

基于时序注意力的不平衡辐射源个体识别方法

高龙, 吕友彬, 王麓娇, 张威, 李潞雨, 徐从安

(海军航空大学二院, 山东 烟台 264001)

摘要: 针对辐射源个体识别中存在的长尾分布显著、采样特征维度高的问题, 提出一种基于时序注意力的改进辐射源个体识别算法。通过构建多尺度特征融合模块整合不同时序粒度下的特征信息, 设计身份感知时序注意力模块, 通过生成并嵌入身份自适应注意力权重, 促使模型聚焦样本数量少的个体和身份相关时序特征。在实采 AIS 数据集和公开 ADS-B 数据集上的实验表明, 所提算法识别准确率分别达到 94.89% 和 93.23%, 且在 3 dB 低信噪比下准确率下降 2% 以内。

关键词: 辐射源个体识别; 长尾分布; 时序注意力; IQ 信号; 特征学习

中图分类号: TP391.41

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2026029

Method for imbalanced specific emitter identification based on temporal attention

Gao Long, Lyu Youbin, Wang Mengjiao, Zhang Wei, Li Tianyu, Xu Cong'an

No.2 School, Naval Aviation University, Yantai 264001, China

Abstract: To address the problems of prominent long-tailed data distribution and high-dimensional sampling features in specific emitter identification (SEI), an improved SEI algorithm based on temporal attention was proposed. By constructing a multi-scale feature fusion module to integrate feature information under different temporal granularities, and designing an identity-aware temporal attention module that generates and embeds identity-adaptive attention weights, the model was encouraged to focus on individuals with a small number of tail samples and identity-related temporal features. Experiments on the self-collected AIS dataset and public ADS-B dataset demonstrate that the proposed algorithm achieves recognition accuracies of 94.89% and 93.23% respectively, and the accuracy decreases by less than 2% under a low signal-to-noise ratio (SNR) of 3 dB.

Keywords: specific emitter identification, long-tailed distribution, temporal attention, IQ signal, feature learning

0 引言

随着全球海上交通运输的持续发展, 针对偷渔、走私、非法入侵等非协作式目标的身份识别已成为交通管控与安全保障的核心需求。此类目标常通过篡改船舶自动识别系统 (automatic identifica-

tion system, AIS)、广播式自动相关监视 (automatic dependent surveillance-broadcast, ADS-B) 的身份广播信息来躲避监管, 导致仅依靠 AIS/ADS-B 系统直接解读的目标数据失去可靠性。但在 AIS、ADS-B 或其他通信系统中, 其射频信号中均蕴含

收稿日期: 2025-11-27; 修回日期: 2026-01-26

通信作者: 徐从安, xcatougao@163.com

基金项目: 国家资助博士后人员计划基金资助项目 (No.GZC20233554); 国家自然科学基金资助项目 (No.62271499); 山东省泰山学者基金资助项目 (No.tsqn202312258)

Foundation Items: The National Funded Postdoctoral Program (No.GZC20233554), The National Natural Science Foundation of China (No.62271499), The Taishan Scholar (No.tsqn202312258)

由发射机硬件电路固有缺陷(如振荡器相位噪声、功率放大器非线性失真等)产生的独特指纹特征,这种物理层特征不受上层数据篡改的影响,为非协作式目标的真实身份溯源提供了关键依据^[1]。因此,作为提取并利用该类特征的核心技术,辐射源个体识别(specific emitter identification, SEI)在海上交通管理、航空监视等民用场景中发挥不可替代的作用,在频谱管理与网络安全等领域具有重要的研究价值与应用前景^[1-2]。

针对SEI任务,学术界已提出多种方法,总体上可划分为传统机器学习方法与深度学习方法两大类^[3-4]。传统机器学习方法主要依赖人工设计的统计特征,通常需要大量人力时间,且难以适配硬件缺陷导致的非线性特征,在复杂实际场景中往往表现有限。随着深度学习技术在特征自动学习领域的突破,SEI方法逐渐向数据驱动方向演进,相关学者围绕模型结构设计、关键特征强化等方面开展了系列研究。在结构设计方面,Ding等^[5]提出基于卷积神经网络(CNN)提取通用软件无线电外设(universal software radio peripheral, USRP)信号的双谱特征,通过监督降维后实现辐射源身份识别,以挖掘信号高阶统计特性中的指纹信息;Pan等^[6]将信号经希尔伯特变换转换为灰度图,实现了时域信号到空间特征的转化,再利用深度残差网络挖掘视觉差异完成SEI任务;Wong等^[7]通过卷积神经网络提取信号以同相/正交(in-phase/quadrature, IQ)不平衡特征,以充分利用硬件非线性引入的固有差异,为辐射源身份鉴别提供了新的特征维度;Wang等^[8]针对复数值卷积网络的计算负载问题,设计稀疏结构选择策略并结合知识蒸馏技术,在压缩模型规模的同时保障识别精度,兼顾了效率与性能;Tu等^[9]将复数值网络应用于自动调制分类,为复杂信号处理设计了基于复值神经网络的模型架构;段可欣等^[10]设计了融合双谱特征的雷达辐射源个体识别方法;Zhou等^[11]构建混合CNN-Transformer架构,通过在前端采用大核卷积模块捕捉射频信号的局部时频纹理特征,后端接入ViT模块实现全局特征依赖的建模,以提升识别准确率。在关键特征强化方面,Zhai等^[12]提出高频增强Transformer模型,通过在Transformer的注意力层前增加高频特征提取子模块,结合小波变换分离信号的高频分量并赋予更高权重,强化高频指纹的捕捉能

力。Qian等^[13]在多尺度神经网络中引入通道注意力机制,融合输出特征与原始信号构建多级字典,通过主成分分析实现稀疏表示识别,强化了关键特征的表征能力;谭凯文等^[14]提出融合代价敏感学习与半监督生成对抗网络(GAN)的SEI方法IC-SGAN,通过对抗生成进行数据增强,提升类不平衡及标签缺失下的识别准确率。这些方法均凭借数据驱动的自动特征提取能力,在不同应用场景下展现出优于传统方法的识别性能。

虽然相关研究已取得长足进步,但面向实采辐射源信号的SEI依然面临很多挑战。首先,数据分布呈现显著的长尾特性。由于船舶或航空器的运行模式高度不均衡,高频出现的部分个体样本充足,而大量低频个体(尾部个体)样本稀缺,部分个体的样本数在总样本中占比不足1%^[5]。这种长尾分布导致传统分类模型容易过拟合头部个体,而对尾部个体的识别准确率急剧下降。其次,信号特征维度高且结构复杂。AIS与ADS-B信号以IQ复数时序形式存在,其个体指纹主要体现在幅度、相位及其随时间变化的细微模式中。现有基于时频图、谱图等二维图像的分类方法在将一维IQ信号转换为二维表示的过程中会引入信息损失,且无法充分捕捉时序相关性^[8]。最后,实际电磁环境中的多径衰落、噪声干扰与频率偏移等因素进一步加大了特征提取的难度,尤其在低信噪比条件下,有效特征的提取更加困难^[15]。上述问题在实采数据中通常耦合出现,而非独立存在。如在使用辐射源信号接收器日常采集船舶信号过程中,AIS信号强度弱且船舶处于海面导致接收角度差,噪声干扰显著,且不同船舶繁忙程度不同导致个体数量存在较大差异。因此,亟待设计同时解决上述问题的算法以提高模型在真实任务上的实用性。

针对不平衡、噪声多、维度高等问题,现有方法主要从数据处理、模型设计和半监督学习3个方面开展研究^[1,10]。在样本不平衡方面,现有方法主要从生成对抗网络、损失函数优化等方面优化少数类个体的学习。例如,Zhang等^[16]提出结合生成对抗网络与格拉姆角场(Gramian angular field, GAF)方法,先通过GAF将一维时域射频信号映射为二维图像格式,以强化幅值关联特征的可视化表达,再利用GAN的生成器学习少数类样本的分布规律,以补充少数类个体信号样本;谭凯文等^[14]提出IC-

SGAN 设计代价敏感损失缓解优势样本导致的梯度传播失衡, 改善分类器在类不平衡数据集上的识别性能; Fu 等^[17]提出了半监督特定辐射源识别方法, 利用度量对抗训练技术, 有效利用未标记样本, 提高在长尾分布数据上的识别性能; Wang 等^[18]提出了自监督对比框架, 用于在有限标记数据条件下进行辐射源识别, 利用未标记样本提供辅助信息和正则化约束, 有效缓解了长尾分布问题; Zha 等^[19]提出解耦表示学习方法, 将网络训练分为特征学习与分类器平衡两个阶段, 通过第二阶段的重采样或重加权等方式纠正长尾分布带来的偏差。这些方法主要通过生成或重加权少数类个体以均衡不同类别对模型的影响, 这也是提升模型对少数类个体适配性的经典方法, 但未考虑通过结合个体身份信息实现少数类个体对模型的引导学习。在噪声鲁棒模型构建方面, 第一类方法在特征学习阶段动态抑制噪声。例如, Deng 等^[20]通过引入门控局部注意力模块, 利用门控机制过滤信号中的噪声等冗余局部特征, 仅保留与射频指纹强相关的分量, 以增强身份相关特征的学习效果; Xu 等^[21]提出了基于深度残差收缩网络的鲁棒辐射源识别方法, 能够有效处理噪声和不平衡数据, 提升了在长尾分布条件下的识别能力。这一类方法聚焦特征层面的噪声过滤, 且动态调整策略多为全局统一设置。第二类方法通过优化模型架构提升抗噪声能力。例如, Shi 等^[22]提出嵌入先验知识的 Transformer 方法, 通过将射频信号的先验知识编码为知识嵌入向量, 融入 Transformer 的自注意力层, 帮助模型在噪声干扰下聚焦有效指纹特征; Huang 等^[23]提出的信道鲁棒 Transformer 模型引入了信道归一化模块, 其对输入信号的信道特征进行实时估计与归一化, 消除信道畸变和噪声等对指纹特征的影响; Liu 等^[24]提出了通过深度集成学习进行多特征融合的辐射源识别方法, 提高了算法对低信噪比环境的鲁棒性。这一类方法通常引入特征提取能力更强的 Transformer 等模型或者用集成学习来提高特征学习的稳定性, 容易出现数据过拟合, 且较少考虑辐射源信号特点。第三类方法通过训练前处理数据以降低噪声影响。例如, Satija 等^[25]提出基于变分模态分解 (VMD) 的特征预处理方法, 通过 VMD 将信号自适应分解为多个本征模态分量, 依据分量的中心频率与能量占比筛选出含有效指纹的分量, 过滤噪声主导的冗余分量, 为后续深度学

习模型提供更纯净的输入特征; Tao 等^[26]针对标签噪声条件下的辐射源识别问题, 提出了样本选择和正则化技术, 通过最大期望 (EM) 和损失函数正则化, 提高了模型在噪声标签数据下的识别性能; 段可欣等^[27]针对噪声污染的问题, 提出无监督聚类识别错误标签结合有监督投票纠正的一体化解决方案。这些方法的筛选标准多为静态设置, 且双阶段方式缺乏端到端的有效协同。总体而言, 这些方法同样未考虑通过显性结合身份信息进行引导, 并且通常采用静态策略实现特征融合。

在高维特征方面, 辐射源接收器所采集时序数据多为采样点数高于 500 的高维数据, 这类数据虽能保留硬件非线性、无意调制等细微指纹信息, 但易伴随特征冗余、信息稀疏的问题。针对该问题, 常见解决方法为针对性设计深度学习网络结构。例如, 谭凯文等^[14]针对 1 000 维时序信号, 通过多尺度拓扑模块 (multiscale topological block, MTB) 提取不同尺度下的高维特征, 结合代价敏感损失缓解高维数据中类别不平衡带来的梯度偏差, 但该方法同时考虑了高维、长尾、白噪声等问题, 并以 GAN 为基础结构, 但需要大量数据训练且稳定性较差, 因此该方法对低噪声、少量个体的识别任务较为有效; Xu 等^[21]将 ADS-B 的 4 800 维高维 IQ 信号进行拼接, 采用残差收缩网络的软阈值机制, 剔除高维数据中的噪声特征, 以提高噪声鲁棒性, 但该方法基于所构造个体数量相对较少的平衡数据集进行验证, 未考虑长尾分布, 因此也未考虑对少数个体的加权; Wang 等^[28]提出单一模型难以兼顾局部细节特征和全局依赖关系, 针对 2 034 维输入信号设计 CNNFormer 模型优化编码机制, 通过 CNN 残差网络提取局部特征, 通过 Transformer 自注意力机制捕捉全局依赖, 但该方法未考虑长尾分布, 且 Transformer 的自注意力权重仅依赖特征本身自适应学习, 易受冗余特征干扰; 谢军^[29]提出单一域提取方法容易遗漏高维数据包含的复杂时域和频域特征, 因此针对单通道 2 048 维 IQ 信号构建双分支卷积神经网络架构, 通过短时傅里叶变换 (short-time Fourier transform, STFT) 和信号时域功率挖掘分别提取频域和时域特征后再进行多域特征融合, 但该方法未考虑分布与噪声问题, 且所采用的短时傅里叶变换方法对噪声敏感。另一类方法是首先通过传统算法进行特征降维与选择, 再设计识

别模型。例如,刘光辉等^[30]认为高维数据的非线性特性难以通过单一特征维度刻画,因此通过变分模态分解方法分解高维信号,然后保留相关性低的特征分量,再分别提取时域、频域、熵等特征并拼接,以获得表征能力更强的多域特征向量,但该方法未考虑高维信号的时序依赖性,且直接拼接多域特征的方式难以动态适应高维冗余特征;顾楚梅等^[31]针对高维数据不相关特征和冗余特征多的问题,先通过随机森林、XGBoost等嵌入式方法快速筛选高维特征以避免维度灾难,再利用封装式方法选择最优特征子集,双阶段压缩高维特征空间。这种双阶段方式性能依赖预先筛选特征的质量,难以与后续识别模型形成端到端优化。此外,相关方法也通常假设数据分布均匀,未考虑分布偏差对特征学习带来的影响。综上所述,虽然上述方案在应用于针对性困难场景时效果较好,但通常针对单一问题场景进行研究,针对复杂场景下的耦合问题研究较少。谭凯文等^[14]综合考虑了上述3个问题,但该方法主要在包含10个个体的数据集上进行了验证,未考虑较多个体场景,且其不平衡场景相对简化,非严格的长尾分布;而且,相关方法通常采用静态策略进行特征融合,未考虑动态适配高维信号的冗余分布、噪声强度及个体特征差异。此外,现有方法多依赖数据驱动,未考虑通过显式嵌入身份信息的方式增强对个体身份的学习。

为解决上述问题,本文提出面向长尾分布、高维特征的辐射源个体识别算法,实现了实采辐射源个体数据的有效识别,主要贡献如下。

1) 针对传统时序注意力缺乏身份信息引导、易聚焦冗余区域导致模型学习出现偏差的问题,提出了身份感知的时序注意力机制,通过将离散辐射源身份标签转化为高维连续嵌入向量,在注意力权重学习中融入身份先验知识。该机制不仅能强化高维数据中与特定身份相关的关键时序特征并抑制噪声干扰,还能通过动态样本重加权实现对长尾分布中少数个体样本的隐式上采样,从而缓解头部个体主导的训练偏差,提升尾部个体的识别性能。

2) 针对高维IQ信号时序相关性复杂、单一尺度特征难以充分表征的问题,设计适配IQ信号的多尺度特征学习模块,构建四分支并行架构,通过不同步长的平均池化与线性上采样操作,覆盖从原始尺度到 $\frac{1}{8}$ 尺度的多时序粒度特征,既保留了信号

的局部瞬时模式,又捕捉了全局结构信息,有效增强模型对辐射源细粒度指纹特征的区分能力,同时避免了传统时频转换带来的信息损耗。

3) 构建1D残差主干网络、身份感知时序注意力与多尺度特征融合模块协同的端到端识别框架,并结合余弦归一化分类器与交叉熵损失,协同实现高维特征冗余抑制、低信噪比信号特征提取与不平衡场景下少数类分布偏差纠正,最终实现辐射源个体的准确识别。

1 特征提取模块设计

针对辐射源个体识别任务中IQ信号时序特性适配难、数据长尾分布及噪声干扰强等问题,本文提出一种融合身份感知时序注意力与多尺度特征融合的改进残差网络模型。模型以原始IQ双通道信号为输入,通过1D残差主干网络的浅层特征学习、多尺度特征融合模块的细粒度信息整合、身份感知时序注意力模块的关键特征强化,最终实现端到端的辐射源个体身份判别,整体框架如图1所示。

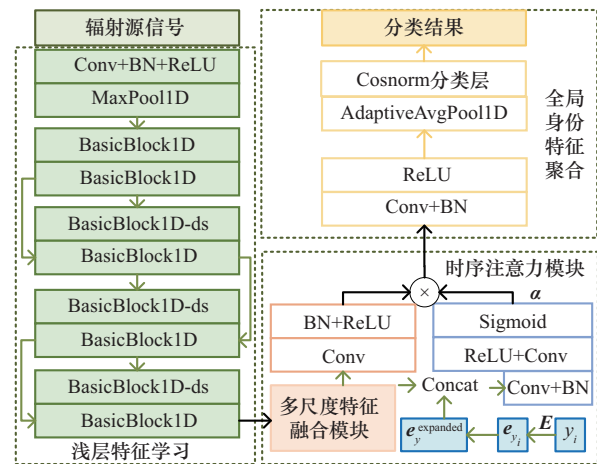


图1 所提模型整体框架

1.1 基于残差网络的浅层特征学习

为从辐射源IQ信号中逐层挖掘从局部瞬时特征到全局结构特征的高阶表征,模型采用1D残差主干网络设计,通过跳跃连接缓解深层网络训练中的梯度消失问题,同时适配时序信号的长程依赖性建模需求。

为捕捉IQ信号的时域特性,避免跨域转换导致的信息损耗,模型采用1D卷积直接对时序信号进行特征提取。网络以原始IQ信号为输入,首先通过初始1D卷积层对双通道信号进行时域特征初

步编码、通道升维与时序下采样，滤除冗余噪声并强化有效时域模式，形式化为

$$\mathbf{F}_{\text{init}} = \text{ReLU} \left(\text{BN} \left(\text{Conv1D} \left(\mathbf{X}_{\text{IQ}}, \text{kernel}_{\text{size}} = 15, \text{stride} = 2, \text{padding} = 7, \text{out}_{\text{channels}} = 64 \right) \right) \right) \quad (1)$$

该初始卷积层为 1D 结构以匹配时序信号的单向性特征，卷积核大小设为 15，从而覆盖更长的时序窗口以捕捉局部相关性，并确保时序长度下采样为原始长度的 $\frac{1}{2}$ ，同时将通道数从 IQ 信号的 2 维提升至 64 维，实现特征维度的有效升维，使数据具备更丰富的局部时域模式表征。然后接批归一化 (BN) 与 ReLU 激活函数，最终获得 $\mathbf{F}_{\text{init}} \in \mathbb{R}^{B \times 64 \times L_1}$ ，其时序维度为 $L_1 = \frac{L}{2}$ 。

初始特征 \mathbf{F}_{init} 经 MaxPool1D 层进一步下采样，使时序长度变为 $L_2 = \frac{L_1}{2} = \frac{L}{4}$ ，然后输入四层残差层，通过逐层扩大感受野，实现从局部瞬时特征到全局结构特征的递进提取。每层残差层由两个 1D 残差块 (BasicBlock1D) 堆叠组成，每个残差块均包含卷积、批归一化、ReLU 的两级特征变换，获得残差块输出特征，可形式化表达为

$$\mathbf{F}_{\text{out}} = \text{ReLU} \left(\text{BN} \left(\text{Conv1D}_2 \left(\text{ReLU} \left(\text{BN} \left(\text{Conv1D}_1 \left(\mathbf{F}_{\text{in}} \right) \right) \right) \right) \right) + \mathbf{F}_{\text{shortcut}} \right) \quad (2)$$

其中， \mathbf{F}_{in} 为残差块输入特征， Conv1D_1 与 Conv1D_2 均为卷积核尺寸为 3 的 1D 卷积层，通过设置 $\text{padding}=1$ 进行对称填充以保持时序长度不变，适配时序信号的局部关联性建模； $\mathbf{F}_{\text{shortcut}}$ 为跳跃连接分支，当输入输出的通道数或时序长度不匹配时（如第 2~4 残差层的第一个残差块），通过在 1D 卷积中设置步长为 2 进行下采样，实现通道数同步升维和时序长度同步下采样，确保残差融合的有效性。当维度完全一致时（如第一层的残差块及各层第二个残差块），直接采用恒等映射，确保残差融合的有效性与梯度传播的通畅性。

四层残差层的通道数随网络深度逐步提升，形成特征抽象递进的层级结构。其中，第一层通道数为 64，通过两级残差块强化局部时域特征的精细表征，时序长度维持 $L_2 = \frac{L}{4}$ 。第二层的第一个残差块

通过 $\text{stride}=2$ 的卷积，将通道升维至 128 且时序下采样至 $L_3 = \frac{L_2}{2}$ ，在提升特征抽象度的同时压缩冗余时序信息；第二个残差块保持维度不变，深化特征表达。第三层进一步通过步长为 2 的卷积将通道数扩展至 256，时序长度下采样至 $L_4 = \frac{L_3}{2}$ ，扩大感受野以捕捉更广泛的时序依赖性。第四层完成最终的特征升维与时序下采样 ($L_5 = \frac{L_4}{2}$)，形成 512 维的高维抽象时域特征，强化个体差异的表征能力。

通过四层残差层的递进式特征提取，网络最终输出深层时域高阶特征 $\mathbf{F}_{\text{deep}} \in \mathbb{R}^{B \times 512 \times L_5}$ ，其中 512 维通道体现特征的高维抽象能力， L_5 为最终时序长度。通过上述设计，模型充分学习了 IQ 信号的时序结构信息与个体特异性模式，实现了基于 1D 卷积与残差结构的时域特征深度挖掘。

1.2 多尺度特征融合

为了充分挖掘辐射源信号的多尺度时频特征，本节设计了多尺度特征融合模块，以整合不同尺度下的特征信息，提升模型对细粒度个体差异的表征能力，其结构如图 2 所示。




图2 多尺度特征融合模块结构

该模块采用多分支并行架构，对输入特征 \mathbf{F}_{deep} （时序长度为 1，通道数为 n ）分别进行多尺度处理。设置 4 个并行分支，其中，分支 0 对输入直接进行卷积、批归一化和 ReLU 激活以提取原始尺度特征；分支 1~分支 3 分别通过步长为 2、4、8 的平均池化下采样后，经卷积、批归一化、ReLU 激活提取多尺度特征，再通过线性上采样插值恢复至原始长度。设第 i 个分支的输出为 $X_i \in \mathbb{R}^{C_i \times L}$ ， $i = 0, 1, 2, 3$ ，最终经特征拼接操作得到融合特征

$$\mathbf{X}_{\text{concat}} = \text{Concat} (X_0, X_1, X_2, X_3) \quad (3)$$

随后，通过 1×1 卷积、批归一化和 ReLU 激活函数完成通道维度的融合与变换，最终输出特征 $f \in \mathbb{R}^{B \times C \times L}$ 。该模块通过多尺度特征的互补融合，实现了对辐射源信号在不同时序粒度下的特征表达

能力的增强,为后续个体感知时序注意力机制提供了丰富的多尺度特征基础,从而提升辐射源个体识别任务中模型对细粒度差异的区分能力。

1.3 身份感知的深层特征学习

不同辐射源个体的关键识别特征在时序维度上的分布具有显著差异性,并且混杂着信道噪声、环境干扰及冗余时序信息。传统时序注意力机制仅依赖原始特征自适应学习权重,缺乏身份信息的显式引导,易导致注意力聚焦于非特异性冗余区域,降低识别鲁棒性。为此,本文设计身份感知的时序注意力模块,将离散的辐射源身份标签转化为连续的高维嵌入向量,通过身份信息与时序特征的跨模态交互,生成身份自适应的时间步注意力权重,以提取目标辐射源关键时序特征,同时抑制噪声与冗余信息的干扰。具体而言,该模块包含以下4个部分。

1) 身份标签嵌入。为将离散的身份标签转化为可参与特征交互的连续向量,设计嵌入层实现标签的高维空间映射。该层通过学习一个可训练的嵌入矩阵 $\mathbf{E} \in \mathbb{R}^{N \times C}$, 其中, N 为辐射源个体数, $C=512$ 为嵌入维度。将每个身份标签 $y_i \in \mathbf{y}$ 映射为对应的身份嵌入向量 $\mathbf{e}_{y_i} \in \mathbb{R}^C$, 可形式化为

$$\mathbf{e}_{y_i} = \mathbf{E} \mathbf{I}_{y_i} \quad (4)$$

其中, $i \in [1, B]$, $\mathbf{I}_{y_i} \in \mathbb{R}^N$ 为身份标签 y_i 对应的独热编码向量。通过该映射,离散的身份信息被转化为连续的高维特征,且在训练过程中,嵌入矩阵 \mathbf{E} 会自适应调整,使同一个体辐射源的嵌入向量距离更近,不同个体距离更远,从而编码辐射源的身份特异性信息。对于整个批次,通过矩阵相乘形式获得身份嵌入输出 $\mathbf{e}_y \in \mathbb{R}^{B \times C}$, 可形式化为

$$\mathbf{e}_y = \text{Embedding}(\mathbf{y}, \mathbf{E}) \quad (5)$$

2) 时序维度对齐。由于身份嵌入向量 $\mathbf{e}_y \in \mathbb{R}^{B \times C}$ 缺乏时序维度,无法直接与时序特征 X_{concat} 进行交互,因此,通过时序维度广播对齐操作扩展其维度。该操作将每个样本的身份嵌入向量在时序维度上重复 L 次,使嵌入向量与时序特征的维度完全匹配,可形式化为

$$\mathbf{e}_y^{\text{expanded}} = \text{Repeat}(\mathbf{e}_y \otimes \mathbf{1}_{1 \times L}) \in \mathbb{R}^{B \times C \times L} \quad (6)$$

其中, $\mathbf{1}_{1 \times L}$ 为 L 维全1向量, \otimes 表示外积运算, $\text{Repeat}(\cdot)$ 表示按时序维度的重复操作,最终将身份嵌入向量扩展为与时序特征同维度的张量。

3) 跨模态特征交互。为使身份信息能够有效引导时序特征的注意力分配,采用通道维度拼接策略实现身份嵌入与时序特征的跨模态交互。将对齐后的身份嵌入张量 $\mathbf{e}_y^{\text{expanded}}$ 与 X_{concat} 在通道维度上拼接,从而在保留原始时序特征的细节信息的同时融入了身份特异性引导信息,可形式化为

$$\text{feat}_{\text{concat}} = \text{Concat}(X_{\text{concat}}, \mathbf{e}_y^{\text{expanded}}; \text{dim} = 1) \in \mathbb{R}^{B \times 2C \times T} \quad (7)$$

其中, $\text{Concat}(\cdot; \text{dim} = 1)$ 表示沿通道维度拼接, $2C$ 为融合后的特征通道数。

4) 自适应注意力生成。为从融合特征中自适应学习每个时间步的重要性,设计轻量级卷积注意力生成器,通过维度压缩与非线性映射生成时间步注意力权重。首先通过 1×1 卷积将融合特征的通道数从 $2C$ 压缩至隐藏维度 D ,在不破坏时序结构的前提下压缩通道维度,降低计算复杂度;然后经批归一化和 ReLU 激活引入非线性,通过第二个 1×1 卷积将通道数压缩至1,得到原始注意力分数;最后经 Sigmoid 激活函数将分数映射至 $[0,1]$ 区间,得到时间步注意力权重

$$\alpha = \text{Sigmoid}(\text{Conv1D}(\text{ReLU}(\text{BN}(\text{Conv1D}(\text{feat}_{\text{concat}})))))) \quad (8)$$

其中, $\alpha_{i,t}$ 表示第 i 个样本第 t 个时间步的注意力权重,权重越大表明该时间步包含的辐射源身份特异性特征越丰富。再将生成的注意力权重与原始时序特征 f 进行逐元素相乘,实现对关键时序特征的增强和冗余信息的抑制,表示为

$$\text{feat}_{\text{weighted}} = f \odot \alpha \in \mathbb{R}^{B \times C \times T} \quad (9)$$

其中, \odot 表示张量的逐元素乘积运算。加权后的特征 $\text{feat}_{\text{weighted}}$ 将作为后续分类器的输入,为辐射源个体识别提供更具身份判别性的时序特征表示。

基于上述步骤,所设计模块能够将身份先验信息注入注意力机制,引导模型关注与特定身份个体相关的判别性时序模式;然后,通过动态样本重加权实现对少数个体样本的隐式上采样,缓解了长尾分布带来的训练偏差,并抑制噪声时段、增强关键信号段,提升了个体特征的内部紧凑性与外部可分性,最终提升模型在不平衡个体上的识别性能。

在模型推理测试阶段,由于测试集的真实标签不可得,因此,构造所有身份嵌入向量的均值作为代理身份信息,可形式化为

$$E_{\text{avg}} = \frac{1}{N} \sum_{i=1}^N \text{Embedding}(i) \quad (10)$$

该设计保证了模块在测试时的可行性与稳定性，同时保持了身份语义信息的统计特性。

1.4 全局身份特征聚合

加权后的特征 $\text{feat}_{\text{weighted}}$ 包含了沿时序维度分布的、经身份信息引导强化的高阶判别特征。为适配最终分类任务的全局特征需求，本文通过多步聚合与维度转换操作，压缩时序冗余并强化核心身份特征表征。

首先，采用卷积、BN、ReLU 和自适应平均池化对 $\text{feat}_{\text{weighted}}$ 的时序维度进行全局压缩，将任意长度的时序特征映射为固定维度的全局特征向量，以消除时序维度差异，保留核心时域结构信息，可表示为

$$F_{\text{pool}} = \text{AdaptiveAvgPool1D}(\text{feat}_{\text{weighted}}, \text{out} = 1) \in \mathbb{R}^{B \times 512 \times 1} \quad (11)$$

该操作整合了 IQ 信号时序上的幅度变化规律、相位连续性等个体差异化信息，形成初步的全局特征表征。

随后，通过 1D 卷积与激活函数，进一步紧凑特征并降低维度冗余。其中，第一级 1 维卷积将 512 维通道特征压缩至 128 维，后接 ReLU 激活函数引入非线性，强化特征判别能力，可表示为

$$F_{\text{conv1}} = \text{ReLU}(\text{Conv1D}(F_{\text{pool}}, \text{in} = 512, \text{out} = 128)) \quad (12)$$

2 分类损失函数设计

2.1 分类器设计

为适配辐射源数据显著的长尾分布特性与低信噪比场景下的识别需求，提升少数个体样本特征类间辨识度，同时强化分类边界的可区分性，引入余弦归一化分类器作为分类头。具体而言，首先，使用 1 维卷积将 128 维特征进一步映射至 4 维，通过 Softmax 激活函数初步生成概率分布特征，可表示为

$$F_{\text{conv2}} = \text{Softmax}(\text{Conv1D}(F_{\text{conv1}}, \text{in} = 128, \text{out} = 4)) \in \mathbb{R}^{B \times 4 \times 1} \quad (13)$$

然后，特征 F_{conv2} 经维度压缩去除冗余单时序轴后，输入余弦归一化分类器完成辐射源身份预测。该分类器通过余弦归一化机制增强特征类间分离度，将 4 维特征映射至 N 维的身份概率分布， N 即辐射源个体总数，上述操作可表示为

$$P_{b,c} = \text{CosNorm}_{\text{Classifier}}(F_{\text{conv2}}) \in \mathbb{R}^{B \times 30} \quad (14)$$

其中， $P_{b,c} \in [0,1]$ 表示第 b 个样本属于第 c 个辐射源个体的概率，满足 $\sum_{c=1}^{30} P_{b,c} = 1$ 。模型通过交叉熵损失函数优化整个特征提取与分类网络的参数，实现对 N 个辐射源个体的身份判别。

2.2 交叉熵损失函数

针对辐射源识别的个体身份预测任务，模型采用标准交叉熵损失函数作为训练优化目标，以直接度量模型预测身份概率分布与真实身份标签分布的差异，引导模型学习具有强判别性的辐射源个体指纹特征。具体而言，交叉熵损失直接度量预测概率分布 P 与真实标签分布 Y 的差异，引导模型学习具有强判别性的辐射源指纹特征，数学表达式为

$$\mathcal{L}_{\text{CE}} = -\frac{1}{B} \sum_{b=1}^B \sum_{c=1}^N Y_{b,c} \log(P_{b,c} + \epsilon) \quad (15)$$

其中， B 为训练批次大小； $Y_{b,c} \in \{0,1\}$ 为第 b 个样本的真实独热标签，对应真实个体的元素位置 c 取值为 1，其余为 0； N 为辐射源个体总数； $\epsilon = 10^{-8}$ 为极小值，用于避免 $P_{b,c} = 0$ 时对数运算出现数值错误。

2.3 模型优化步骤

本文提出的算法的伪代码如算法 1 所示。

算法 1 基于注意力残差网络的辐射源识别训练算法

输入 辐射源 IQ 数据集 D 、批次大小 B 、初始学习率 lr 、训练轮数 T_{max}

输出 训练好的辐射源识别模型 Model

- 1) 初始化 Model (包含 1D 残差主干网络、时序注意力模块、线性分类器)
- 2) 初始化优化器 Optimizer (Adam, 学习率为 lr)
- 3) 初始化损失函数 \mathcal{L} , $t = 0$
- 4) while $t < T_{\text{max}}$ do
- 5) 从 D_{train} 中按 $B=64$ 采样，得到批次数据 X_{batch} 和标签 y_{batch}
- 6) 前向传播，获得对输入批次中个体的身份预测概率标签
- 7) 计算损失并进行反向传播
- 8) 优化器更新模型参数
- 9) 在测试集上计算验证准确率 acc_{val}
- 10) 若 acc_{val} 高于历史最优值，则保存当前模型为最佳模型
- 11) $t=t+1$

- 12) end while
- 13) 返回最佳模型 Model

3 实验分析

为系统验证本文所提算法的有效性, 首先详细说明实验所用的两类实采数据集, 然后明确对比算法的选型与参数配置, 同时给出实验的软硬件环境及核心评价指标, 最后从不同算法性能对比、噪声鲁棒性、长尾样本识别效果及消融实验等维度进行实验结果分析与讨论。

3.1 数据集介绍

为评估所设计的辐射源识别模型性能, 采用两个真实场景下采集的辐射源信号数据集开展实验, 分别为自采的船舶 AIS 辐射源长尾识别数据集与公开的飞机 ADS-B 实采数据集, 其样本量分布如图 3 所示, 所采集 AIS 数据集 I、Q 信号频谱如图 4 所示。

1) 船舶 AIS 辐射源长尾识别数据集

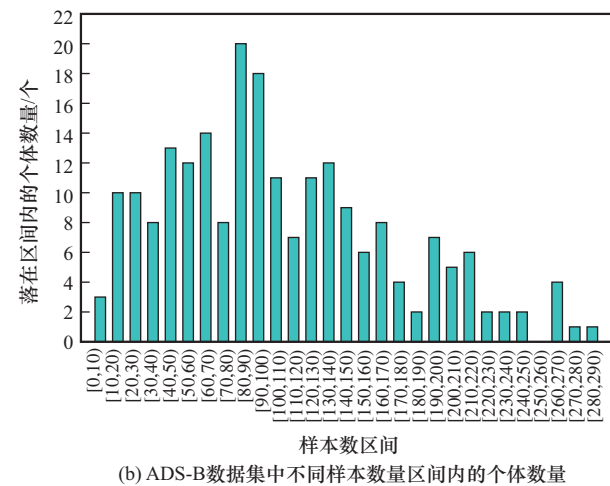



图 3 数据集样本量分布





图 4 所采集 AIS 数据集 I、Q 信号频谱

该数据集采集自中国山东省烟台市烟台港附近海域。数据采集设备为 SM200C 信号采集仪, 专门用于捕获民用船舶自动识别系统的 AIS 辐射源信号, 采集频段设置为 161.975 MHz, 信号带宽为 25 kHz。采集完成后, 通过人工标注方式对原始信号数据进行清洗, 确保数据标签的准确性与可靠性。为获取结构化辐射源信息, 本文完成了 AIS 辐射源信号自动检测与解调算法, 依据 AIS 数据编码协议对采集的原始信号进行解调处理, 最终得到多维数据信息, 包括以 IQ 复数数据形式存储的船舶 AIS 辐射源射频信号等。

所构建数据集包含 30 个不同的民船辐射源个体, 各个体样本数量按频次呈现典型的长尾分布特

征,且符合 Zipf 分布规律,如图 3(a)所示,其中样本数量最多的个体的样本数量达 7 309 个,最少个体的样本数量仅 59 个。尾部个体样本占比不足 1%。数据集中每个采样样本均包含 I、Q 两类复数信号特征,其维度达 11 520。此外,由于接收处的建筑物遮挡和其他信号干扰,所采集数据信噪比低。因此是一个典型的不平衡、高维、低信噪比辐射源个体识别问题。为保证训练和测试数据的独立性和分布一致性,按照每个个体样本数量 6:4 的比例随机划分训练集和测试集,且二者无连续信号片段重叠。

2) ADS-B 实采数据集

该数据集为发布于 Science Data Bank 数据平台的公开可获取的实采数据集。数据集采集于 2022 年 10 月 5 日,信号采样率设置为 40 MHz,采集对象为航空器广播式自动相关监视信号,格式为 DF=17。数据集共包含 216 个数据文件,即 216 个个体,每个文件分别对应一架飞机的 I 和 Q 信号数据,采样特征长度为 4 800 点。考虑到个体数量较多,因此绘制了不同样本数量的个体分布,如图 3(b)所示,样本量在 10 个以下的个体有 5 个,在 270 个以上的有 2 个,因此也是一个典型的维度高、不平衡问题明显的辐射源个体识别问题。训练和测试集划分比例为 7:3,其他划分方式与 AIS 数据相同。

3.2 对比算法简介

本文将所设计辐射源个体识别算法与典型传统算法和深度学习算法进行了对比。在传统算法方面,为对辐射源信号的识别,特征提取过程以辐射源 IQ 复数信号为核心输入,围绕信号的物理本质与模式差异,构建了统计、频谱、时域、调制四维度的特征体系,实现原始高维采样点向低维有效特征的转化。其中,统计特征学习幅度分布(均值、偏度等)、相位波动(相位差分均值、标准差等)、IQ 分量关联(协方差、相关系数等)及高阶矩(3 阶矩、4 阶矩)等,捕捉信号的整体统计规律;频谱特征基于 1 024 点快速傅里叶变换(FFT),提取幅度谱能量、相位谱分布、频谱质心、滚降率及主频信息,刻画信号的频域结构差异;时域特征通过自相关分析(IQ 分量自相关最大值、尾部均值)、过零率(IQ 分量单位时间过零次数)、能量分布及包络峰值特性,反映信号的时间动态变化;调制特征则针对辐射源调制特性,提

取幅度变异系数、相位跳变参数、瞬时频率波动及星座图统计属性(符号平衡度、IQ 相关性等),以区分不同调制模式的信号差异。整个提取过程既通过人工设计筛选剔除冗余信息,又全面覆盖信号的多维度物理特性,最终获得 72 维的统计特征,为后续随机森林、XGBoost 等分类模型提供了兼具辨识度与鲁棒性的输入特征。具体对比算法介绍如下。

1) 随机森林(RandomForest)。随机森林是基于多棵决策树的集成学习算法,核心特点为抗过拟合能力强、鲁棒性突出,能高效处理高维数据并捕捉非线性特征关联。本文设置决策树数量为 200 棵以平衡训练效率与泛化性能,将最大树深度限制为 20,最小样本分裂数设为 5 以抑制噪声干扰,最终通过多数投票机制输出分类结果。

2) 支持向量机(SVM)。支持向量机基于统计学习理论,利用核函数的非线性映射能力在高维数据处理中表现优异,核心特点是能通过寻找最优分离超平面实现识别,且泛化能力较强,是常用的处理高维数据的算法。本文采用径向基核函数(radial basis function, RBF)并设置 scale 模式以自动匹配特征尺度差异,通过设置正则化参数 $C=1.0$ 平衡拟合精度与泛化能力,通过优化核函数与正则化参数,可挖掘信号特征的弱线性关联,避免高维数据导致的过拟合问题。

3) XGBoost。XGBoost 是基于梯度提升树的集成算法,其融合了正则化机制与采样技术,能捕捉数据的细粒度特征差异,训练效率高、泛化能力强。本文设置 200 棵决策树并将最大深度限制为 10 以控制模型复杂度,采用 0.1 的学习率逐步迭代优化,通过 0.8 的子采样与列采样降低特征冗余,结合 L1 与 L2 正则化约束模型权重。

4) 集成模型(Ensemble)。集成模型通过融合多基模型优势,降低单一模型的偏差与方差,提升分类稳定性与泛化性能。本文采用软投票机制融合随机森林、SVM 与 XGBoost 这 3 个基模型,沿用各基模型的最优配置以保障性能上限,通过均等权重整合三者输出的概率分布,最后取最大概率作为最终分类结果。

5) 多层感知机(MLP)。多层感知机是具备深层特征提取能力的前馈神经网络,其非线性拟合能力强,能通过隐藏层自适应学习数据的抽象关联。

本文设计了128-64-32的三层隐藏层结构,采用ReLU激活函数解决梯度消失问题,同时通过L2正则化抑制过拟合,选用Adam优化器训练模型,学习率为0.001,迭代训练100次。

6) LT-SEI^[19]。面向长尾分布辐射源识别任务,设计基于解耦表示学习的两阶段训练框架。首先,在特征学习阶段使用不平衡训练数据进行信号表示学习,提取射频指纹特征;其次,在分类器学习阶段引入平衡采样与渐进平衡采样策略,构建类平衡数据集以优化分类决策边界。为进一步缓解长尾效应,设计自适应类权重调节机制,在损失函数中赋予尾类更高权重,抑制头部类别对梯度的主导影响;同时结合特征表示与分类器的解耦设计,提升模型对尾类样本的识别能力。

7) IC-SGAN^[14]。该算法针对非均衡个体SEI任务,利用生成式对抗网络的二元博弈结构,有效利用无标记数据补充特征信息。在判别网络中嵌入多尺度拓扑模块与残差单元,强化时域信号的多维分辨率特征提取;设计非均衡个体损失,通过自适应权重调节缓解多数类样本的梯度主导问题,以解决辐射源数据的长尾分布导致的性能下降问题。

8) RSNI-SEI^[21]。该算法聚焦低信噪比环境下的鲁棒性SEI需求,以深度残差收缩网络为核心架构。通过非线性变换层引入软阈值函数,自动抑制信号中的噪声特征,减少干扰对射频指纹提取的影响;设计自适应阈值子网,为每个IQ信号样本动态分配最优阈值。训练阶段采用噪声注入策略,向输入信号添加不同SNR的高斯白噪声,提升模型对复杂信道环境的泛化能力。

3.3 软硬件环境设置

本实验的软硬件环境配置如下:操作系统为Ubuntu 20.04 LTS,编程语言为Python 3.8,深度学习框架使用PyTorch 1.7.0,使用i9-13900K和NVIDIA GeForce RTX 3080 Ti GPU提供算力支撑,使用Adam作为优化器,学习率为0.000 2,批次大小为64,训练轮数为100次。

3.4 评价指标

为了客观衡量各模型在辐射源识别任务中的性能,针对两个数据集的长尾分布与强噪声特性,选取准确率(ACC)、精确度(Precision)、召回率(Recall)、F1分数(F1-Score)4个核心指标进行性能量化。设TP代表真实为某辐射源的样本被正确

预测,TN代表真实非某辐射源的样本被正确排除,FP代表真实非某辐射源的样本被误判,FN代表真实为某辐射源的样本被误判,相关指标计算如下。

1) 准确率,反映模型对所有样本的整体分类正确性,计算式为

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (16)$$

该指标用于衡量全局识别正确率,但长尾数据中头部类别可能拉高ACC,需结合其他指标分析尾部样本性能。

2) 精确度,反映模型预测结果的可靠性以避免误判,计算式为

$$Precision = \frac{TP}{TP + FP} \quad (17)$$

提高该指标能够降低船舶尾部个体的误判率。

3) 召回率,反映模型对真实目标的覆盖性以避免漏判,计算式为

$$Recall = \frac{TP}{TP + FN} \quad (18)$$

该指标能够关键适配长尾场景,衡量模型对尾部小样本的捕捉能力,避免漏判导致身份丢失。

4) F1分数,用于调和平均精确度与召回率,平衡准确性与覆盖性,计算式为

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (19)$$

F1分数作为综合性能核心指标,可避免单一指标偏差,适配长尾与含噪声数据集的统一性能衡量。

3.5 实验结果分析

1) 不同算法实验结果对比

不同算法的实验结果如表1所示。从表1可以看出,从数据角度来看,各算法在AIS数据集的效果普遍弱于在ADS-B数据集的效果,这主要是AIS数据集维度高、覆盖范围相对较小、海上复杂电磁环境等导致的设备干扰大,信号噪声更强、相位失真更明显;且船舶设备型号差异大、非标准化特性突出,导致辐射源指纹分布更分散,增加了识别难度;从算法角度来看,传统机器学习算法在两类数据集上的表现普遍弱于深度学习算法。性能最优的XGBoost在AIS数据集的ACC为78.18%,在ADS-B数据集为78.91%,与深度学习算法差距较大。这主要是由于该数据集维度高且个体数量多,传统算法难以捕捉IQ信号的时序相关性与辐射源硬件指

表1 不同算法的实验结果

算法	AIS				ADS-B			
	ACC	精确度	召回率	F1 分数	ACC	精确度	召回率	F1 分数
Random Forest ^[32]	75.13%	76.12%	75.23%	73.14%	77.15%	78.01%	77.23%	77.62%
SVM ^[33]	58.87%	62.14%	59.34%	60.71%	47.17%	48.22%	47.42%	47.82%
XGBoost ^[34]	78.18%	79.05%	78.26%	78.65%	78.91%	79.25%	78.27%	78.77%
Ensemble ^[35]	77.18%	77.18%	75.68%	76.07%	76.78%	78.06%	77.41%	77.74%
MLP ^[36]	74.04%	74.21%	74.33%	74.26%	77.29%	78.12%	77.36%	77.74%
LT-SEI ^[19]	83.97%	83.86%	83.97%	83.92%	88.45%	88.91%	88.45%	88.32%
IC-SGAN ^[14]	80.87%	82.53%	80.87%	81.69%	91.06%	91.26%	91.48%	91.37%
RSNI-SEI ^[21]	87.62%	83.64%	87.31%	85.42%	87.59%	88.17%	87.59%	87.45%
所提算法	94.89%	94.97%	94.89%	94.88%	93.23%	93.64%	93.23%	93.69%

纹的细粒度差异；同时，在辐射源识别的长尾分布场景下，传统算法易因样本量失衡出现头部个体过拟合、尾部个体欠拟合的问题，导致整体泛化能力不足，使算法性能有限。

生成式模型和端到端模型的效果均优于最基础的多层神经网络，表明通过针对性设计卷积结构、特征学习方法等可以有效提升特征学习能力。生成式模型 IC-SGAN^[14]在两类数据集上表现出较大差异，且在 ADS-B 数据集上的效果整体优于 AIS 数据集。这种差异主要源于数据集特性。IC-SGAN 采用生成式方法，对 1 000 维、5 个个体的仿真数据和 10 个个体的真实数据验证了有效性，所使用数据的维度和个体数量较少；而 AIS 数据集信号达 11 520 维、30 个个体且噪声干扰强，生成式模型在训练中难以充分学习辐射源个体的真实特征分布，导致生成样本质量不足，进而限制识别性能，且实测训练不够稳定，容易崩溃。而 ADS-B 数据集信号为 4 800 维且信噪比高，与文献[14]所处理的数据集维度类似，其生成架构和多尺度拓扑特征学习方式可有效增强特征表达能力，因此性能较好。端到端方法中，LT-SEI^[19]和 RSNI-SEI^[21]对 AIS 数据集的高维辐射源信号适配性较强，且稳定性较好，这是因为端到端框架可直接从原始 IQ 信号中逐层提取多尺度特征，并通过损失函数进一步适配识别任务，避免了传统人工特征工程的信息损失，同时其深度网络结构能更精准地捕捉 IQ 信号的时序关联性与辐射源指纹的细粒度差异，因此在高维、不平衡的数据集上，表现优于传统机器学习算法与生成式方法 IC-SGAN。RSNI-SEI^[21]重点关注平衡场

景下的低信噪比问题，通过自适应软阈值去噪等方式提升对噪声的鲁棒性，因此该算法在文献[21]中设置的个体数量较少且样本数量平衡的 ADS-B 数据集上的性能较好，在本文所采集的噪声较多、个体数量较少的 AIS 数据集上的性能也较好，但该算法未考虑样本不平衡问题，因此在本文所处理的不平衡场景下，其性能整体而言有一定下降。

本文提出的算法在 AIS 和 ADS-B 数据集上均展现出明显优势，通过动态强化 IQ 信号的有效特征、抑制冗余与噪声干扰，所提算法在长尾分布和高维特征场景下达到高识别精度与鲁棒性。

2) 噪声鲁棒性分析

辐射源信号在实际传播过程中会受到多径衰落、电磁噪声等信道干扰，而信噪比波动会直接影响特征提取的可靠性。考虑到高斯白噪声是通信系统中最典型的背景干扰，因此为验证所提算法在复杂干扰场景下的鲁棒性，本节实验以公开的 ADS-B 数据集为对象，构建基于高斯白噪声的干扰模型，通过控制噪声功率实现不同信噪比条件，以分析模型性能变化规律。

实验采用加性白高斯噪声，其概率密度函数满足正态分布，且功率谱密度在整个频域内均匀分布，与辐射源信号在环境信道中面临的自然电磁干扰特性一致。噪声添加过程严格遵循信噪比定义，信噪比为

$$\text{SNR (dB)} = 10 \lg \left(\frac{P_{\text{signal}}}{P_{\text{noise}}} \right) \quad (20)$$

其中， P_{signal} 为 ADS-B 原始 IQ 信号的平均功率， P_{noise} 为添加的高斯白噪声功率。通过调整 P_{noise} ，

使数据集信噪比分别达到 14 dB (对应噪声占比为 20%)、7 dB (对应噪声占比为 40%) 和 3 dB (对应噪声占比为 60%)，覆盖实际应用中 3 类典型高、中、低信噪比干扰环境。ADS-B 数据集中不同噪声下的准确率和 F1 分数如表 2 所示。

从表 2 可以看出，所提算法在不同强度噪声环境下均展现出最优且稳定的抗干扰性能。具体而言，在信噪比为 14 dB 和 7 dB 的条件下，所提算法的准确率分别达到 93.94% 和 92.87%，F1 分数均保持在 92% 以上；即使在 3 dB 的低信噪比极端场景下，所提算法仍维持 91.96% 的 ACC 和 91.87% 的 F1 分数，性能衰减幅度控制在 2% 以内。相比之下，RSNI-SEI 虽表现出一定的鲁棒性，但其 ACC 较所提算法低约 6%，可能与其预置的软阈值去噪机制过度抑制了弱特征有关。XGBoost 受限于传统特征工程对噪声的敏感性，性能随信噪比降低而持续下滑。综合来看，所提算法通过身份感知注意力机制动态聚焦关键时序模式、抑制噪声干扰，结合多尺度特征网络提取 IQ 信号细粒度特征，有效增强了复杂电磁环境下的特征鲁棒性。

3) 不同样本数量个体识别正确率分析

考虑到所处理数据集的个体数量多，为了进一步分析所设计算法的有效性，本节按照不同个体的样本数量由高到低对个体进行排序，然后将个体分为 0~25% (头部，样本数量最多的 25% 个体)，25%~50%，50%~75%，75%~100% (尾部) 共 4 组。基于 AIS 数据集与含 60% 噪声的 ADS-B 数据集，对比其与 XGBoost、RSNI-SEI 的识别性能差异，不同样本数的个体识别准确率和 F1 分数分别如表 3 和表 4 所示。

从表 3 和表 4 可以看出，后两种采用针对性处理不平衡个体的方法均呈现出中间两组高，头部其次，尾部最低的特点，这和算法为实现整体更高准确率而采取的不平衡个体处理策略相关，而尾部样本个体分散、数量多但样本少导致区分困难。整体而言，所提算法在各组个体上均表现出较好的均衡识别能力，尤其在尾部类性能优势明显，在 AIS 尾部类上 F1 分数达 94.27%，高于对比算法 5% 以上。这主要是由于身份感知注意力机制的动态重加权效果，使尾部类样本在特征交互中获得更高注意力权重，有效缓解了样本稀缺导致的欠拟合。

F1 分数能够更好地反映个体识别的均衡性，所

表 2 ADS-B 数据集中不同噪声下的个体识别准确率与 F1 分数

算法	ACC			F1 分数		
	SNR=14 dB	SNR=7 dB	SNR=3 dB	SNR=14 dB	SNR=7 dB	SNR=3 dB
XGBoost ^[34]	78.60%	78.06%	76.65%	78.14%	77.55%	76.11%
RSNI-SEI ^[21]	85.78%	85.30%	85.58%	85.57%	84.97%	85.46%
所提算法	93.94%	92.87%	91.96%	93.78%	92.74%	91.87%

表 3 AIS 数据集中不同样本数的个体识别准确率与 F1 分数

算法	ACC				F1 分数			
	0~25%	25%~50%	50%~75%	75%~100%	0~25%	25%~50%	50%~75%	75%~100%
XGBoost ^[34]	81.58%	81.68%	69.36%	43.42%	82.44%	86.06%	78.38%	55.64%
RSNI-SEI ^[21]	85.35%	90.04%	81.17%	83.17%	81.27%	93.67%	89.83%	87.58%
所提算法	94.24%	97.45%	94.15%	89.89%	94.54%	97.87%	96.63%	94.27%

表 4 含 60% 噪声的 ADS-B 数据集中不同样本数的个体识别准确率与 F1 分数

算法	ACC				F1 分数			
	0~25%	25%~50%	50%~75%	75%~100%	0~25%	25%~50%	50%~75%	75%~100%
XGBoost ^[34]	80.07%	79.45%	73.76%	54.69%	83.44%	85.07%	79.82%	64.36%
RSNI-SEI ^[21]	86.35%	87.26%	86.52%	74.02%	89.15%	91.38%	91.24%	79.65%
所提算法	91.66%	93.20%	93.11%	86.81%	92.96%	95.28%	95.37%	90.09%

提算法在 AIS 数据集上的 F1 分数差值为 3.60%，低于其他两种算法，证明其未牺牲少数类性能换取整体准确率，均衡性较好。在 3 dB 强噪声 ADS-B 数据集上，尾部类 F1 分数仍达 90.09%，与头部类差距仅 2.87%，表明注意力机制与残差结构在噪声抑制与特征保留间实现了有效平衡，所提算法未偏向头部多样本类，而是对尾部少样本类也实现了较好的识别，避免了牺牲少数类性能换取整体准确率的学习偏差。

此外，在含 60% 噪声的 ADS-B 数据集中，所提算法依然保持较高的稳定性。在该低信噪比场景下，所提算法在各分组的性能衰减幅度远低于对比算法：在头部个体和中间个体均保持领先的准确率和 F1 分数的前提下，尾部个体的准确率和 F1 分数远高于对比算法，衰减幅度最低，证明所提算法在长尾分布和噪声干扰双重挑战下仍能稳定捕捉尾部个体的特征。

综上，在 AIS 和 ADS-B 两种典型任务场景下，所提算法对不同样本量辐射源个体的识别性能均较好，尤其是对尾部少数类的识别准确率与头部个体的差距较小，表明了算法的均衡性与稳定性，能够满足实际场景中辐射源样本量不均衡的识别需求。

4) 消融实验分析

为量化验证所提模型中身份感知时序注意力模块与多尺度特征融合模块的贡献，本节基于 AIS 数据集设计消融实验，结果如表 5 所示。基于残差网络的基础模型达到了一定的准确率。当引入身份感知时序注意力模块时，模型性能提升明显，ACC 提升 3.84%，F1 分数提升 4.47%，表明通过动态建模时序维度的特征重要性权重，所提算法能够自适应聚焦与辐射源身份强相关的关键时序片段，如信号调制细节、硬件非线性失真特征等，同时抑制电磁环境中的随机噪声与冗余信息，有效解决了 AIS 信号时序跨度大、有效特征稀疏的问题。

表 5 消融实验

身份感知时序注意力	多尺度特征融合	ACC	F1 分数
×	×	89.57%	89.46%
√	×	93.41%	93.93%
√	√	94.89%	94.88%

在引入身份感知时序注意力模块的基础上，进一步添加多尺度特征融合模块后，模型准确率进一步提升了 1.48%，表明多尺度特征融合模块与身份

感知时序注意力模块可形成有效协同，前者通过并行提取不同感受野下的特征弥补单一尺度特征对复杂辐射源信号表征的局限性，后者则为多尺度特征分配动态注意力权重，确保关键尺度的有效特征被优先利用。

5) 训练稳定性分析

所提算法的训练准确率与损失值如图 5 所示。从图 5 可以看出，所设计模型收敛速度快，在约 30 个训练轮次后，准确率基本稳定在 90% 以上。损失值曲线快速下降并趋于平缓，无明显波动，且训练过程中无梯度消失现象，这主要得益于多尺度特征融合与损失函数的协同作用，确保了深层网络的稳定训练。此外，不同训练次数下测试集的准确率波动较小，说明模型泛化能力强，具有较好的适应性和稳定性。




图 5 所提算法的训练准确率与损失值

4 结束语

本文针对辐射源个体识别在实际应用中面临的数据长尾分布显著、高维特征提取效率低等问题，提出一种基于时序注意力与多尺度特征融合的不平衡辐射源个体识别方法。该方法基于残差单元作为主干架构，融合身份感知时序注意力与多尺度特征融合模块，既通过 1D 卷积与残差连接捕捉 IQ 信号的时序相关性，又借助身份先验引导的注意力机制聚焦关键特征、抑制噪声冗余，同时通过多分支并行架构整合不同时序粒度信息，强化细粒度个体差异表征；引入交叉熵损失和余弦归一化分类器，缓解长尾分布导致的训练偏差。基于实测的高维、低信噪比 AIS 数据集与公开 ADS-B 数据集的多维度实验表明，所提算法在准确率等核心指标上相较于 XGBoost、RSNI-SEI 等主流算法性能提升 5% 以上，且在高噪声情况下算法性能波动小，鲁棒性优

势显著,充分验证了所设计模型在高维、低信噪比、不平衡辐射源识别任务中的有效性与实用性。

参考文献:

- [1] ITU-R. Technical characteristics for a universal shipborne automatic identification system using time division multiple access in the VHF maritime mobile band[R]. International Telecommunication Union, 2014.
- [2] Liu Y, Wang H, Chen W. Maritime target identification based on AIS emitter fingerprinting[J]. IEEE Journal of Oceanic Engineering, 2022, 47(2): 567-578.
- [3] 闫文君, 段可欣, 凌青, 等. 数据恶劣条件下的辐射源个体识别方法综述[J]. 海军航空大学学报, 2024, 39(5): 523-534.
Yan W J, Duan K X, Ling Q, et al. Overview of individual identification methods for radiation sources under harsh data conditions[J]. Journal of Naval Aviation University, 2024, 39(5): 523-534.
- [4] Ding L, Wang S, Wang F, et al. A survey of specific emitter identification techniques[J]. IET Communications, 2021, 14(15): 2512-2524.
- [5] Ding L D, Wang S L, Wang F G, et al. Specific emitter identification via convolutional neural networks[J]. IEEE Communications Letters, 2018, 22(12): 2591-2594.
- [6] Pan Y W, Yang S H, Peng H, et al. Specific emitter identification based on deep residual networks[J]. IEEE Access, 2019, 7: 54425-54434.
- [7] Wong L J, Headley W C, Michaels A J. Specific emitter identification using convolutional neural network-based IQ imbalance estimators[J]. IEEE Access, 2019, 7: 33544-33555.
- [8] Wang Y, Gui G, Gacanin H, et al. An efficient specific emitter identification method based on complex-valued neural networks and network compression[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(8): 2305-2317.
- [9] Tu Y, Lin Y, Hou C B, et al. Complex-valued networks for automatic modulation classification[J]. IEEE Transactions on Vehicular Technology, 2020, 69(9): 10085-10089.
- [10] 段可欣, 闫文君, 刘凯, 等. 融合双谱特征的雷达辐射源个体识别方法[J]. 海军航空大学学报, 2023, 38(5): 382-390.
Duan K X, Yan W J, Liu K, et al. A method for individual recognition of radar emitter based on fusion of bispectral features[J]. Journal of Naval Aviation University, 2023, 38(5): 382-390.
- [11] Zhou M S, Kong M M, Tian Y, et al. Mixed CNN and transformer for specific emitter identification[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 6504410.
- [12] Zhai L, Chang Z H, Yang S Y, et al. HET: an efficient high-frequency enhancement transformer for specific emitter identification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2025, PP (99): 1-15.
- [13] Qian Y H, Qi J, Kuai X Y, et al. Specific emitter identification based on multi-level sparse representation in automatic identification system[J]. IEEE Transactions on Information Forensics and Security, 2021, 16: 2872-2884.
- [14] 谭凯文, 张立民, 闫文君, 等. 面向非均衡类别的半监督辐射源识别方法[J]. 雷达学报, 2022, 11(4): 713-727.
Tan K W, Zhang L M, Yan W J, et al. A semi-supervised emitter identification method for imbalanced category[J]. Journal of Radars, 2022, 11(4): 713-727.
- [15] Qu L Z, Yang J N, Huang K J, et al. Specific emitter identification based on one-dimensional complex-valued residual networks with an attention mechanism[J]. Bulletin of the Polish Academy of Sciences Technical Sciences, 2021 69(5): 138814.
- [16] Zhang Y Z, Zhou Z N, Li X P. Generative adversarial networks with Gramian angular field for handling imbalanced data in specific emitter identification[J]. Signal, Image and Video Processing, 2024, 18(3): 2929-2938.
- [17] Fu X, Peng Y, Liu Y C, et al. Semi-supervised specific emitter identification method using metric-adversarial training[J]. IEEE Internet of Things Journal, 2023, 10(12): 10778-10789.
- [18] Wang J Q, Guo L S, Liu P F, et al. A self-supervised contrastive framework for specific emitter identification with limited labeled data[J]. Remote Sensing, 2025, 17(15): 2659.
- [19] Zha H R, Wang H H, Feng Z M, et al. LT-SEI: long-tailed specific emitter identification based on decoupled representation learning in low-resource scenarios[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(1): 929-943.
- [20] Deng P F, Hong S H, Qi J, et al. A lightweight transformer-based approach of specific emitter identification for the automatic identification system[J]. IEEE Transactions on Information Forensics and Security, 2023, 18: 2303-2317.
- [21] Xu C A, Wu J F, Xuan Q, et al. A robust specific emitter identification method for CPS devices based on deep residual shrinkage network[J]. IEEE Transactions on Reliability, 2025, 74(3): 3671-3680.
- [22] Shi L, Chen X, Lu K Y, et al. KLT-SEI: knowledge transformer for specific emitter identification[C]//Proceedings of the 2024 IEEE/CIC International Conference on Communications in China (ICCC). Piscataway: IEEE Press, 2024: 355-360.
- [23] Huang K J, Yang J N, Liu H, et al. Channel-robust specific emitter identification based on transformer[J]. Highlights in Science, Engineering and Technology, 2022, 7: 71-76.
- [24] Liu Z M. Multi-feature fusion for specific emitter identification via deep ensemble learning[J]. Digital Signal Processing, 2021, 110: 102939.
- [25] Satija U, Trivedi N, Biswal G, et al. Specific emitter identification based on variational mode decomposition and spectral features in single hop and relaying scenarios[J]. IEEE Transactions on Information Forensics and Security, 2019, 14(3): 581-591.
- [26] Tao M Y, Fu X, Zhang Q Y, et al. Robust specific emitter identification with sample selection and regularization under label noise[J]. IEEE Internet of Things Journal, 2024, 11(24): 40702-40713.
- [27] 段可欣, 闫文君, 凌青, 等. 样本标签污染条件下的雷达辐射源个体识别技术[J]. 海军航空大学学报, 2024, 39(2): 189-198, 260.
Duan K X, Yan W J, Ling Q, et al. Individual identification technology of radar radiation sources under sample label pollution conditions[J]. Journal of Naval Aviation University, 2024, 39(2): 189-198, 260.
- [28] Wang B, Gao N, Wang F. Specific emitter identification based on CNN and transformer[C]//Proceedings of the 5th International Academic Exchange Conference on Science and Technology Innovation (IAECST).

Piscataway: IEEE Press, 2024: 571-575.

[29] 谢军. 基于多域特征融合的通信辐射源个体识别方法[J]. 计算机科学与应用, 2025, 15(3): 94-101.

Xie J. Specific emitter identification method using multi-domain feature fusion[J]. Computer Science and Application, 2025, 15(3): 94-101.

[30] 刘高辉, 闫迪. BDmin-VMD-CA 结合 MDFF 的通信辐射源个体识别[J]. 计算机系统应用, 2025, 34(8): 105-115.

Liu G H, Yan D. Identification of communication radiation source individuals by BDmin-VMD-CA combined with MDFF[J]. Computer Systems and Applications, 2025, 34(8): 105-115.

[31] 顾楚梅, 曹建军, 王保卫, 等. 基于混合式特征选择的辐射源个体识别[J]. 计算机科学, 2024, 51(5): 267-276.

Gu C M, Cao J J, Wang B W, et al. Specific emitter identification based on hybrid feature selection[J]. Computer Science, 2024, 51(5): 267-276.

[32] Breiman L. Random forests[J]. Machine Learning, 2001, 45(1): 5-32.

[33] Boser B E, Guyon I M, Vapnik V N. A training algorithm for optimal margin classifiers[C]//Proceedings of the Fifth Annual Workshop on Computational Learning Theory. New York: ACM Press, 1992: 144-152.

[34] Chen T Q, Guestrin C. XGBoost: a scalable tree boosting system[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM Press, 2016: 785-794.

[35] Zhou Z H. Ensemble methods: foundations and algorithms[M]. Berlin: Springer, 2012.

[36] Lecun Y, Boser B, Denker J S, et al. Backpropagation applied to handwritten zip code recognition[J]. Neural Computation, 1989, 1(4): 541-551.

[作者简介]



高龙 (1993-), 男, 山东济宁人, 博士, 海军航空大学讲师, 主要研究方向为模式识别、态势感知。



吕友彬 (1991-), 男, 山东临沂人, 海军航空大学讲师, 主要研究方向为航空管制、目标识别等。



王薨娇 (1998-), 女, 山东烟台人, 海军航空大学助教, 主要研究方向为信号分析、通信感知。



张威 (1984-), 男, 辽宁葫芦岛人, 海军航空大学副教授, 主要研究方向为模式识别、态势感知。



李涵雨 (1993-), 女, 山东烟台人, 海军航空大学博士生, 主要研究方向为模式识别、信号处理。



徐从安 (1987-), 男, 山东日照人, 博士, 海军航空大学副教授, 主要研究方向为机器学习、态势感知。