 WiFi、蓝牙等背景干扰信号以及数据增强过程中的时频掩码进行模拟。

### 2.2 基于深度学习的无人机射频信号识别方法

### 目标

对于本文的基于深度学习的无人机射频信号双任务识别问题, 目标可以描述为

$$\hat{y}_m, \hat{y}_s = \arg \max_{(y_m, y_s) \in \mathcal{Y}_m \times \mathcal{Y}_s} f(y_m, y_s | x; \theta_m) \quad (3)$$

其中,  $\mathcal{Y}_m$  是无人机型号标签空间;  $\mathcal{Y}_s$  是无人机飞行状态标签空间;  $(\hat{y}_m, \hat{y}_s)$  是预测的无人机类型与飞行状态;  $\theta_m$  是网络参数。设置  $\mathcal{X}$  为输入特征空间, 该空间由变换后的短时傅里叶变换 (Short-Time Fourier Transform, STFT) 矩阵组成,  $x \in \mathcal{X}$  为输入样本。该问题的本质是从假设空间  $\mathcal{F}$  中寻找一个映射函数  $f(\cdot)$ , 使得模型预测与真实标签之间的差异最小。为量化这一差异, 定义期望风险为

$$\varepsilon_{\text{exp}} = \mathbb{E}_{(x, y_m, y_s) \sim P_{\mathcal{X} \times \mathcal{Y}_m \times \mathcal{Y}_s}} [\mathcal{L}_{\text{RFFI}}((\hat{y}_m, \hat{y}_s)(y_m, y_s))] \quad (4)$$

其中,  $P_{\mathcal{X} \times \mathcal{Y}_m \times \mathcal{Y}_s}$  为输入与标签的联合分布;  $\mathcal{L}_{\text{RFFI}}$  为用于量化模型预测值与实际标签之间差异的损失函数。针对型号识别与飞行状态识别两个任务的优化需求, 构建加权联合损失函数

$$\tilde{\mathcal{L}}_{\text{RFFI}} = \lambda_m \mathcal{L}_{\text{CE}}(\hat{y}_m, y_m) + \lambda_s \mathcal{L}_{\text{CE}}(\hat{y}_s, y_s) \quad (5)$$

其中,  $\tilde{\mathcal{L}}_{\text{RFFI}}$  为总损失函数, 其物理含义为型号识别任务损失与飞行状态识别任务损失的加权和;  $\mathcal{L}_{\text{CE}}$  为分类交叉熵损失函数;  $\lambda_m$  和  $\lambda_s$  分别为型号识别和飞行状态识别任务的动态权重, 用于自适应调节两个任务在训练过程中的优化优先级。

由于真实联合分布  $P_{\mathcal{X} \times \mathcal{Y}_m \times \mathcal{Y}_s}$  未知, 期望风险  $\varepsilon_{\text{exp}}$  无法直接计算, 需通过经验分布近似得到可优化的经验风险  $\varepsilon_{\text{emp}}$ , 即利用训练样本的经验频率代替理论概率。首先定义训练集上的经验分布为

$$\hat{P}_{\mathcal{X} \times \mathcal{Y}_m \times \mathcal{Y}_s} = \frac{1}{N} \sum_{n=1}^N \delta(x = x_n, y_m = y_{m,n}, y_s = y_{s,n}) \quad (6)$$

其中,  $N$  为训练样本总数;  $n$  为样本索引;  $x_n$  为第  $n$  个输入样本;  $y_{m,n}, y_{s,n}$  为第  $n$  个样本的真实型号和飞行状态标签;  $\delta(\cdot)$  为指示函数, 当满足条件时取值为 1, 否则为 0。

将式(6)的经验分布代入式(4)的期望定义, 展开可得

$$\varepsilon_{\text{emp}} = \sum_{x, y_m, y_s} \hat{P}(x, y_m, y_s) \cdot \mathcal{L}_{\text{RFFI}}((\hat{y}_m, \hat{y}_s), (y_m, y_s)) = \frac{1}{N} \sum_{n=1}^N \mathcal{L}_{\text{RFFI}}((\hat{y}_{m,n}, \hat{y}_{s,n}), (y_{m,n}, y_{s,n})) \quad (7)$$

再将式(5)的加权联合损失函数代入式(7), 得到可计算的经验风险表达式

$$\varepsilon_{\text{emp}} = \frac{1}{N} \sum_{n=1}^N [\lambda_m \mathcal{L}_{\text{CE}}(\hat{y}_{m,n}, y_{m,n}) + \lambda_s \mathcal{L}_{\text{CE}}(\hat{y}_{s,n}, y_{s,n})] \quad (8)$$

式(8)即经验风险最小化目标, 为在训练集上最小化所有样本的加权总损失平均值。

### 3 无人机射频信号识别方法

#### 3.1 总体框架

针对无人机射频跳频信号在复杂电磁环境下特征微弱、非平稳且多尺度耦合的特性, 以及型号识别与飞行状态识别任务间存在层次依赖关系的物理事实, 本文提出 CMS-DTN, 旨在构建一

$$[\hat{Y}_m, \hat{Y}_s] = F_{\text{decoder}}(F_{\text{bifpn\_l}}(F_{\text{encoder}}(F_{\text{cms}}(X; \Theta_{\text{cms}}); \Theta_{\text{encoder}}); \Theta_{\text{bifpn\_l}}); \Theta_{\text{decoder}}) \quad (9)$$

其中,  $F_{\text{cms}}$  表示复数多尺度融合模块;  $F_{\text{encoder}}$  为轻量级编码器网络;  $F_{\text{bifpn\_l}}$  为 BiFPN-light;  $F_{\text{decoder}}$  为难度自适应级联双流分类器;  $\Theta$  代表各模块的可训练参数。

#### 3.2 CMS 模块

在无人机射频信号识别任务中, 原始输入为复数形式的时频图, 其包含了信号幅度与相位的完整信息。传统的实值卷积网络通常将实部与虚部视为独立的实数通道进行并行处理, 这种处理方式等价于假设 I/Q 分量间不存在交叉能量耦合, 即忽略了复数域内固有的约束关系。对于无人机跳频信号而言, 其 I/Q 分量并非相互独立, 在理想载波调制下, 二者满足严格的  $90^\circ$  正交相位关系, 且跳频切换时刻的相位连续性直接决定了时频图上跳频轨迹的斜率与块状结构的边界清晰

一个能协同提取型号特征与行为特征的端到端学习框架。本文提出的网络框架如图 1 所示。整体架构由三个核心模块级联构成: CMS 模块、BiFPN-light 以及难度自适应级联双流分类器。

首先, CMS 模块对输入的复数时频图进行实部与虚部的深度交互融合, 完成多尺度特征增强。随后, BiFPN-light 先对融合特征进行分层编码以提取多分辨率特征表示, 后通过轻量化双向跨层连接机制, 实现多尺度特征的高效聚合与加权融合。最终, 级联双流分类器以“型号-状态”的层次依赖关系为约束, 完成飞行状态的精细判别, 并通过难度自适应加权机制动态调节双任务损失权重, 实现端到端的协同优化。

网络输入为无人机射频信号的复数时频图数据  $X \in \mathbb{R}^{H \times W \times 2}$ , 其中高度  $H$  和宽度  $W$  分别对应时频图的频率维和时间维, 最后一维的 2 个通道分别表示信号的实部和虚部。网络通过多层次变换最终分别输出无人机型号和飞行状态两个分类结果。

度。对于原始输入直接进行实值卷积处理会导致该种相位耦合关系在初始提取阶段即被强行解耦, 丢弃了区分不同跳变模式的相位梯度信息, 导致网络无法学习二者的物理相关性, 在复杂电磁环境中易出现干扰敏感和过拟合问题。

为解决上述问题, 并充分挖掘跳频信号在时频域中表现出的多尺度特性, 本文提出了 CMS 模块。该模块作为网络的核心前端, 旨在通过严格模拟复数域乘法代数结构的复数卷积<sup>[23]</sup>, 在特征提取的初始阶段保持 I/Q 信号的相位关系, 并利用多尺度融合策略捕获从局部细节到全局上下文的丰富特征。复数卷积层是 CMS 模块的核心组件, 对于输入复数张量  $X = X_r + jX_i$ , 其中  $X_r, X_i \in \mathbb{R}^{H \times W \times 1}$  分别表示实部和虚部, 复数卷积操作定义为



$$Z_r = \text{Conv2D}(X_r, W_r, b_r) - \text{Conv2D}(X_i, W_i, b_i) \quad (10)$$

$$Z_i = \text{Conv2D}(X_r, W_i, b_i) + \text{Conv2D}(X_i, W_r, b_r) \quad (11)$$

其中,  $W_r, W_i \in \mathbb{R}^{k \times k \times 1 \times F}$  分别为实部和虚部的卷积核权重;  $b_r, b_i \in \mathbb{R}^F$  为偏置项;  $k$  为卷积核大小;  $F$  为输出通道数。

复数卷积操作严格模拟了复数乘法, 这种交叉耦合机制使得输出特征图的每个空间位置均编码了局部邻域内 I/Q 分量的相位差信息。对于无人机跳频信号  $s(n) = Ae^{j\phi_s(n)}$ , 复数卷积输出可表示为

$$y = \sum_{n=1}^N s(n)W^*(n) \quad (12)$$

其中  $W^*(n)$  为卷积核共轭项。当可学习的卷积核相位与跳频信号相位匹配时, 输入信号瞬时相位  $\phi_s(n)$  和卷积核瞬时相位  $\phi_w(n)$  满足  $\phi_s(n) - \phi_w(n) \approx \text{const}$ , 即卷积窗口内各响应分量具有稳定相位差, 因此能够实现同相叠加, 输出幅值满足  $|y| \propto N$ , 形成稳定的相干累积增益。相比之下, WiFi、蓝牙等干扰信号的相位历程与无人机跳频信号存在系统性失配, 无法在同一卷积核下形成

稳定的相干积累, 输出幅值相对较低。这种内在的相位选择性使网络能够有效抑制异构干扰, 聚焦于无人机跳频信号。

经过复数卷积层初步处理后的特征图, 需要进一步提取具有判别性的模式。无人机射频信号在时频图上呈现出多样的结构, 既存在局部信号强度信息, 也存在由跳频序列构成的中等范围图案, 还包括表征整个信号段的全局宏观形态。单一的卷积核尺寸难以有效捕获所有这些不同尺度的信息。为此, 本文引入多尺度特征融合, 采用并行分支结构处理复数卷积的输出, 每个分支使用不同大小的深度可分离卷积核来捕获不同感受野下的特征。考虑到对于不同的输入信号, 各尺度特征的重要性可能是动态变化的, 因此本文引入自适应加权融合机制。该机制为每个分支分配一个可学习的权重, 并通过 Softmax 函数进行归一化, 得到最终融合权重。通过上述操作, CMS 模块在初始特征提取过程中既保留了 I/Q 信号的物理相关性, 又在局部特征图层面面对不同感受野分支提取的特征进行动态重校准。




图1 所提无人机射频信号识别方法框架图

### 3.3 BiFPN-light 网络

通过 CMS 模块的初步处理, 网络获得了对无人机射频跳频信号复数域特性与多尺度结构的鲁棒初级表征。然而, 信号的判别性特征同时蕴含在高时空分辨率的瞬时跳变与低时空分辨率的长期规律之中, 若仅依靠单向深层网络, 会不可避免地丢失必要的局部或全局信息。因此, 本文基于双向特征金字塔网络 (Bidirectional Feature Pyramid Network, BiFPN) [24] 思想, 针对无人机射频跳频信号设计轻量化的 BiFPN-light 架构。该架构通过轻量级编码器和简化双向通路, 协同利用编码器不同深度捕获的互补多尺度信息, 实现更高效更轻量的多尺度特征融合。

首先, 轻量级编码器由残差连接、深度可分离卷积和 ECA (Efficient Channel Attention) 机制 [25] 构建。每个编码器块完成 2 倍下采样并扩展特征通道数, 其中残差连接缓解了梯度消失问题, ECA 机制通过轻量级的一维卷积跨通道交互, 生成通道注意力权重, 从而自适应地校准通道特征响应增强了重要特征的响应。这种设计在减少参数数量的同时保持了较强的特征提取能力。其次, 本文对融合路径进行了轻量化设计。不同于自然图像的复杂过渡, 无人机跳频信号的时频结构变化较为跳跃, 要求模型具备微观瞬态特征和宏观跳频规律协同感知能力。而过多的中间转换节点在引入更多参数和计算量的同时, 对跳频信号判别性特征的增益极其有限, 甚至可能因过度融合中层特征而模糊局部与全局特征, 导致模型性能下降。因此, 本文删除了部分中间节点, 简化了融合操作, 在保持性能的同时进一步降低计算复杂度, 实现了对无人机射频信号时频图中瞬态特征和跳频时序规律的高效融合。同时, 通过可学习加权融合来平衡不同输入特征的重要性。

$$\text{WeightedAdd}(X, Y) = \frac{\text{ReLU}(w_X) \cdot X + \text{ReLU}(w_Y) \cdot Y}{\text{ReLU}(w_X) + \text{ReLU}(w_Y)} \quad (13)$$

其中,  $w_X$  和  $w_Y$  为可学习的权重参数。与 CMS 模块的局部特征加权不同, BiFPN-light 的可学习加权融合作用于全局多尺度特征的路径层面, 通过学习如何最优地组合来自不同分辨率、不同语义层次的特征图, 以平衡细节信息与语义信息。

### 3.4 级联双流分类与动态损失权重调整

在该无人机射频信号双任务识别场景中, 包含型号识别与飞行状态识别两个子任务。而无人机的飞行控制信号调制规则与其型号紧密相关, 基于此, 本文在型号识别的基础上设计了级联双流分类架构, 并配套动态损失权重调整机制, 实现更智能的双任务学习。级联分类器的核心思想是利用任务间的依赖关系, 将型号识别结果作为先验知识辅助飞行状态识别, 形成信息流动的因果链。相比于将两个任务视为相互独立的并联多任务结构, 该设计能够显式建模型号信息对飞行状态判别的约束作用, 从而有效降低跨型号飞行状态识别的不确定性。

首先, 对 BiFPN-light 的输出全局平均池化 (Global average pooling, GAP) 以提取共享特征, 并将型号识别作为基础任务, 直接基于共享特征进行预测。其次, 为实现任务间信息传递, 将型号识别的高维特征压缩为紧凑的嵌入向量, 再将共享特征与型号嵌入向量拼接, 为飞行状态识别提供上下文信息。同时, 引入 Dropout 和 L2 正则化技术以避免过拟合。本文在级联双流分类架构的基础上, 进一步引入了动态损失权重调整机制, 以避免简单任务主导训练, 从而使得网络对较难的任务缺乏关注。首先计算各任务在最近  $W$  个 epoch 内的平滑准确率。

$$\text{Acc}_i^{\text{recent}} = \frac{1}{W} \sum_{t=T-W+1}^T \text{Acc}_i^{(t)} \quad (14)$$

其次, 基于准确率反推任务难度, 准确率越



低表示任务越困难。

$$D_i = 1 - \text{Acc}_i^{\text{recent}} \quad (15)$$

然后, 进行自适应权重计算, 权重调整幅度与任务难度差异成正比。

$$\Delta = \alpha \cdot \frac{|D_m - D_s|}{\max(D_m, D_s)} \quad (16)$$

其中,  $D_m, D_s$  分别为型号和飞行状态识别任务的难度系数;  $\alpha$  为最大调整步长。

最后, 根据难度比较结果, 动态调整损失权重, 同时给出必要的约束条件。

$$[\lambda_m, \lambda_s] =$$

$$\begin{cases} [\min(\lambda_m + \Delta, 0.7), \max(\lambda_s - \Delta, 0.3)] & \text{if } D_m > D_s \\ [\max(\lambda_m - \Delta, 0.3), \min(\lambda_s + \Delta, 0.7)] & \text{otherwise} \end{cases} \quad (17)$$

$$\lambda_m + \lambda_s = 1 \quad (18)$$

在该设计中, 滑动窗口评估和权重边界限制防止权重剧烈振荡, 保证训练平稳收敛。动态权重确保网络资源在任务间合理分配, 随着训练进行, 难度较大的任务将更多关注。通过级联信息流和动态权重平衡, 网络实现了双任务间的协同学习, 提升了整体识别性能。

## 4 实验与讨论

### 4.1 数据集描述与预处理

DroneDetectv2 数据集<sup>[26]</sup>由 7 种不同型号的 UAV 组成, 包括新款 DJI Mavic 2 Air S、DJI Mavic Pro、DJI Mavic Pro 2、DJI Inspire 2、DJI Mavic Mini、DJI Phantom 4 和 Parrot Disco。数据集中信号由 Nuand BladeRF SDR 和开源软件 GNU-Radio 收集, 采样率为 60Mbits/s, 带宽为 28MHz, 中心频率为 2.4375GHz, 每段样本包含持续 2s 内的  $1.2 \times 10^8$  个 I/Q 数据。该数据集包含四类射频信号: 纯蓝牙干扰、纯 Wi-Fi 干扰、两者共存及无干扰场景, 并涵盖无人机的三种飞行模式: 开机 (ON)、悬停 (HO) 与飞行 (FY)。原始 I/Q 数据在输入神经网络前必须经过预处理,

具体流程包括以下步骤。

1) 为了进一步模拟电磁环境复杂性, 本文在 I/Q 数据中引入 AWGN 混合创建加噪样本, 信噪比 (Signal-to-Noise Ratio, SNR) 为 -15dB 至 15dB。

2) 针对无人机射频跳频信号的非平稳特性, 本文使用 STFT 将 I/Q 数据转化为时频图, 通过将一维时序信号映射到二维时频面, 从而屏蔽部分干扰并更直观地显示射频信号特征。STFT 计算采用 1024 点汉明窗, 窗重叠率为 50%, 其数学表达为:

$$X(m, k) = \sum_{n=0}^{N-1} x(n + mH)w(n)e^{-j\frac{2\pi}{N}kn} \quad (19)$$

其中,  $m$  为时间帧;  $k$  为频率仓;  $N$  为窗口长度;  $H$  为重叠样本;  $w(n)$  为汉明窗函数。

3) 对生成的复数 STFT 矩阵双线性插值, 缩放至  $512 \times 512$ , 后截取中心 320 个频率点以聚焦有效信号区域。保留复数 STFT 的实部与虚部作为双通道特征, 保存每个输入样本为  $512 \times 320 \times 2$  的二元矩阵。

4) 仅对训练集应用数据增强。数据增强可有效扩充训练数据集, 常用于为提高模型泛化能力和鲁棒性。本文对复数时频图数据进行了针对性增强处理, 分别通过频域掩码以模拟频段干扰, 时域掩码以模拟信号丢失, 幅度缩放以微调信号整体幅度, 相位旋转以施加微小相位偏移。

### 4.2 实验设置

该实验在 Tensorflow 2.10.0 和 Keras 2.10.0 框架下使用 Python 3.9.15 环境进行, 在 NVIDIA RTX4070 SUPER GPU 上运行。训练过程中使用 Adam 优化器, 超参数设置如下: 学习率为 0.0001, 批次大小为 16, 训练轮数为 150。各任务训练损失值由交叉熵损失函数计算得出。本文使用公开无人机射频数据集来评估所提出的方法, 增强前数据集共包含 12152 个训练样本, 3039 个测试样本。在训练过程中, 先按照 3:1 划

分训练集和验证集, 后对训练集进行 2 倍数据增强。神经网络输入尺寸 (W, H, C) 为 (512, 320, 2)。本文还通过现有方法对比来评估所提出的无人机信号识别方法的性能和复杂度, 包括 Raw IQ<sup>[27]</sup>、VGG16、ResNet18<sup>[16]</sup>、ShuffleNetV2<sup>[28]</sup>、EfficientNetV2<sup>[29]</sup>、MobileNetV2<sup>[30]</sup>、MobileNetV3、LMSC、MC-CNN<sup>[21]</sup> 和 CNN|Triplet-DNN<sup>[22]</sup>。本文通过准确率评估模型性能, 通过浮点数运算量、参数量和存储占用评估模型复杂度。

### 4.3 性能分析


在本节中, 本文首先对比了不同方法在不同信噪比下的识别精度, 然后对具体识别结果进行分析。值得注意的是, 在对比实验中, 本文在各模型中一致应用了所提出的级联双流分类与动态损失值权重调整策略, 以保证模型主体性能评估的公平性。其中, 基于 1D 时序数据的神经网络的方法 (Raw IQ) 的平均型号识别准确度仅为 40.06%, 平均飞行状态识别精度为 47.54%, 且模型在低信噪比下几乎失效, 表明其并不适合无人机跳频信号识别任务。相比之下, 基于时频图和 2D 神经网络的方法性能显著提升。

如图 2 (a) 所示, 在型号识别方面, 所提方法平均准确率达 95.31%, 且在所有 SNR 条件下均


取得最优表现。各模型在高 SNR 的情况下差距最小, 但随着 SNR 逐渐减小, 所提方法的优势逐渐增大, 在 -15dB 的极端低信噪比条件下, 其准确率已显著领先。而如图 2 (b) 所示, 飞行状态识别任务整体难度更高, 各模型平均准确率普遍低于型号识别准确率, 且模型间性能差距更大。但所提方法依然在所有 SNR 条件下均表现最优, 在 SNR 为 -15dB 时准确率达到 84.34%, 显著高于其他模型。

结合原理分析, 传统 CNN 架构 (如 VGG16、ResNet18) 感受野单一, 难以全面捕获时频结构。轻量化模型 (如 MobileNetV2、MobileNetV3) 过度依赖深度可分离卷积可能导致特征表示能力不足, 且缺乏有效的跨尺度特征交互机制, 无法实现多尺度特征图互补。而 LMSC、MC-CNN 与 CNN|Triplet-DNN 虽引入多尺度或多分支设计, 但特征融合为单向或简单拼接, 缺乏双向交互的动态校正能力, 难以有效融合跨层级全局语义信息。此外, 对比方法均使用实数卷积直接处理时频图, 忽略了 I/Q 信号固有的相位结构, 易导致在信噪比恶化时丢失关键的相位判别特征。

如图 3 所示为所提方法在 SNR=0dB 下的识别混淆矩阵。在型号识别层面, 所提方法对于不同



(a) 型号识别准确率



(b) 飞行状态识别准确率

图2 不同方法识别准确度对比




图3 SNR=0dB时,所提方法识别结果混淆矩阵

系列的无人机识别准确率接近 100%，偏差主要集中在识别 DJI Mavic Pro (MP1) 和 DJI Mavic Pro 2 (MP2)，归因于二者硬件及信号模式的强相似性。在飞行状态识别层面，所提方法能够精准识别无人机是否起飞 (ON or FY/HO)，对于难度更高的飞行 (FY) 模式和悬停 (HO) 模式识别，也能保持较高识别准确度。总体而言，所提方法在型号识别与飞行状态识别两项任务中均表现优秀，尤其在低信噪比环境下优势更为突出，说明其具备更强的噪声鲁棒性，在无人机射频信号识别任务中展现出较强性能。

#### 4.4 复杂度分析

本节将从浮点数运算量 (FLOPs)、参数量和模型大小三个方面，对所提方法与对比模型的复杂度进行综合分析，所有测试均以  $512 \times 320 \times 2$  为输入。如表 1 所示，虽然 1D 的 Raw IQ 方法具有最低的 FLOPs，但性能较差。而在 2D 方法中，所提方法具有最少的参数量和最低的存储占用，尽管在 FLOPs 上略高于 ShuffleNetV2 (为其 1.30 倍)，但仅有其 43% 的参数量和存储占用，且型号识别和飞行状态识别的平均准确度分别领先其 2.98% 和 5.35%。此外，所提方法的计算复杂度

表 1 不同方法的复杂度比较

| 方法              | FLOPs(G)    | 参数量(M)      | 存储占用(MB)    | 平均准确率(%)     |              |
|-----------------|-------------|-------------|-------------|--------------|--------------|
|                 |             |             |             | 型号识别         | 飞行状态识别       |
| Raw IQ          | <b>0.35</b> | 10.19       | 38.89       | 40.06        | 47.54        |
| VGG16           | 51.60       | 58.18       | 221.93      | 92.42        | 86.68        |
| ResNet18        | 5.80        | 11.25       | 42.93       | 92.80        | 86.69        |
| ShuffleNetV2    | 0.44        | 1.68        | 6.41        | 92.55        | 86.79        |
| EfficientNetV2  | 9.33        | 20.50       | 78.21       | 92.75        | 86.93        |
| MobileNetV2     | 1.01        | 2.43        | 9.25        | 93.95        | 88.37        |
| MobileNetV3     | 0.72        | 3.11        | 11.87       | 94.23        | 89.82        |
| LMSC            | 0.83        | 1.21        | 4.61        | 94.28        | 90.09        |
| MC-CNN          | 7.48        | 0.73        | 2.80        | 94.35        | 90.18        |
| CNN Triplet-DNN | 7.09        | 2.67        | 10.22       | 94.65        | 90.67        |
| CMS-DTN         | 0.57        | <b>0.72</b> | <b>2.76</b> | <b>95.31</b> | <b>91.43</b> |

不仅显著低于 VGG16 (51.60G) 和 ResNet18 (5.80G) 等传统图像分类模型, 也远低于性能较为接近的 MC-CNN (7.48G) 和 CNN|Triplet-DNN (7.09G)。即使相比于高性能轻量化模型, 所提方法的 FLOPs 也仅为 MobileNetV3 (0.72G) 的 79% 和 LMSC (0.83G) 的 69%, 表明本文方法在复杂度与精度之间实现了最佳平衡。

表2 不同时-频分辨率输入下模型性能比较

| 输入尺寸      | 方法              | FLOPs(G) | 平均准确率(%) |        |
|-----------|-----------------|----------|----------|--------|
|           |                 |          | 型号识别     | 飞行状态识别 |
| 512×320×2 | MobileNetV3     | 0.72     | 94.23    | 89.82  |
|           | LMSC            | 0.83     | 94.28    | 90.09  |
|           | MC-CNN          | 7.48     | 94.35    | 90.18  |
|           | CNN Triplet-DNN | 7.09     | 94.65    | 90.67  |
|           | CMS-DTN         | 0.57     | 95.31    | 91.43  |
| 256×320×2 | MobileNetV3     | 0.36     | 93.61    | 88.73  |
|           | LMSC            | 0.41     | 93.98    | 89.47  |
|           | MC-CNN          | 3.72     | 93.95    | 89.45  |
|           | CNN Triplet-DNN | 3.55     | 94.25    | 89.86  |
|           | CMS-DTN         | 0.29     | 95.23    | 91.21  |
| 128×320×2 | MobileNetV3     | 0.36     | 93.19    | 87.58  |
|           | LMSC            | 0.41     | 93.32    | 88.87  |
|           | MC-CNN          | 3.72     | 93.55    | 88.89  |
|           | CNN Triplet-DNN | 3.55     | 93.90    | 89.21  |
|           | CMS-DTN         | 0.29     | 94.74    | 90.56  |

#### 4.5 时-频分辨率压缩实验

为深入探究所提方法对输入时域与频域信息的依赖程度, 并评估其在数据压缩场景下的实用性, 本文进行了时-频分辨率压缩实验。基准输入尺寸为 512×320×2 的复数时频图, 分别将其频率轴和时间轴分辨率压缩至一半, 得到 512×160×2 和 256×320×2 的输入, 观察模型性能的变化。本文选取了先前实验中性能较优的 MobileNetV3、LMSC、MC-CNN 和 CNN|Triplet-DNN 与所提方法进行对比。

如表2所示, 在输入层面, 所有模型对时间轴(x轴)压缩都表现出较高的敏感性, 而当频率轴(y轴)分辨率减半时, 性能下降幅度则相

对较小, 这与射频跳频信号在时间维度上特征高度集中, 而在频率维度上相对发散的物理特性完全吻合。在模型性能对比层面, 所提方法在时间轴压缩时性能下降最少, 而在频率轴压缩时性能几乎不受影响。这证明了所提方法对输入分辨率变化的强鲁棒性, 同时也表明在需要进一步压缩数据的场景中, 可以优先考虑降低频率轴分辨率, 此时所提方法能在确保精度的前提下, 实现推理速度的倍增。

#### 4.6 消融实验

为进一步验证本文所提出模型中各核心组件的有效性, 本文进行了消融实验研究, 所有实验均在相同的数据集与训练设置下进行。本文从定量性能指标与定性注意力可视化两个维度, 系统评估了移除或替换关键模块对模型识别性能的影响。首先, 如表3所示, 移除 CMS 模块(用普通卷积层代替)导致了最显著的性能下降, 型号识别准确率降低 1.96%, 飞行状态识别准确率降低 3.77%, 尽管计算量从 0.57G 降至 0.49G, 但识别精度的损失远超计算收益的代价。其次, CMS 模块内部采用复数卷积实现射频信号 I/Q 两路信息的联合建模, 为验证该设计的必要性, 本文进一步进行了模块内组件消融。结果表明, 单独移除复数卷积(保留 CMS 框架但改用实值卷积)同样造成性能退化, 型号识别准确率降低 1.01%, 飞行状态识别准确率降低 1.80%。

同时, 为进一步验证 CMS 及其内部模块的有效性, 本文使用 GradCAM 工具, 从注意力可视化角度进行深入评估。如图4所示, 对于同时存在 WIFI 和蓝牙干扰的双通道 I/Q 输入, 完整模型 CMS-DTN 的热力图(图4(c))呈现出高度聚焦的稀疏激活模式, 模型注意力精确集中于跳频信号所在的时频块, 对背景中的 WiFi 宽带干扰与蓝牙零星噪声几乎完全抑制。相比之下, w/o 复数卷积变体(图4(d))的热力图出现多焦点弥散现象, 在跳频信号周围存在次级激活区域, 这直



观验证了复数卷积通过联合建模 I/Q 相位耦合, 使匹配跳频模式的信号分量相干增强, 而失配的干扰分量因相位历程失配难以形成有效累积, 输出幅值相对较弱, 从而实现了稳定的相位选择性判别。此外, w/o CMS 模块变体 (图 4(e)) 的热力图则呈现全局性模糊响应, 模型无法建立稳定的跳频信号关注, 注意力在噪声基底上波动较大。上述定量指标与可视化结果共同验证, CMS 模块中的复数卷积与多尺度融合机制能够有效提取无人机 I/Q 信号的跳频特征, 从而在复杂电磁干扰环境下保持稳定的判别能力。

此外, 如表 3 剩余实验结果所示, 将 BiFPN-light 替换为标准 BiFPN 后, 模型计算量急剧增加, 但型号识别准确率反而下降 1.23%, 飞行状态识别下降 2.71%。这验证了本文轻量设计的合理性, 即标准 BiFPN 的多尺度特征冗余叠加在射频时频图这类单尺度密集预测任务中并非必要,

BiFPN-light 以轻量编码器和简化融合路径实现的高效特征复用, 能够以约 1/5 的计算成本实现更优的特征融合。最后, 移除动态损失值权重机制或用并联分类头取代级联指导, 对型号识别性能几乎无影响, 但飞行状态识别准确度出现明显下降。其原因在于动态加权机制缓解了飞行状态类别不平衡导致的梯度淹没, 级联指导结构则通过型号特征的高层语义注入, 为飞行状态判别提供了先验约束。两者的移除虽未损害主任务, 但一定程度上破坏的多任务协同的稳定性, 导致飞行状态识别性能降低。

## 5 结束语

针对时频域非平稳多尺度特征提取以及型号与飞行状态双任务识别问题, 本文提出一种新型的无人机射频信号识别方法。该方法通过 CMS 模块耦合 I/Q 信号保留相位关系, 抑制电磁干扰,




图4 消融实验模型注意力可视化

表3 不同模型变体的性能对比

|                   | FLOPs(G) | 平均准确率(%)     |              |
|-------------------|----------|--------------|--------------|
|                   |          | 型号识别         | 飞行状态识别       |
| <b>CMS-DTN</b>    | 0.57     | <b>95.31</b> | <b>91.43</b> |
| w/o 复数卷积          | 0.57     | 94.30        | 89.63        |
| w/o CMS 模块        | 0.49     | 93.35        | 87.66        |
| w/ BiFPN-standard | 2.71     | 94.08        | 88.72        |
| w/o 难度自适应加权       | 0.57     | 95.28        | 90.21        |
| 并联分类头             | 0.57     | 95.30        | 90.28        |


并融合不同时频尺度特征；设计BiFPN-light提升特征传导与融合效率；通过级联双流分类头以及难度感知损失值加权算法实现双任务间交互与平衡。实验结果表明，所提方法在已知类识别场景下已具备较高性能，后续研究将重点拓展至未知类识别判别框架，以进一步提升模型在实际场景中的应用价值。

## 参考文献:

- [1] Dorling K, Heinrichs J, Messier G G, et al. Vehicle routing problems for drone delivery[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2016, 47(1): 70-85.
- [2] Tesauo L L. Drone incident reporting in the United States: the impact it has on the overall domestic drone threat[D]. Saint Leo: Saint Leo University, 2025.
- [3] Hommes A, Shoykhetbrod A, Noetel D, et al. Detection of acoustic, electro-optical and RADAR signatures of small unmanned aerial vehicles[C]//Target and Background Signatures II. Bellingham: SPIE Press, 2016, 9997: 999701.
- [4] Shi Z G, Chang X Y, Yang X Q, et al. An acoustic-based surveillance system for amateur drones detection and localization [J]. IEEE Transactions on Vehicular Technology, 2020, 69(3): 2731-2739.
- [5] Guvenc I, Koohifar F, Singh S, et al. Detection, tracking, and interdiction for amateur drones[J]. IEEE Communications Magazine, 2018, 56(4): 75-81.
- [6] 俞宁宁, 毛盛健, 周成伟, 等. DroneRFa: 用于侦测低空无人机的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 dataset of drone radio frequency signals for detecting low-altitude drones[J]. Journal of Electronics & Information Technology, 2024, 46(4): 1147-1156.
- [7] Liu H C, Bi J, Wang X M, et al. A transformer-based conditional GAN with multiple instance learning for UAV signal detection and classification[J]. arXiv preprint arXiv:2507.14592, 2025.
- [8] 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. Piscataway: IEEE Press, 2019: 1-13.
- [9] Nie W, Han Z C, Li Y, et al. UAV detection and localization based on multi-dimensional signal features[J]. IEEE Sensors Journal, 2021, 22(6): 5150-5162.
- [10] 聂伟, 张中洋, 杨小龙, 等. 基于梅尔倒谱系数的无人机探测与识别方法[J]. 电子与信息学报, 2025, 47(4): 1076-1084.  
Nie W, Zhang Z Y, Yang X L, et al. Unmanned aerial vehicles detection and recognition method based on Mel Frequency Cepstral Coefficients[J]. Journal of Electronics & Information Technology, 2025, 47(4): 1076-1084.
- [11] Al-Iqubaydhi N, Alenezi A, Alanazi T, et al. Deep learning for unmanned aerial vehicles detection: a review[J]. Computer Science Review, 2024, 51: 100614.
- [12] Allahham M S, Khattab T, Mohamed A. Deep learning for RF-based drone detection and identification: a multi-channel 1-D convolutional neural networks approach[C]//2020 IEEE International Conference on Informatics, IoT, and Enabling Technologies (ICIoT). Piscataway: IEEE Press, 2020: 112-117.
- [13] Al-Emadi S, Al-Senaïd F. Drone detection approach based on radio-frequency using convolutional neural network[C]//2020 IEEE International Conference on Informatics, IoT, and Enabling Technologies (ICIoT). Piscataway: IEEE Press, 2020: 29-34.
- [14] Cai Z R, Liu Z Y, Kou L. Reliable UAV monitoring system using deep learning approaches[J]. IEEE Transactions on Reliability, 2021, 71(2): 973-983.
- [15] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[J]. arXiv preprint arXiv:1409.1556, 2014.
- [16] He K M, Zhang X Y, Re S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 770-778.
- [17] Glüge S, Nyfeler M, Aghaebrahimian A, et al. Robust low-cost drone detection and classification using convolutional neural networks in low SNR environments[J]. IEEE Journal of Radio Frequency Identification, 2024.
- [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] Zhu F F, Zhou F H, Ding R, et al. Lightweight neural network with fixed classifier for enhanced drone RF signal recognition [J]. IEEE Transactions on Cognitive Communications and Networking, 2025, 12: 1905-1917.
- [20] Howard A, Sandler M, Chu G, et al. Searching for Mobilenetv3 [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2019: 1314-1324.
- [21] Nguyen V B, Nguyen-Ngoc A T, Hoang V P, et al. RF-based drone classification using multi-scale convolutional neural network[J]. IEEE Internet of Things Journal, 2026. DOI: 10.1109/JIOT.2026.3687500.
- [22] 赵慎, 李广选, 周鲜成, 等. 多无人机射频信号 CNN/Triplet-DNN 异构网络特征提取与机型识别[J]. 电子与信息学报, 2026, 48(3): 1230-1240.
- Zhao S, Li G X, Zhou X C, et al. Multi-UAV RF signals CNN/Triplet-DNN heterogeneous network feature extraction and type recognition[J]. Journal of Electronics & Information Technology, 2026, 48(3): 1230-1240.
- [23] Quan Y H, Chen Y X, Shao Y Z, et al. Image denoising using complex-valued deep CNN[J]. Pattern Recognition, 2021, 111: 107639.
- [24] Tan M X, Pang R M, Le Q V. Efficientdet: scalable and efficient object detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 10781-10790.
- [25] Wang Q L, Wu B G, Zhu P F, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 11534-11542.
- [26] Swinney C J, Woods J C. Dronedetect dataset: a radio frequency dataset of unmanned aerial system (Uas) signals for machine learning detection & classification[J]. IEEE Dataport, 2021.
- [27] Wang Q X, Sun Y Z, Wang Z F, et al. Model-based RF fingerprint extraction approach for robust IoT device identification [J]. IEEE Internet of Things Journal, 2025, 12(12): 21915-21930. doi: 10.1109/JIOT.2025.3549231.
- [28] Ma N N, Zhang X Y, Zheng H T, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design[C]//European Conference on Computer Vision. Berlin: Springer Press, 2018: 122-138.
- [29] Tan M X, Le Q. Efficientnetv2: smaller models and faster training[C]//International Conference on Machine Learning. New York: ACM Press, 2021: 10096-10106.
- [30] Sandler M, Howard A, Zhu M L, et al. Mobilenetv2: inverted residuals and linear bottlenecks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2018: 4510-4520.
- 姜晨希 (2001-), 男, 浙江工业大学信息工程学院硕士生, 主要研究方向为无人机安全与人工智能。



智能。

陈永毅 (1997-): 男, 博士, 浙江工业大学信息工程学院助理研究员, 主要研究方向为工业大数据分析、故障诊断、健康医疗与人工智能。

张丹 (1985-), 男, 博士, 浙江工业大学信息工程学院教授, 主要研究方向为工业互联网与人工智能。

