

# 宽度学习驱动的跨时间域无人机个体增量识别

孟玟好<sup>1</sup>, 齐佩汉<sup>2</sup>, 刘新阳<sup>2</sup>, 潘晨露<sup>2</sup>

(1. 西安电子科技大学杭州研究院, 杭州 311231; 2. 西安电子科技大学通信工程学院, 西安 710071)

**摘要:** 智能信号识别技术能够有效提升无人机(Unmanned aerial vehicle, UAV)个体识别的性能,但在实际应用中仍受到信道时变性与特征迁移性的显著制约。针对低空智联环境射频指纹识别在时变信道中面临的泛化性退化问题,本文提出一种宽度学习驱动的跨时间域无人机个体增量识别方法。该方法以融合多尺度非对称卷积的残差网络作为骨干预训练模型,引入宽度学习对跨时间的目标域进行持续增量学习,并结合可学习特征融合与经验回放机制协同抑制跨时间域特征漂移。实验结果表明,本文方法在源域与跨时间域的个体识别准确率均达到90%以上,较基准算法提升超过20%,有效缓解了时变迁移对识别性能的不利影响,为复杂环境下的无人机身份辨识与非法检测提供了可靠的技术支撑。

**关键词:** 无人机识别; 宽度学习; 跨时间域; 多尺度网络; 特征融合

**中图分类号:** TP391      **文献标志码:** A

**引用格式:** 孟玟好, 齐佩汉, 刘新阳, 等. 宽度学习驱动的跨时间域无人机个体增量识别[J]. 数据采集与处理, 2026, 41(3): 663-673. MENG Wenyu, QI Peihan, LIU Xinyang, et al. Broad learning-driven cross-time-domain incremental UAV individual identification[J]. Journal of Data Acquisition and Processing, 2026, 41(3): 663-673.

## 引言

随着低空经济的蓬勃发展,无人机凭借机动性强、成本效益高等优势,在智慧农业、环境监测及公共安全等领域展现出广阔的应用前景<sup>[1-3]</sup>。然而无人机应用规模的持续扩大使得空域管理日趋复杂,加之飞行审批制度与监管手段尚不健全,导致“黑飞”、非法侦察及隐私侵犯等恶性事件频发,严重威胁低空安全与公共秩序<sup>[4]</sup>。因此,针对低空空域开展高效、精准的无人机监管与身份识别已成为保障低空智联安全的迫切需求。

当前无人机检测与识别的主流技术主要包括雷达检测<sup>[5]</sup>、声学探测<sup>[6]</sup>、视觉识别<sup>[7]</sup>和基于射频指纹(Radio frequency fingerprint, RFF)的识别4类方法。鉴于传统检测方式在复杂环境下的局限性,基于RFF的识别技术凭借非合作式、被动探测等优势,已成为国内外无人机监控领域主要研究方向<sup>[8]</sup>。该技术通过捕获无人机通信信号,提取硬件差异产生的唯一且难以伪造的细微特征,为个体身份辨识提供物理层基础。相比传统方法,RFF技术因其环境鲁棒性强、获取成本低、功耗小和隐蔽性高等优点,已成为低空智联中支撑军事射频态势感知与商业频谱智能管理的核心技术。

随着人工智能技术的发展,基于RFF的无人机识别经历了从手工特征到数据驱动的模式演进。相较于依赖专家知识的手工特征,以卷积神经网络(Convolutional neural network, CNN)、残差网络(Residual neural network, ResNet)及深度神经网络(Deep neural network, DNN)等为代表的深度学习模型已成

为主流<sup>[9]</sup>,实现了比传统方法更高精度的特征提取与个体识别。文献[10]通过小波分解结合轻量级CNN在多类无人机识别中达到了98%的准确率。文献[11]提出具备噪声容限的微型对比学习网络(Tiny contrastive learning network, Tiny-CLN),通过抗噪机制在仅包含25%~30%的定量参数下实现了资源受限的高精度小样本无人机识别。

在复杂多变的无线通信环境中,信道时变特性会对射频指纹产生扰动,导致同一设备在不同时间或地点的信号存在显著差异,使得静态训练范式下的深度学习模型易学习到特定环境噪声,难以适应动态时空差异,从而制约了识别系统泛化能力。为解决上述问题,增量学习(Incremental learning, IL)应运而生,该方法在预训练模型的基础上仅利用新样本进行部分参数更新,在保持识别精度的同时显著降低缓存与训练开销。然而灾难性遗忘<sup>[12]</sup>仍是增量学习面临的核心挑战,即模型在学习新任务时倾向于覆盖旧知识,导致对先前任务的识别性能急剧下降。现有研究主要通过以下机制缓解遗忘问题:(1)正则化约束,如文献[13]通过在损失函数中引入惩罚项限制重要权重修改,从而有效保护关键知识;(2)经验回放,如文献[14]提出的增量分类器和表示学习(Incremental classifier and representation learning, iCaRL)框架通过维护样本缓冲区并结合原型匹配策略,实现类别增量与知识留存;(3)知识蒸馏,如文献[15]通过局部交叉熵损失函数学习新类别,辅以知识蒸馏抑制历史知识的流失,并结合多样性正则化以拓宽特征空间的表征丰富度。

尽管上述方法在缓解灾难性遗忘方面取得一定成效,但在实际部署中仍受限于样本获取困难、标注成本高昂等小样本困境。宽度学习(Broad learning, BL)凭借其扁平化架构、动态节点扩展及高效解析的特性,为射频指纹的小样本动态适应提供了有效途径。文献[16]提出的知识图谱驱动的增量宽度学习框架通过构建信号特征间的关联知识图谱,显著提升了模型在极小样本约束下的识别效能与增量迭代效率。然而,上述研究多假设数据来源于相同的信道环境,未充分考虑实际部署中信号采集跨越数周甚至数月的现实:温度、湿度及电磁背景的动态变化引入显著信道时变效应,使得同一设备在不同时段呈现差异化的射频指纹分布,即形成不同的“时间域”。现有BL领域研究多聚焦于独立同分布场景,对跨时间域环境下的信道演变引发的特征分布漂移问题关注不足,常规的增量策略应对此类非平稳特征时,往往难以兼顾新知识获取与旧知识留存的平衡。

针对上述挑战,本文提出一种宽度学习驱动的跨时间域无人机识别方法。首先基于多尺度残差网络构建源域预训练模型,通过引入非对称卷积核以捕获信号中多维度的稳健指纹特征;随后在预训练模型基础上融入宽度学习架构,利用门控循环单元对骨干网络与信念网络提取的异构特征进行加权融合;最后结合参数冻结策略与知识回放机制,在仅需微调极少参数的条件下,显著提升了模型在跨时间场景中的泛化性能与识别稳定性。

## 1 问题描述与系统模型

### 1.1 问题描述

本文应用场景为低空智联环境下的无人机身份监管,监管方由地面接收站被动截获无人机的广播式自动相关监视信号(Automatic dependent surveillance-broadcast, ADS-B),经解调与预处理后提取I/Q分量作为识别输入。数据由地面站采集,源域和目标域标签由操作人员结合飞行日志校核标注。在实际部署中,信号采集跨越数周,信道环境的时变效应导致同一无人机在不同时段呈现差异化的射频指纹分布,增量识别旨在使模型适应目标域新分布的同时保持对源域知识的稳定记忆。在上述场景下,识别性能的核心挑战来源于信号传播的物理过程。其中,由于相噪、数模变换(D/A)、功率放大器及滤波器等器件的非线性因素共同作用,各无人机通信发射机形成唯一可辨的射频指纹特征。在信号采集阶段,所采集的信号除包含目标调制信息和指纹特征外,往往会受到信道噪声等因素干扰,接收端接收的信号 $x$ 可表示为

$$x = g_k(d; s) \otimes h + n \tag{1}$$

式中:  $g_k$  代表第  $k$  个无人机通信发射机模型, 其中包含调制信息数据  $d$  和目标个体的指纹特征信息  $s$ ;  $h$  表示信道脉冲响应;  $n$  为信道中的噪声; “ $\otimes$ ”表示卷积操作。接收端经过预处理获取信号中的同相分量  $x_i$  和正交分量  $x_q$ , 作为后续识别工作的输入。假设有  $C$  类无人机目标, 对每类无人机分别采集  $m$  个信号样本: 首日的数据集作为源域数据集, 定义类标签集合为  $L = \{L_1, L_2, \dots, L_C\}$ , 每一类集合  $L_i = \{l_1, l_2, \dots, l_m\}$ ; 新增日期的数据集作为目标域, 定义新增日期的数据集集合  $R = \{R_1, R_2, \dots, R_n\}$ , 其中  $R_i$  代表第  $i$  天采集的数据。

本文定义单个发射器收集的信号数据  $x$  的样本空间为  $X$ , 定义  $Y$  为  $X$  的类别空间,  $y(y \in Y)$  是其对应的类别标签。在传统个体识别问题中, 源域数据集  $D_1$  定义为  $D_1(x_i, y_i), i = 1, 2, \dots, n_1$ , 其中  $n_1$  表示  $D_1$  的样本量, 主要任务是找到一个模型  $p(\cdot)$  和一组参数, 以最大化它们在该数据集上的联合概率分布, 即

$$\max \prod_{i=1}^{n_1} p(y_i | x_i, \theta) \tag{2}$$

式中  $\theta$  表示源域预训练初始参数。

辐射源个体识别任务通常具有持续性的特点, 需要模型在长时间跨度的动态环境中维持有效性性与鲁棒性。针对目标域数据集  $D_2(x'_j, y'_j), j = 1, 2, \dots, n_2$ , 其中  $n_2$  表示  $D_2$  的样本量, 使用增量学习技术使得模型同时拟合  $D_1$  和  $D_2$  上的数据分布, 即最大化模型在  $D_1$  和  $D_2$  上的联合概率分布, 即

$$\max \prod_{i=1}^{n_1} p(y_i | x_i, \theta^*) \prod_{j=1}^{n_2} p(y_j | x_j, \theta^*) \tag{3}$$

式中  $\theta^*$  表示跨时间域宽度学习后的最优参数。

### 1.2 系统模型

本文面向跨时间域无人机个体识别任务, 提出一种宽度学习驱动的增量识别方法, 以应对信道时变及持续学习能力不足等问题。如图1所示, 该系统由特征提取、深度特征编码与增量式宽度学习三大模块构成。特征提取模块依托多尺度残差网络提取输入 I/Q 信号的稳健射频指纹; 深度特征编码模块采用精简深度信念网络压缩骨干特征进行降维压缩, 提取低维隐空间表征; 增量式宽度学习模块通过可学习门控机制将骨干特征与编码特征加权融合, 并利用增强层的动态扩展与岭回归解析求解实现对新知识的快速研究。该架构无需对全局模型进行迭代重训, 在确保识别精度的同时, 显著提升了在动态环境下模型持续学习的效率。

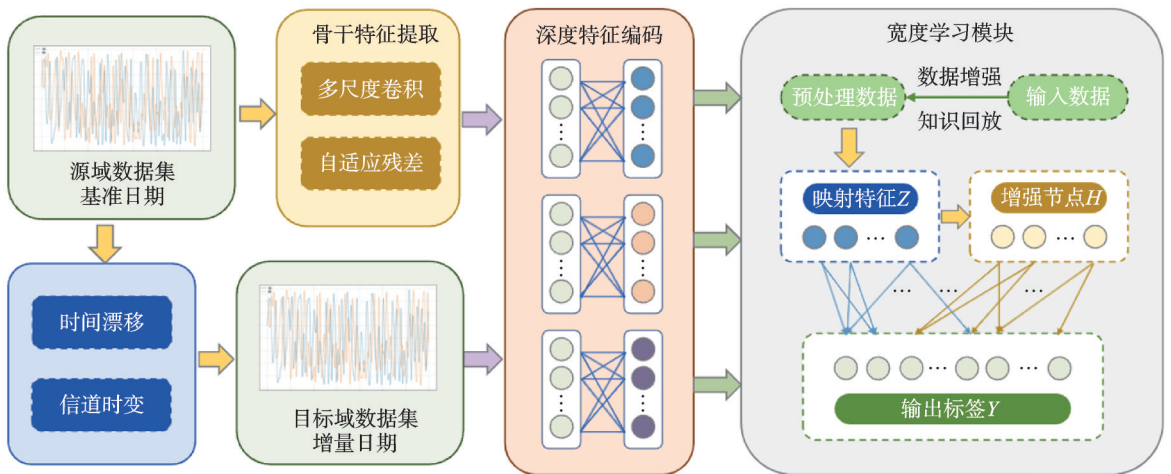


图1 本文系统的总体框架

Fig.1 Overview framework of the proposed system

## 2 跨时间域无人机识别方法

针对跨时域无人机个体识别任务,主流深度学习方法因其“黑箱”特性导致可解释性不足,制约了工程化应用。为此,本文提出一种基于宽度学习的增量识别方法,依托多尺度残差网络提取多层次稳健特征,通过动态扩展增强节点实现模型容量的灵活调整。该策略在显著降低计算开销的同时,强化了特征权重的可解释性,保障了模型在跨时域条件下的识别稳定性。

### 2.1 网络特征

网络特征提取由多尺度残差网络(Multi-scale residual network, MS-ResNet)与深度信念网络(Deep belief network, DBN)协同完成。MS-ResNet以ResNet18为原型演进为并行多分支架构,通过配置不同尺度的时域卷积算子协同捕获信号从局部纹理到全局模式的多层次特征。为实现跨维度的特征传递与融合,本文引入了如图2所示的自适应残差模块,通过在跳跃连接中集成 $1 \times 1$ 卷积以实现通道匹配与维度对齐,缓解深层梯度消失的同时强化射频指纹细微特征的代表精度。DBN则对MS-ResNet特征进行高阶抽象与降维压缩,二者异构互补,为后续宽度学习提供多维度判别性特征支撑。

DBN用于对骨干特征进行高阶抽象与降维。标准DBN由多层受限玻尔兹曼机(Restricted Boltzmann machine, RBM)堆叠而成,其核心机制在于通过能量函数建模可见层与隐藏层神经元间的联合概率分布。对于给定状态集 $E(V, H)$ ,能量函数定义为

$$E(V, H) = - \sum_{i=1}^{n_v} m_i V_i - \sum_{j=1}^{n_h} n_j H_j - \sum_{i=1}^{n_v} \sum_{j=1}^{n_h} V_i Q_{j,i} H_j \quad (4)$$

式中: $V$ 与 $H$ 分别表示可见层与隐藏层神经元状态, $m$ 、 $n$ 为偏置, $Q$ 为连接权重, $n_v$ 和 $n_h$ 分别表示可见层节点数和隐藏层节点数。RBM通过最大化似然函数学习数据的概率分布,其隐藏层输出可作为下一层的网络输入,通过逐层堆叠构成DBN,实现对特征的无监督逐层抽象。本文采用简化DBN架构,以多层全连接网络替代传统RBM堆叠结构,实现对骨干特征的压缩编码与分类任务的联合优化。该设计在保留逐层抽象特性的基础上,提取低维隐空间特征,为后续模块提供紧凑且更具判别性的特征表示。

特征融合机制方面,由MS-ResNet提取的骨干特征与DBN编码特征经张量拼接后,通过门控机制实施自适应加权融合。该机制通过调节各维度特征的贡献度,在保留关键识别信息的同时有效抑制冗余噪声。模型既能通过MS-ResNet捕获多精度的时域指纹变化,又可借助DBN提炼高阶语义特征,通过全面挖掘数据的内在结构,为宽度学习提供高质量特征,有效提升跨时间域无人机个体识别的精度与鲁棒性。

### 2.2 宽度学习

宽度学习系统(Broad learning system, BLS)采用扁平化神经网络结构,旨在缓解深度网络训练效率低及梯度消失等局限性,并具备高效的增量学习能力<sup>[17]</sup>,结构如图3所示。其核心机制是通过特征映射和随机映射非线性增强将输入投影至高维空间,并利用岭回归解析求解输出权重,规避了繁琐的反向传播过程。BLS中多数连接权重趋向于零,这一稀疏特性增强了模型的可解释性:特征节点强度反映了决策贡献度,增强节点则体现对复杂分布数据的扩展学习能力。此外,设计的宽度学习模块通过冻结骨干参数并局部更新,实现了模型计算效率与操作透明度的有机统一。

给定输入数据 $X \in \mathbf{R}^{N \times M}$ (其中 $N$ 表示样本数量, $M$ 表示变量数量),BLS应用线性变换来生成判别性特征表示。对于第 $i$ 个特征映射组 $Z_i$ ,表示为




图2 自适应残差模块

Fig.2 Adaptive residual block

$$Z_i = \varphi_i(XW_{ei} + e_{ei}) \quad (1)$$

式中:  $W_{ei}$  为随机初始化的权重矩阵,  $e_{ei}$  表示相应的偏置项,  $\varphi_i$  为非线性激活函数(如 sigmoid、ReLU 或双曲正切), 通过对数据进行投影来增强变换表达能力, 并得到一组映射特征输出  $Z \in \mathbf{R}^{N \times nk}$ , 其中  $n$  表示特征节点的分组数量,  $k$  表示每个特征映射分组中的特征节点数量, 即

$$Z = [Z_1, Z_2, \dots, Z_n] \quad (2)$$

增强节点  $H_j$  通过非线性变换从  $Z$  生成, 表示为

$$H_j = \zeta_j(ZW_{hj} + e_{hj}) \quad (3)$$

式中:  $W_{hj}$  和  $e_{hj}$  分别代表第  $j$  个增强节点对应的随机权重和偏置,  $\zeta_j$  为一个类似于  $\varphi_i$  的激活函数, 增强节点均表示为  $H \in \mathbf{R}^{N \times m}$ , 即

$$H = [H_1, H_2, \dots, H_m] \quad (4)$$

然后将  $Z$  和  $H$  合并, 形成  $A = [Z|H] \in \mathbf{R}^{N \times (nk+m)}$ , 则基础的 BLS 模型可以表示为

$$Y = [Z|H]W = AW \quad (5)$$

式中  $W$  表示输出权重矩阵, 可以通过最小化预测误差平方和来确定, 具体表示为

$$\arg \min_w \lambda \|W\|^2 + \|AW - Y\|^2 \quad (6)$$

式中:  $\lambda$  代表岭回归中与  $L_2$ -norm 相关的参数, 用于平衡偏差和方差;  $Y \in \mathbf{R}^{n \times c}$  表示输出矩阵。其中最优权重  $W$  的计算方法为

$$W = \lim_{\lambda \rightarrow 0} (\lambda I + AA^T)^{-1} A^T Y \quad (7)$$

式中  $I$  表示单位矩阵。与主要用于求解线性方程组最小二乘解的伪逆法不同, 岭回归法在最小二乘法的基础上引入了正则化项, 不仅能够避免矩阵求逆过程中的数值不稳定问题, 还能通过调节正则化参数  $\lambda$  实现对模型拟合能力与泛化性能的平衡。具体而言, 当  $\lambda$  取值较小时, 模型更接近普通最小二乘解, 拟合程度较高; 当  $\lambda$  增大时, 正则化效果增强, 模型参数趋向平滑, 对噪声的抵抗能力提升, 这种灵活性使得宽度学习系统能够适应不同复杂度的分类任务。

本文方法先以冻结的 MS-ResNet 与 DBN 提取融合特征, 再经由 BLS 特征映射、增强节点扩展及岭回归解析求解完成增量更新, 最后结合回放缓冲区微调输出权重, 实现跨时间域的个体稳定识别。

### 3 实验验证

#### 3.1 数据准备与参数设置

为验证所提无人机增量识别方法的有效性, 本文构建了一个具有显著时间偏移特性的实采 ADS-B 信号数据集。实验采集地点位于室外开阔测试场, 接收端为 USRP X310 配合 VERT900 天线, 架设于地面固定站; 采集目标为 21 架常见民用多旋翼无人机, 均搭载 ADS-B 机载发射装置。无人机 ADS-B 系统信号采用 Mode S 1090ES 数据链, 经预处理剔除 ICAO 标识符后提取 I/Q 分量作为输入。数据集覆盖基准期  $T_0$  以及跨度为 4 至 6 周的 3 个后续时段  $T_1 \sim T_3$ 。实验将首日  $T_0$  采集的 10 500 个样本(每类 500 个)作为源域, 按 7:1.5:1.5 的比例划分为训练集、验证集与测试集;  $T_1 \sim T_3$  作为目标域, 每类包含 50 个信号样本, 旨在模拟真实环境下无人机个体指纹随时间漂移的增量识别场景。数据集详细参数如表

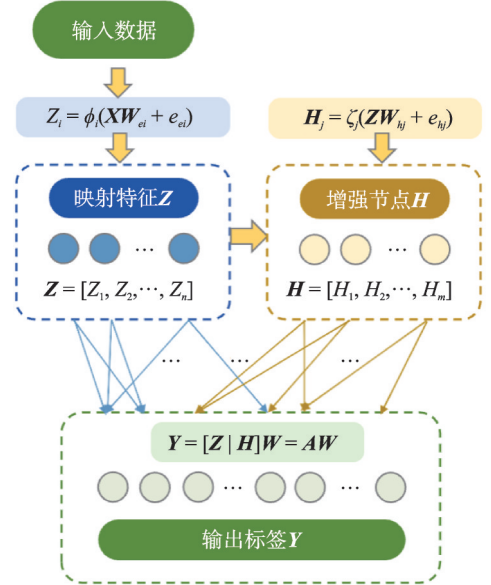


图3 宽度学习系统模型

Fig.3 Broad learning system model

1所示。

本文使用的实验硬件平台CPU为Intel(R) Core (TM) i7-10875H, GPU为NVIDIA GeForce RTX 2080, 软件开发环境为Python3.11.0、Pythorch2.5.1和CUDA 12.1的深度学习架构。基线模型在引入多尺度卷积的ResNet18网络模型上进行预训练,采用交叉熵损失函数作为损失函数,使用Adam优化器进行网络参数更新,训练过程中设置批量大小为32,训练周期设置为100轮,学习率采用步进衰减策略,初始值设为0.001,早停耐心值设为10,每经过5次早停计数周期按0.5倍系数进行衰减。为了缓解增量学习过程中的灾难性遗忘,构建最大容量500的回放缓存,初始设置源域每类加载20个样本,目标域每类加载10个样本,正则化系数 $\lambda$ 设为 $1e^{-3}$ 。

### 3.2 性能分析

#### 3.2.1 源域与目标域性能评估

为验证本文方法在跨时间域场景下的有效性,实验以仅在源域 $T_0$ 上训练的模型为基线,采用日期递归增量学习策略,模型更新阶段以目标域日期后缀进行标识,不同模型识别准确率(Accuracy, Acc)如表2所示。实验结果表明,随着采集时间跨度的增加,基线模型在未见域上的适应性呈显著下降趋势。引入本文提出的宽度增量学习方法后,模型在各目标域上的识别性能较基线算法均有大幅提升(增幅普遍逾20%),且更新后的模型在源域及已学习的历史目标域上均能维持90%以上的准确率,证明了本文方法在提升新域自适应能力的同时,能够有效抑制灾难性遗忘。

表2 跨时间域无人机增量识别方法识别准确率对比

Table 2 Recognition accuracy comparison of the cross-time-domain incremental UAV identification method

识别模型	$T_0$	$T_1$	$T_2$	$T_3$
基线	99.44	63.43	51.40	50.40
IBL <sub>1</sub>	95.31	96.80	75.00	57.20
IBL <sub>2</sub>	93.86	97.30	95.60	60.80
IBL <sub>3</sub>	93.79	93.30	97.70	94.40

值得关注的是,在对 $T_3$ 数据集的细分测试中,模型IBL<sub>2</sub>的性能(Acc=60.80%)受数据集重叠度与时间漂移的双重影响:在 $T_3$ 目标域中,5台曾在 $T_1$ 、 $T_2$ 出现且均参与增量更新的设备( $T_3=T_2+2$  days)识别准确率达94.40%,而另5台仅见于 $T_0$ ,未曾参与中间时段增量更新的设备( $T_3\approx T_0+6$  weeks),其识别准确率则大幅度降至27.2%。此现象对应了设备指纹特征随时间演变的物理规律,即信道漂移幅度与采集时间间隔呈正相关,进一步凸显了在低空智联环境开展跨时域增量识别研究的必要性。

#### 3.2.2 特征可视化

为深入探究所提方法在跨时间域任务中的特征分布特性,本文采用t分布随机邻域嵌入(t-Distributed stochastic neighbor embedding, t-SNE)对模型提取的高维语义特征进行降维与二维可视

表1 数据集参数

Table 1 Dataset parameters

参数名称	定义
调制方式	脉冲位置调制
载波频率/MHz	350
接收带宽/MHz	2
样本长度	30 000
无人机数量/架	21
飞行高度/m	5~10
飞行速度/(m·s <sup>-1</sup> )	5~15
收发距离/m	20~200
持续时间/s	5

化。其中源域样本以圆形标记,目标域样本以星形标记,以直观对比两域特征的分布关系,有效凸显不同类别样本间的相似性与判别边界。

图4展示了3组跨时间域任务( $T_0-T_1$ 、 $T_1-T_2$ 、 $T_2-T_3$ )的特征分布结果。由图4可见,在引入宽度增量学习后,源域与目标域样本在特征空间中的分布逐渐趋近,类别边界日益清晰,误分类点极少,其类内聚集性仍保持较高水平,且两域的样本几乎完全重叠,表明该方法即使在信道漂移显著及样本分布不平衡的条件下,依然能够维持较强的判别鲁棒性,这一现象与对应识别结果相一致。

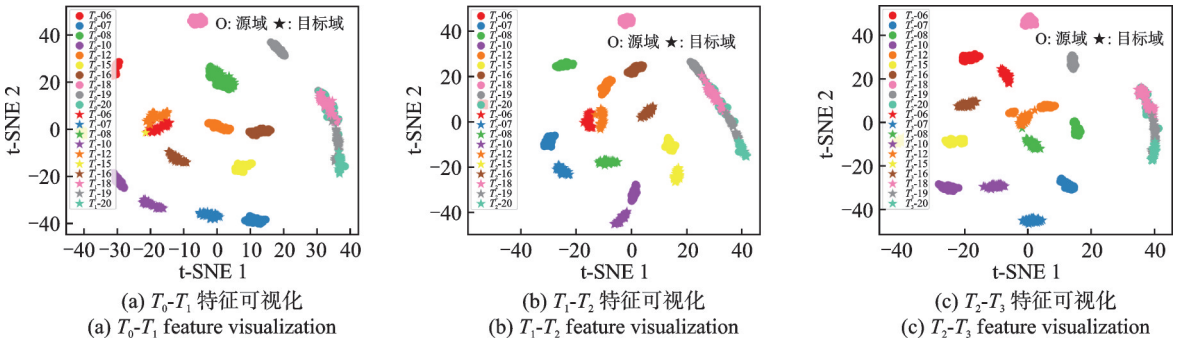


图4 t-SNE 特征可视化

Fig.4 t-SNE feature visualization

综上所述,t-SNE 可视化结果进一步验证了所提方法在缓解源域与目标域特征分布差异方面的有效性,并从特征空间视角佐证了其在跨时间域识别任务中具备良好的鲁棒性与泛化能力。

### 3.3 不同参数性能对比

为评估本实验所选参数的合理性,本文采用控制变量法在基线模型上对参数进行优选,以获得较优的识别性能。

#### 3.3.1 不同训练样本数量性能对比

训练样本量是衡量辐射源个体识别(Specific emitter identification, SEI)算法性能及其工程化部署可行性的核心指标。为探究本文方法在小样本约束下的鲁棒性,实验将目标域中单个辐射源的训练样本数  $n$  分别设为 5、10、20、30 和 50,并在保持其他超参数恒定的条件下进行评估,不同目标域的识别准确率对比结果如图 5 所示。实验结果表明,目标域识别性能随样本规模的扩大呈单调上升趋势,且性能增益逐步趋于饱和,证实了样本信息量对特征表征能力的提升具有正向促进作用。在持续增量学习框架下,模型对时变信号的特征提取能力稳步增强,展现出良好的泛化潜力。即便在极少样本( $n=10$ )的情况下,本文方法在目标域上仍能保持 90% 以上的识别准确率。综合考量识别性能与计算成本的平衡,实验选取  $n=10$  作为最优样本配置,以在保障算法高精度的同时,最小化工程化部署的计算复杂度。

#### 3.3.2 不同节点个数性能对比

在训练样本数量固定为 10 的场景下,本文进一步考察了特征节点和增强节点规模对模型识别精度




图5 不同样本数量下各目标域的准确率对比  
Fig.5 Accuracy comparison across target domains under different sample sizes

的影响,图6为特征节点数 $N_0$ 对各目标域的识别准确率的影响曲线。实验结果表明,随着 $N_0$ 从2增至32,模型在3个目标域上的识别性能均呈先升后降的趋势,并在 $N_0=8$ 时模型性能达到峰值。当特征节点规模较小时,随机映射产生的特征空间不足以提供充分的互补信息,难以对256维预训练深度特征形成有效增益;当 $N_0$ 过大时,随机投影引入的噪声成分随之增加,在小样本约束下极易诱发过拟合,削弱了深度判别特征的泛化优势。综上所述,实验验证了宽度学习中“适度随机映射”的设计准则,即仅需引入少量的额外随机映射节点即可显著增强模型的鲁棒性与特征表达能力。

在固定训练样本数 $n=10$ 且特征节点数 $N_0=8$ 的基础上,本文以 $T_1$ 目标域为典型场景,考察了增强节点配置对模型识别性能的影响。实验设置初始增强节点数 $N_1$ 分别为100、200和300,每步步进式新增20个节点,累加增强节点数 $N_2$ 增至200,实验结果如图7所示。实验结果表明,在累计新增节点数一致的情况下,初始节点数较大的配置展现出更高的识别准确率。这表明在样本受限条件下,初始增强节点数决定了模型的基础拟合能力与表征空间边界。随着扩展节点数的增加,不同初始配置间的性能差异显著收窄。当累计新增节点达到200个时,3组实验的准确率曲线呈现收敛态势,该现象说明扩展节点能够逐步补偿初始结构容量的不足,使模型最终逼近相近的性能上限。在硬件资源允许范围内,采用较大的初始增强节点数有助于模型在增量学习初期快速获得优异性能,且不改变最终的稳态精度。

综合上述实验分析,在兼顾算法识别性能与计算复杂度的前提下,后续实验将特征节点数 $N_0$ 固定为8,初始增强节点数 $N_1$ 和累计扩展增强节点 $N_2$ 分别固定为200和100。

### 3.4 不同增量学习方法性能对比

为了评估本文提出的方法在跨时间域方面的性能,本节将本文方法与3种典型增量学习方法进行对比:LWF<sup>[15]</sup>、EWC<sup>[18]</sup>和ER<sup>[19]</sup>方法。为确保公平比较,所有方法均采用相同的骨干网络结构,并在统一划分的源域与目标域数据集上进行训练。超参数配置均保持一致:采用Adam优化器,学习率设为0.001,迭代轮数为5,且不引入额外的数据增强或正则化约束。针对ER方法,回放缓冲区容量设为500,且用源域训练集进行初始化填充。为消除随机性影响,所有实验均通过50次蒙特卡洛独立重复实验获取平均识别准确率作为最终评估指标,对比结果如表3所示。表3实验结果表明,本文方法在跨时域识别任务中均显著优于对比方法。本文方法不仅在各目标域上取得了最高的识别精度,同时在源域性能保持方面也优于其他方案,证实了其在捕捉新域分布特征的同时,能更有效地抑制灾难性遗忘。在对比算法中,ER方法在保留源域性能方面表现出较强的稳健性,这验证了经验回放机制在缓解遗忘问题上的有效性,也为本文引入的知识回放策略提供了实证支撑。相比之下,EWC方法在源域上的性




图6 不同特征节点个数下各目标域的准确率对比

Fig.6 Accuracy comparison across target domains under different numbers of feature nodes




图7 不同增强节点准确率对比

Fig.7 Accuracy comparison under different numbers of enhancement nodes

能退化较为严重,表明基于单纯重要性约束的正则化策略在应对电磁信号大幅度时变迁移时,其表征调整灵活性受到一定限制。

#### 4 结束语

针对跨时间域下射频指纹不稳定性带来的识别挑战,本文提出了一种宽度学习驱动的无人机个体增量识别方法。该方法以多尺度残差网络为特征提取骨干,通过引入宽度学习机制实现目标域数据的持续增量学习。针对特征漂移,引入可学习门控机制自适应融合高低维特征,同时结合参数冻结与知识回放策略,在抑制灾难性遗忘的同时增强了跨时间域特征的判别力。实验结果表明,该方法在小样本及长跨度时间域场景下,其识别准确率、时间鲁棒性及泛化性能均优于现有基线模型,为资源受限下的无人机个体增量识别提供了有效解决方案。

#### 参考文献:

- [1] 中华人民共和国中央人民政府. 2024年政府工作报告[R]. 北京: 中华人民共和国中央人民政府, 2024.
- [2] 欧阳桃花. 低空经济的技术创新与场景创新[J]. 人民论坛·学术前沿, 2024(15): 57-68.  
OUYANG Taohua. Technological innovation and scenario innovation of low-altitude economy[J]. *Frontiers*, 2024(15): 57-68.
- [3] 王加琪, 王威. 多无人机强弱信号混叠下的检测与识别方法[J]. 数据采集与处理, 2025, 40(6): 1464-1476.  
WANG Jiaqi, WANG Wei. Detection and identification method for multiple UAVs with mixed strong weak signals[J]. *Journal of Data Acquisition and Processing*, 2025, 40(6): 1464-1476.
- [4] 陈黎. 从纳卡冲突看无人机/反无人机作战的未来发展[J]. 国防科技工业, 2021(1): 54-57.  
CHEN Li. On the future development of UAV/anti-UAV operations from the perspective of Naka conflict[J]. *Defence Science & Technology Industry*, 2021(1): 54-57.
- [5] 章鹏飞, 李刚, 霍超颖, 等. 基于双雷达微动特征融合的无人机分类识别[J]. 雷达学报, 2018, 7(5): 557-564.  
ZHANG Pengfei, LI Gang, HUO Chaoying, et al. Classification of drones based on micro-Doppler radar signatures using dual radar sensors[J]. *Journal of Radars*, 2018, 7(5): 557-564.
- [6] TEJERA-BERENGUE D, ZHU-ZHOU F, UTRILLA-MANSO M, et al. Acoustic-based detection of UAVs using machine learning: Analysis of distance and environmental effects[C]//Proceedings of 2023 IEEE Sensors Applications Symposium (SAS). Ottawa, ON, Canada: IEEE, 2023: 1-6.
- [7] LIU X, SHI R, GAO H, et al. An improved algorithm for infrared road object recognition in UAV perspective[J]. *Scientific Reports*, 2026, 16: 2377.
- [8] LIU G, XI Z, LIU R. A novel wireless interference identification and scheduling method based on convolutional neural network [C]//Proceedings of 2022 IEEE International Conference on Communications Workshops (ICC Workshops). Seoul, Korea: IEEE, 2022: 1-6.
- [9] 周锋, 杜奕航, 赵芸, 等. 基于度量学习和子域自适应的辐射源个体识别[J]. 电讯技术, 2025, 65(3): 347-353.  
ZHOU Feng, DU Yihang, ZHAO Yun, et al. Specific emitter identification based on metric learning and subdomain adaptation [J]. *Telecommunication Engineering*, 2025, 65(3): 347-353.
- [10] BREMNES K, MOEN R, YEDURI S R, et al. Classification of UAVs utilizing fixed boundary empirical wavelet sub-bands of RF fingerprints and deep convolutional neural network[J]. *IEEE Sensors Journal*, 2022, 22(21): 21248-21256.
- [11] ZHANG T, XU D, ALFARRAJ O, et al. Design of tiny contrastive learning network with noise tolerance for unauthorized

表3 本文方法与典型增量学习方法在各目标域下的识别准确率对比

**Table 3 Recognition accuracy comparison of the proposed method and typical incremental learning methods across target domains %**

方法	域名	$T_1$	$T_2$	$T_3$
LWF	源域 $T_0$	89.57	87.95	89.34
	目标域	80.90	69.70	89.90
EWC	源域 $T_0$	79.99	66.29	56.81
	目标域	78.39	79.80	92.93
ER	源域 $T_0$	90.42	90.30	96.91
	目标域	78.89	80.81	92.93
本文方法	源域 $T_0$	98.27	94.38	93.25
	目标域	<b>93.20</b>	<b>96.80</b>	<b>96.60</b>

- device identification in Internet of UAVs[J]. *IEEE Internet of Things Journal*, 2024, 11(12): 20912-20929.
- [12] IVANOV L I, OBUKHOVA N A, BARANOV P S. Review of modern UAV detection algorithms using methods of computer vision[C]//*Proceedings of 2020 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIconRus)*. St. Petersburg and Moscow, Russia: IEEE, 2020: 322-325.
- [13] ZHANG J, ZHANG J, GHOSH S, et al. Class-incremental learning via deep model consolidation[C]//*Proceedings of 2020 IEEE Winter Conference on Applications of Computer Vision (WACV)*. Snowmass, CO, USA: IEEE, 2020: 1120-1129.
- [14] KANAKIS M, BRUGGEMANN D, SAHA S, et al. Reparameterizing convolutions for incremental multi-task learning without task interference[C]//*Proceedings of Computer Vision—ECCV 2020*. Cham: Springer, 2020: 689-707.
- [15] 刘展阳, 刘进锋. 基于知识蒸馏的不存储旧数据的类增量学习[J]. *计算机应用*, 2024, 44(S2): 12-17.  
LIU Zhan yang, LIU Jin feng. Data-free class incremental learning based on knowledge distillation[J]. *Journal of Computer Applications*, 2024, 44(S2): 12-17.
- [16] HUA M, ZHANG Y, ZHANG Q, et al. KG-IBL: Knowledge graph driven incremental broad learning for few-shot specific emitter identification[J]. *IEEE Transactions on Information Forensics and Security*, 2024, 19: 10016-10028.
- [17] PHILIP CHEN C L, LIU Z. Broad learning system: An effective and efficient incremental learning system without the need for deep architecture[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(1): 10-24.
- [18] WANG S, LUO X. Incremental learning method for lung nodule detection based on EWC and feature distillation[C]//*Proceedings of International Conference on Biomedical and Intelligent Systems (IC-BIS 2022)*. Chengdu, China: SPIE, 2022: 39.
- [19] DENG Z, LI C, SONG R, et al. Centroid-guided domain incremental learning for EEG-based seizure prediction[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 2500613.

## 作者简介:



孟致婷(2002-),女,硕士研究生,研究方向:深度学习、智能信号处理,E-mail: a2511104771@126.com。



齐佩汉(1986-),通信作者,男,教授,研究方向:智能通信信号处理和人工智能攻防,E-mail: phqi@xidian.edu.cn。



刘新阳(2000-),男,硕士研究生,研究方向:智能雷达探测。



潘晨露(2002-),女,硕士研究生,研究方向:通信信号参数智能并行提取。

(编辑:张黄群)

## Broad Learning-Driven Cross-Time-Domain Incremental UAV Individual Identification

MENG Wenyu<sup>1</sup>, QI Peihan<sup>2\*</sup>, LIU Xinyang<sup>2</sup>, PAN Chenlu<sup>2</sup>

(1. Hangzhou Institute of Technology, Xidian University, Hangzhou 311231, China; 2. School of Telecommunications Engineering, Xidian University, Xi'an 710071, China)

**Abstract:** Intelligent signal recognition technologies can effectively enhance the performance of individual unmanned aerial vehicle (UAV) identification. However, their practical deployment is significantly constrained by time-varying channel effects and feature distribution drift across domains. With the rapid development of the low-altitude economy, UAV safety supervision urgently demands reliable identity authentication mechanisms. Radio frequency fingerprint (RFF) identification, while inherently difficult to forge owing to hardware uniqueness, suffers from severe feature drift in time-varying channels typical of low-altitude intelligent networks. This drift leads to the catastrophic degradation of generalization in pre-trained models. To address this issue, we propose a broad learning-driven method for cross-time-domain incremental identification of individual UAVs. This method adopts a residual network integrated with multi-scale asymmetric convolutions as the backbone, aiming to extract robust and multi-granularity fingerprint features directly from IQ signals. A broad learning system is subsequently introduced as an incrementally updatable classifier; it rapidly updates model weights for new time-domain data by leveraging the generalized inverse matrix, thereby circumventing catastrophic forgetting. Furthermore, a learnable feature fusion module and an experience replay mechanism are synergistically designed to suppress feature drift across time domains. Extensive experiments are conducted on real-world UAV RF signal datasets collected over multiple time spans, with intervals ranging from days to weeks. The results demonstrate that the proposed method achieves an identification accuracy exceeding 90% on both the source and cross-time domains, outperforming baseline algorithms by over 20%. Meanwhile, it maintains stable recognition performance on data from earlier time periods. The proposed approach effectively mitigates the adverse effects of time-varying domain shift, offering reliable technical support for continuous UAV identity recognition and the detection of unauthorized UAVs in complex environments.

### Highlights:

1. Broad learning-driven incremental model enables robust cross-time UAV identification.
2. Multi-scale convolutions and replay suppress cross-time feature drift.
3. Resolves catastrophic forgetting and accuracy degradation in time-varying channels.
4. Achieves over 90% accuracy in source and cross-time domains, and more than 20% over baselines.

**Key words:** UAV identification; broad learning; cross-time domain; multi-scale network; feature fusion

---

**Foundation items:** National Natural Science Foundation of China (No. 62171334); National Basic Scientific Research of China (No. JCKY2023110C099).

**Received:** 2026-03-13; **Revised:** 2026-05-05

**\*Corresponding author, E-mail:** phqi@xidian.edu.cn.