

基于无损 VMD 和 Mamba 的小样本辐射源识别方法

何文龙, 陈 剑*, 尹宝鑫, 毛浩阳, 贾 杰, 王兴伟

(东北大学计算机科学与工程学院, 辽宁沈阳 110169)

摘 要: 随着无线通信技术的快速发展, 无线通信辐射源数量呈现出指数级增长态势, 电磁环境日益复杂, 频谱资源日趋紧张。在这一背景下, 如何在海量的设备中实现精准的身份识别与安全接入, 已成为关乎社会稳定与经济发展的核心议题。传统的身份认证方式依赖协议层或应用层的数字凭证, 存在易被窃取、伪造或攻击等安全漏洞。相比之下, 基于射频指纹(Radio Frequency Fingerprinting, RFF)的特定辐射源识别技术(Specific Emitter Identification, SEI)作为一种物理层的安全手段, 具有广阔应用前景。该技术通过提取发射机硬件电路中固有的物理缺陷进行身份认证, 具有天然的唯一性与长期稳定性。然而, 现有基于深度学习的通信辐射源识别方法普遍面对标注数据依赖性强、泛化能力不足、长序列信号处理效率低等的挑战。为此, 本文重点聚焦小样本条件下通信辐射源的高效识别问题, 提出了一种基于自监督学习的低复杂度识别算法。首先, 针对原始 I/Q 信号中指纹特征易被信道噪声和调制信息掩盖的问题, 本文引入了无损的变分模态分解(Variational Mode Decomposition, VMD)方法, 通过自适应地将原始 I/Q 信号转换为多个本征模态函数分量, 增强了指纹特征的表示能力; 其次, 为克服传统序列建模模型在处理长序列信号时的二次计算复杂度瓶颈, 本文引入了具有线性计算复杂度的 Mamba 架构, 并构建了一个基于 Mamba 线性流编码器的自监督网络模型, 利用大规模辅助数据集进行预训练, 结合对比学习和监督学习, 促使模型学习具有强判别性的通用特征表示; 最后, 针对实际应用中新增设备样本稀缺和存在未知干扰的问题, 本文采用了迁移学习策略, 利用少量的目标域辐射源样本微调一个轻量级线性分类器, 以快速适应具体的下游分类任务。在 WiSig 数据集上的仿真实验结果表明, 本文所提出的方法在 6-way 1-shot 场景下识别准确率达到 91.20%, 在显著降低了计算复杂度与样本集规模依赖的同时保持了较高的识别性能, 具有良好的现实应用前景。

关键词: 特定辐射源识别; 小样本学习; 自监督学习; 变分模态分解; Mamba; 数据增强

基金项目: 国家自然科学基金(No.62132004, No.62572109, No.62572113); 航空科学基金(No.20230026050001); 辽宁省中央引导地方科技发展专项资金资助项目(No.2025JH6/101100009); 沈阳市中青年科技创新领军人才项目(No.RC231173); 沈阳市科技计划项目(No.23-503-6-17)

中图分类号: TN911.7

文献标识码: A

文章编号: 0372-2112(2026)06-2509-13

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20260405

Few-Shot Specific Emitter Identification Method Based on Lossless VMD and Mamba

HE Wenlong, CHEN Jian*, YIN Baoxin, MAO Haoyang, JIA Jie, WANG Xingwei

(School of Computer Science and Engineering, Northeastern University, Shenyang, Liaoning 110169, China)

Abstract: With the rapid development of wireless communication technology, the number of wireless communication emitters has grown exponentially, leading to an increasingly complex electromagnetic environment and increasingly scarce spectrum resources. Against this backdrop, achieving precise identity recognition and secure access among massive devices has become a critical issue concerning social stability and economic development. Traditional identity authentication methods rely on digital credentials at the protocol or application layer, which are susceptible to theft, forgery, or attacks. In contrast, the specific emitter identification (SEI) technology based on radio frequency fingerprinting (RFF) serves as a physical-layer security measure with broad application prospects. This technology authenticates identities by extracting the inherent physical imperfections in the emitter's hardware circuits, offering natural uniqueness and long-term stability. However, existing deep learning-based methods for communication emitter identification generally face challenges, including heavy reliance on labeled data, limited generalization, and low efficiency in processing long-sequence signals. To address these issues, this paper focuses on the efficient identification of communication emitters under few-shot conditions and proposes a low-complexity self-supervised recognition algorithm. First, to overcome the problem that fingerprint features in the original I/Q signals are easily obscured by channel noise and modulation information, this paper introduces a

lossless variational mode decomposition (VMD) method. This approach adaptively converts the original I/Q signals into multiple intrinsic mode function components, enhancing the representational capacity of fingerprint features. Second, to address the quadratic computational complexity bottleneck of traditional sequence modeling methods when processing long-sequence signals, this paper incorporates the Mamba architecture, which has linear computational complexity. A self-supervised network model based on the Mamba linear flow encoder is constructed, utilizing a large-scale auxiliary dataset for pre-training. By integrating contrastive and supervised learning, the model is guided to learn discriminative, generalizable feature representations. Finally, to tackle the scarcity of new device samples and the presence of unknown interference in practical applications, this paper employs a transfer learning strategy. Using a small number of target-domain emitter samples, a lightweight linear classifier is fine-tuned to adapt to specific downstream classification tasks quickly. Simulation results on the WiSig dataset show that the proposed method achieves 91.20% accuracy in a 6-way 1-shot scenario. While significantly reducing computational complexity and dependence on sample size, the method maintains high recognition performance, demonstrating promising potential for real-world applications.

Keywords: specific emitter identification; few-shot learning; self-supervised learning; variational mode decomposition; Mamba; data augmentation

Foundation Item(s): National Natural Science Foundation of China (No.62132004, No.62572109, No.62572113); Aeronautical Science Foundation of China (No.20230026050001); Central Government Guided Local Science and Technology Development Fund Project of Liaoning (No.2025JH6/101100009); Young and Middle-Aged Leading Talents in Technological Innovation of Shenyang (No.RC231173); Shenyang Science and Technology Plan Fund Project (No.23-503-6-17)

0 引言

随着科技的发展,无线通信技术凭借其便捷性和泛用性成为了现代信息社会不可或缺的部分。与此同时,物联网技术的普及与深入应用,使得网络接入设备数量呈指数级增长,电磁环境日益复杂。在这一背景下,如何在海量的设备中实现精准的身份识别与安全接入,成为亟待解决的关键问题。基于射频指纹特征(Radio Frequency Fingerprinting, RFF)的特定辐射源识别(Specific Emitter Identification, SEI)技术^[1],为解决该问题提供了一种极具潜力的物理层安全方案。

射频指纹特征本质上表征了发射机功放管的非线性特性、混频器的相位噪声等硬件元件以及制造工艺的固有差异,从而导致了信号在基带调制、上变频和功率放大等过程中不可避免地产生畸变^[2]。该特征具备与生物指纹类似的唯一标识性和长期稳定性,即使是同一型号、同一批次的设备,其射频指纹特征也会存在细微的差别。因此,通过提取并分析射频信号中蕴含的这种指纹特征,可以实现对无线设备的唯一识别,为设备身份认证、网络安全防护^[3]、电子侦察与国防安全^[4]等领域提供了新的技术途径。

准确提取并识别射频信号中包含的指纹特征,是SEI领域中的核心技术课题。国内外的相关研究主要分为3个阶段:传统人工特征方法、基于深度学习方法以及面向小样本的学习方法^[5]。传统SEI方法主要依赖人工特征提取和专家经验比对等手段,从接收到的射频信号中手动设计并计算一系列特征参数,构建特征数据库,通过模式匹配实现设备识别。刘旭

等人^[6]使用递归分析和固有尺度时间分解方法提取雷达信号的包络特征,并采用支持向量机分类器进行分类。经验模态分解(Empirical Mode Decomposition, EMD)和变分模态分解(Variational Mode Decomposition, VMD)等也陆续被引入SEI领域,梁江海等人^[7]通过EMD分解将信号中的主要信号成分与杂散成分分离,提取杂散成分的频域特征作为信号指纹,提高了特征提取能力的鲁棒性。然而,随着电磁环境的日益复杂以及大量新类型辐射源的出现,传统方法表现出明显的局限性:一方面,人工设计的特征难以全面捕捉发射机的硬件非线性特性;另一方面,特征库的构建和维护需要大量的先验知识和人工干预,在动态变化的电磁环境中难以快速适应。

深度学习的兴起为SEI领域提供了数据驱动的解决思路。深度学习能够通过多层非线性变换自动学习原始信息中的高层次判别特征,早期的研究主要将成功应用于计算机视觉领域的模型架构引入SEI领域,包括卷积神经网络(Convolutional Neural Network, CNN)、循环神经网络(Recurrent Neural Network, RNN)、生成对抗网络(Generative Adversarial Network, GAN)等。Merchant等人^[8]通过在相同标准的发射器间制造变异性,生成唯一且可重复的签名作为指纹,利用时域复基带信号训练CNN,在ZigBee设备上取得了较好的效果。Debashri Roy等人^[9]提出了一种射频对抗学习框架,将接收到的原始I/Q信号输入GAN,学习发射器的I/Q样本空间用以识别非合法辐射源,并在通用软件无线电外设(Universal Software Radio Peripheral, USRP)上进行了验证。尽管深度学习在

SEI 领域表现出了强大的特征提取和判别能力,但其模型的有效性严重依赖高质量的训练数据集,而现实场景中许多辐射源的信号样本获取难度较大,训练数据集不足以支撑训练模型获得良好的特征提取能力,易出现过拟合的风险。同时,许多深度学习模型往往仅在封闭的已知类别集合中表现良好,对训练过程中未出现的辐射源类别的泛化能力不足,而现实场景中往往会有新的辐射源加入,此时模型的识别性能将大幅降低。此外,深度学习模型决策的可解释性差以及对数据集标签的需求等问题也限制了其在动态开放场景中的广泛应用。

针对深度学习模型的诸多问题,小样本学习被引入 SEI 领域,旨在使模型能够仅通过少量的样本来快速适应任务。该方法的核心思想是通过度量学习、元学习或数据增强等方式,使模型在预训练阶段学习可迁移的通用特征表示,从而在面对新类别时仅需少量样本即可实现有效识别。Wang 等人^[10]提出了一种深度度量集成学习模型,采用复值卷积神经网络+混合度量损失进行特征嵌入,并构建集成分类器,在 ADS-B 数据集上进行预训练后,在每类仅 5 个支持集样本的条件下识别准确率达到 98%。Xie 等人^[11]提出了一种基于 VMD 和元学习的识别方法:首先,对接收信号进行 VMD 处理,再通过希尔伯特变换获得希尔伯特时频谱;随后,构建了基于优化的元学习算法,仅需 80 个带标签样本即可完成训练,在低信噪比环境下取得了超过 80% 的识别准确率。Liu 等人^[12]提出了一种基于双插值度量学习的小样本学习方法:首先,对小波分解后的低频和高频系数进行混合与重构;其次,在样本层面对重构后的信号序列进行 Mixup 插值,以增强数据多样性;然后,采用复值卷积神经网络进行特征提取与分类。该方法不依赖辅助数据集,在真实 Wi-Fi 数据集上仅需 10 个样本即可达到 91.48% 的准确率。然而,现有以 Transformer 为代表的主流模型架构依赖自注意力机制,其计算复杂度与序列长度平方成正比($O(n^2)$),这使得传统 Transformer 架构在处理长序列任务中面临计算开销巨大的问题。随着未来对高采样率、长时信号分析以及边缘设备部署需求的日益增长,急需寻找具有更高计算效率的序列建模方法。相比之下,Mamba 通过结构化状态空间与选择性扫描机制,在保持对长距离序列有效建模的同时,将计算复杂度降低至线性相关($O(n)$),在资源受限或实时响应场景下具有更好的应用前景。

综合上述分析,现有研究在应对复杂电磁环境下样本稀缺、类别动态变化等挑战时仍存在提升空间。本文重点聚焦小样本条件下通信辐射源的高效识别

问题,提出了一种基于无损变分模态分解和 Mamba 自监督学习网络的算法。该方法首先通过无损 VMD 信号分解提升指纹特征的显式表达能力,并进一步利用具有线性复杂度的序列建模网络捕获其长程依赖,同时结合自监督预训练方案学习信号指纹的通用表征,最终实现在有限标注样本与低计算开销条件下模型识别性能与泛化能力的提升。本文的主要贡献包括:

(1) 在信号预处理中引入了无损 VMD 分解。相较于传统的 VMD 分解方法,无损 VMD 在保持信号能量完整传递的同时,避免了因迭代产生的重建误差与模态混叠。同时,由于手动分配了中心频率,无需解决优化问题,分解所需时间大幅缩短。

(2) 将 Mamba 架构引入 SEI 的自监督学习框架。利用选择性状态空间模型和线性扫描机制,实现在线性相关的计算复杂度下,有效建模信号的长程依赖关系,与平方复杂度的 Transformer 相比,在模型轻量化与推理效率上具有显著优势。

(3) 实现了混合损失自监督预训练+冻结特征提取器微调的两阶段框架。通过对比损失和监督损失的联合优化,促使模型学习对信道畸变不变的通用特征表示。在下游任务中,仅需微调一个轻量的线性分类器,即可快速适配新类别,极大地降低了对目标域标注数据量的需求。

1 模型算法

本文模型算法由三部分组成:第一部分为基于无损 VMD 的信号分解;第二部分为基于 Mamba 的自监督学习算法;第三部分为基于小样本学习的微调。模型整体流程如图 1 所示。

1.1 信号获取

一般而言,接收机接收到的无线信号模型可以表示为

$$x(t) = h(t) * s(t) + n(t) \quad (1)$$

其中: $x(t)$ 为接收信号; $h(t)$ 为无线信道响应; $s(t)$ 为发射机发送的符合预先规定协议(如 802.11 a/g 等)的标准数据包,一般包含前导码和数据块; $n(t)$ 为信道噪声。发送信号在传播过程中受到时变信道 $h(t)$ 的影响,并与加性噪声 $n(t)$ 混合,最终被多个未同步的通用软件无线电外设捕获,得到离散的复基带 I/Q 样本序列。通过对捕获的原始信号进行能量检测与筛选,可从连续的 I/Q 样本流中分离出有效数据包,并排除来自接入点的 ACK 响应信号。对每个有效数据包,截取其固定长度的 I/Q 样本,构成非均衡数据集。为了获取信道无关的射频指纹信息,进一步利用已知的前导码(典型如 L-STF 和 L-LTF 等)对数据进行重采样、频偏估计与校正、信道估计与最小均方误差




图1 SSL-Mamba模型整体流程图

Figure 1 Overview of the SSL-Mamba model

(Minimum Mean Square Error, MMSE)均衡,再从处理后的信号中提取固定长度的I/Q样本,构成均衡数据集。对于Wi-Fi类型数据集,文献[13]详细阐述了信号获取的流程。

1.2 基于无损VMD的信号分解算法

对提取到的I/Q信号,进一步引入VMD分解方法。VMD是Dragomiretskiy和Zosso于2014年提出的一种算法^[14],通过构建变分问题,将信号分解为本征模态函数(Intrinsic Mode Functions, IMF)分量,使所有分量具有最小带宽之和,同时确保所有分量之和等于原始信号。VMD的约束变分问题可以表示为

$$\min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \quad (2)$$

$$\text{s.t. } \sum_{k=1}^K u_k = f$$

其中: $\{u_k\}$ 为分解后的第 k 个IMF分量; $\{\omega_k\}$ 为其中心频率; $\delta(t)$ 为狄拉克函数; $*$ 为卷积运算符; ∂_t 为关于 t 的导数; $\|\cdot\|$ 为泛函空间 $C(-\infty, \infty)$ 中的 L^2 范数; K 为需要分解的分量数; f 为输入信号。

引入Lagrange乘法算子 λ 和惩罚系数 α ,可将式(2)所述约束变分问题转换为非约束变分问题,即

$$L(\{u_k\}, \{\omega_k\}, \lambda) = \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_k u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \quad (3)$$

进一步利用交替方向乘子(Alternating Direction Method of Multipliers, ADMM)迭代 u_k^{n+1} 、 ω_k^{n+1} 和 λ_k^{n+1} ,寻求增广拉格朗日表达式的鞍点,并使用Plancherel傅里叶等距变换,可得到频域表达式为

$$\hat{u}_k^{n+1} = \underset{\hat{u}_k, u_k \in X}{\operatorname{argmin}} \left\{ \int_0^\infty \left\| j\omega \left[(1 + \operatorname{sgn}(\omega)) * \hat{u}_k(\omega) \right] \right\|_2^2 + \left\| \hat{f}(\omega) - \sum_k \hat{u}_k(\omega) + \frac{\hat{\lambda}(\omega)}{2} \right\|_2^2 \right\} \quad (4)$$

其中, X 为 u_k 的全部可取集合, ω 为随机频率。将第一项的 ω 用 $\omega - \omega_k$ 代替并转换为非负频率区间积分的形式,进一步简化可得到 $\hat{u}_k^{n+1}$ 二次优化问题的解为

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (5)$$

同理也可求得 ω_k^{n+1} 和 $\hat{\lambda}^{n+1}$ 的最小值问题。然而,由于ADMM中引入了拉格朗日乘子 λ ,会产生显著的重建误差,该误差随着IMF分量的增加变得明显,可能会滤除辐射源的关键频谱特征,甚至有可能会错误地定位中心频率。为了解决ADMM方法的缺点,Liu等人^[15]提出了一种改进VMD算法,称为无损VMD,该方法基于式(4)的闭形式解进行优化,通过手动分配中心频率,并采用自适应加权方式对不同IMF分量进行融合,避免了迭代过程中对 λ 的强依赖,以及中心频率位置错误的可能性。同时,无损VMD能够保持信号能量的完整传递,在分解的过程中也不会引入信息丢失,可以完全还原出原始信息。具体方程为

$$U_k(\omega) = F(\omega) \cdot \frac{(\omega - \omega_k)^{-2}}{\sum_i (\omega - \omega_i)^{-2}} \quad (6)$$

其中中心频率 ω_k 可以通过求解以下优化问题得到:

$$\operatorname{argmin} \{ \omega_k \} \int_0^\infty \frac{|F(\omega)|^2}{\sum_k (\omega - \omega_i)^{-2}} d\omega \quad (7)$$

实际上,数字调制信号的频谱在其基本频率 $2\pi/T_s$ 的倍数上达到峰值,其中, T_s 为单个符号时长。因此,可以直接设定 IMF 分量 ω_k 的中心频率为 $2\pi/T_s$ 的倍数。为了处理离散信号,可以得到式(6)的离散形式为

$$U_k(\omega) = F(\omega) \cdot \frac{(k - k_i)^{-2}}{\sum_j (k - k_j)^{-2}}, \quad k = 0, 1, \dots, L-1 \quad (8)$$

其中, k_i 为第 i 个中心频率对应的离散傅里叶变换 (Discrete Fourier Transform, DFT) 索引。若已知原始 I/Q 信号的采样率和符号率,可计算得到基频 $2\pi/T_s$ 对应的 DFT 索引 k_0 :

$$k_0 = \frac{f_{\text{sample}}}{f_{\text{symbol}}} \quad (9)$$

VMD 作为一种数据增强手段,将每个输入信号分解为 k 个通道,实现了从原始 I/Q 信号空间到更高维分解空间的变换,即变换 $\varphi: \mathbb{R}^{L \times 2} \rightarrow \mathbb{R}^{L \times k \times 2}$ 。该变换将一维的原始 I/Q 序列映射为包含 k 个固有模态函数的二维时频表示,有效地丰富了序列结构信息,使得模型能够从不同频带分量中提取更具判别性的指纹特征。同时,本文采用的无损 VMD 相较于 ADMM,在模态混叠抑制方面具有更优性能,能够生成更纯净、更具判别性的 IMF 分量,使得特征提取阶段模型能够

更聚焦于硬件自身的射频特征,而非 VMD 算法引入的分解噪声,进而提升小样本条件下辐射源识别的鲁棒性与准确率。

1.3 基于 Mamba 的自监督学习算法

本文提出了一种基于 Mamba 的自监督学习框架,旨在从射频信号中学习更具鲁棒性的特征表示。Mamba 是一种基于结构化状态空间模型 (Structured State Space Models, Structured SSM) 的序列建模架构^[16],其核心在于引入了选择性扫描机制,能够根据当前输入动态地调整状态转移参数,从而有效克服了传统线性时不变 SSM 在建模处理长序列依赖时的局限。与依赖自注意力机制的 Transformer 架构相比, Mamba 能够在保持线性时间复杂度的同时,高效地捕捉长距离的依赖关系,因而在长序列建模任务中展现出显著的计算效率优势。本文所提出的自监督框架中包含两条并行的前向传播支路,两条支路共享一个由卷积神经网络和 Mamba 线性流编码器构成的特征提取与编码主干网络,该网络的支路结构如图 2 所示。对于 VMD 分解后得到的 IMF 分量 X_{ori} ,支路一直接对 X_{ori} 处理,支路二则对 X_{ori} 数据增强得到的分量 X_{aug} 处理。整个自监督学习过程可表示为如下数学形式:

$$X_{\text{aug}} = \text{DA}(X_{\text{ori}})$$

$$X_{\text{ori}}^{\text{enc}} = \text{Encoder}(\text{Extraction}(X_{\text{ori}})) \quad (10)$$

$$X_{\text{aug}}^{\text{enc}} = \text{Encoder}(\text{Extraction}(X_{\text{aug}}))$$

其中: $X_{\text{ori}}, X_{\text{aug}} \in \mathbb{R}^{b \times T \times c}$ 为输入分量; $X_{\text{ori}}^{\text{enc}}, X_{\text{aug}}^{\text{enc}} \in \mathbb{R}^{b \times T \times d_m}$ 为编码后的特征序列,这里 b 为批次大小, T 为序列长度, c 为输入通道数(对于 VMD 数据, $c = 2k$, k 为 VMD 分解通道数), d_m 为特征维度。




图2 自监督网络支路框架结构

Figure 2 Self-supervised network branch framework structure

为构建具有挑战性的自监督学习重建任务,本文在预训练阶段采用了以下3种数据增强方法:(1)时间掩码增强,对原始信号随机片段置零来模拟传输过程中出现的信号丢失;(2)高斯加噪增强,对原始信号添加高斯噪声来模拟传输环境中的背景噪声;(3)信号插值增强,依据公式 $C = \alpha A + (1 - \alpha)B$ 在不同样本间进行线性插值,其中 A, B 属于同类别样本,通过在特征空间生成新的合成样本来扩充样本多样性。所有增强样本经过归一化处理,并与原始样本合并,从而构建出一个均衡且规模较大的训练集。该增强流程的核心意义在于,通过构建多样且符合真实信道畸变的信号变体,迫使模型在预测与重构过程中学习到对多种干扰不变的通用特征表示,为后续小样本微调提供强初始化的特征提取基础。

1.3.1 CNN 特征提取模块

自监督算法的特征提取模块是一个由多个级联的残差一维卷积块(记为 ResConv1d)构成的卷积神经网络,特征提取器从输入张量 $\mathbf{X}_{\text{ori}}, \mathbf{X}_{\text{aug}}$ 中进行多层次、多尺度的时域特征提取。每个 ResConv1d 块包含一条捷径,若输入与输出的通道维度不一致,则应用 1×1 卷积进行维度变换,即 $\mathbf{X}_{\text{cut}} = \text{Conv1d}_{1 \times 1}(\mathbf{X}_{\text{in}})$;若维度一致,则应用恒等映射,即 $\mathbf{X}_{\text{cut}} = \mathbf{X}_{\text{in}}$ 。主干路径包含两路并行卷积分支,分别设置不同大小的卷积核 k_t, k_f , 得到不同感受野下的时域特征 $\mathbf{X}_t = \text{Conv1d}_{k_t}(\mathbf{X}_{\text{in}})$ 和 $\mathbf{X}_f = \text{Conv1d}_{k_f}(\mathbf{X}_{\text{in}})$, 将 $\mathbf{X}_t$ 和 $\mathbf{X}_f$ 相加,经过批归一化和 ReLU (Rectified Linear Unit) 激活函数,再与捷径输出 $\mathbf{X}_{\text{cut}}$ 相加得到该块的最终输出 $\mathbf{X}_{\text{out}} \in \mathbb{R}^{b \times T \times d_m}$ 。这种残差结构能有效捕获信号中的短程和长程时间特性,并缓解梯度消失和促进特征重用,将低层特征提炼为更高维度的表示,提升模型在后续编码阶段区分不同设备的能力。

1.3.2 Mamba 线性流编码模块

Mamba 线性流编码器通过单个 Mamba 层处理 CNN 提取得到的特征张量,并利用 SSM 以线性复杂度处理序列的依赖关系。SSM 将序列处理建模为一个连续时间系统的离散化形式,对于 t 时刻的输入序列 $x_t \in \mathbb{R}^{b \times d_m}$, 系统通过一个隐藏状态 $h_t \in \mathbb{R}^{b \times d_s}$ 来演化:

$$\begin{aligned} h_t &= \bar{A}h_{t-1} + \bar{B}x_t \\ y_t &= \bar{C}h_t \end{aligned} \quad (11)$$

其中,状态转移矩阵 $\bar{A} \in \mathbb{R}^{b \times d_s \times d_s}$, 输入矩阵 $\bar{B} \in \mathbb{R}^{b \times d_s \times d_m}$, 输出矩阵 $\bar{C} \in \mathbb{R}^{b \times d_m \times d_s}$ 是由连续时间参数 A, B 和离散化时间参数 Δ 通过零阶保持得到的,具体为 $\bar{A} = \exp(\Delta A)$, $\bar{B} = (\Delta A)^{-1}(\exp(\Delta A) - I) \cdot \Delta B$ 。输入首先经过均方根层归一化处理,随后通过线性投影进

行通道维度扩展。接着,信号被送入一个卷积核大小为 k_c 的一维卷积层处理,卷积输出与独立线性投影生成的信号逐元素相乘实现选择性门控,再输入到选择性状态空间模型中。SSM 的输出与另一路独立投影生成的信号进行逐元素相乘,经过全局平均池化输出最终编码序列 $\mathbf{X}^{\text{enc}} \in \mathbb{R}^{b \times T \times d_m}$ 。在此过程中, Mamba 块以流式方式处理 CNN 提取得到的特征,通过隐藏状态 h_t 线性递归积累序列信息。与 Transformer 架构相比, Mamba 避免了对所有历史元素进行相似度计算的高昂开销,在保持线性计算复杂度的同时,仍能通过对输入变化的选择性参数适应来保持区分辐射源指纹的能力。

自监督预训练流程如算法 1 所示。

算法 1 自监督预训练流程

输入: IMF 分量数据集 D , 数据增强参数 aug_par , 损失权重 λ_c, λ_s

输出: 预训练好的特征提取器 F_θ

数据与模型准备

从文件中加载预处理好的训练集 D_{train} 和验证集 D_{val}

初始化模型: $M = (F_\theta, P_\phi, C_\psi)$ 包含投影头、分类头

定义损失函数: $\mathcal{L}_{\text{contrastive}}, \mathcal{L}_{\text{supervised}}$

定义优化器与学习率调度器: $\text{optimizer}, \text{scheduler}$

主循环训练

FOR epoch = 1 in 1 000

FOR batch in D_{train}

从训练集中抽取样本 $\mathbf{X}_{\text{ori}}, \mathbf{Y}_{\text{labels}}$

$\mathbf{X}_{\text{aug}} = \text{DA}(\mathbf{X}_{\text{ori}}, \text{aug_par})$ 数据增强

$\text{outputs} = M(\mathbf{X}_{\text{ori}}, \mathbf{X}_{\text{aug}})$

$\mathcal{L}_{\text{contrastive}} = \text{contrastive}(\text{outputs})$

$\mathcal{L}_{\text{supervised}} = \text{supervised}(\text{outputs}, \mathbf{Y}_{\text{labels}})$

$\mathcal{L}_{\text{total}} = \lambda_c \mathcal{L}_{\text{contrastive}} + \lambda_s \mathcal{L}_{\text{supervised}}$

$M = \text{optimizer.zero_grad}(M, \mathcal{L}_{\text{total}})$

END

验证与学习率调整

从验证集中抽取样本 $\mathbf{X}'_{\text{ori}}, \mathbf{Y}'_{\text{labels}}$

按照训练集处理流程计算验证集损失函数 $\mathcal{L}_{\text{val}}$

检查早停并保存最佳模型

IF $\mathcal{L}_{\text{val}} < \mathcal{L}_{\text{val_best}}$

保存模型

IF $\mathcal{L}_{\text{val}}$ 连续 10 个 epoch 未衰减

调整学习率

END

模型采用了一种对比学习和监督学习相结合的混合损失策略,其目标函数定义为

$$\mathcal{L}_{\text{total}} = \lambda_c \mathcal{L}_{\text{contrastive}} + \lambda_s \mathcal{L}_{\text{supervised}} \quad (12)$$

其中, $\mathcal{L}_{\text{contrastive}}$ 为对比损失, $\mathcal{L}_{\text{supervised}}$ 为分类损失, λ_c 和 λ_s 为两项损失函数的加权系数。对比损失采用基于

InfoNCE (Noise-Contrastive Estimation) 的对比学习形式,其核心思想是通过鼓励模型对同一信号的不同增强视图在特征空间中保持接近,而对不同信号的增强视图保持远离,促使模型学习对数据增强具有不变性的通用特征表示。具体地,对于同一批次内的 N 个原始信号样本 $\{x_i\} (i=1,2,\dots,N)$,对每个样本施加数据增强,得到其增强视图 x_i^+ , (x_i, x_i^+) 构成一个正样本对。记 z_i 和 z_i^+ 分别为 x_i 和 x_i^+ 经过特征提取器、编码器和投影头后得到的归一化特征向量。则样本 x_i 的对比损失为

$$\mathcal{L}_{\text{contrastive}}^{(i)} = -\log \frac{\exp(\text{sim}(z_i, z_i^+))}{\sum_{k=1|k \neq i}^{2N} \exp(\text{sim}(z_i, z_k))} \quad (13)$$

其中, $\text{sim}(u, v)$ 为两个归一化向量的余弦相似度,分母部分求和批次中除 z_i 本身外的所有 $2N-1$ 个特征向量(包括同一样本的增强视图、其他样本的原始视图和增强视图)。

分类损失采用标准交叉熵损失,确保模型所学特征能够有效服务于下游的分类任务,其定义为

$$\mathcal{L}_{\text{supervised}} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \cdot \log(\hat{y}_{i,c}) \quad (14)$$

其中, N 为批次大小, C 为类别数, $y_{i,c}$ 为样本 i 的真实标签, $\hat{y}_{i,c}$ 为模型对类别 c 的预测概率。训练目标旨在最小化原始信号编码 $\mathbf{X}_{\text{ori}}^{\text{enc}}$ 与对应增强信号编码 $\mathbf{X}_{\text{aug}}^{\text{enc}}$ 在特征空间中的对比损失,同时结合对 $\mathbf{X}_{\text{ori}}$ 的分类损失,确保模型能够学习到对数据增强具有鲁棒性,同时对设备类别信息敏感的强大特征表示。预训练完成后,特征提取器部分(CNN 提取器+Mamba 编码器)可被迁移至下游的小样本射频指纹识别任务中。

1.4 小样本微调

本文采用小样本微调的方式以应对 SEI 任务中训练样本稀缺的问题。在微调阶段,本文使用 Mamba 自监督学习训练得到的模型作为特征提取器,并冻结该特征提取网络的参数,仅使用目标域下的小样本支持集对末端的一个轻量级线性分类器进行有监督的微调,使其适应特定的分类任务。微调阶段以标准交叉熵损失为损失函数,其定义为

$$\mathcal{L}_{\text{classifier}} = \text{CrossEntropyLoss}(\hat{y}, y_{\text{true}}) \quad (15)$$

其中, $\hat{y}$ 为模型对输入样本的预测标签; y_{true} 为样本的真实标签。微调阶段的损失函数设置与预训练阶段的分类损失一致,此处不再赘述。整个过程中,只对分类器的参数进行更新,特征提取器负责从样本中提炼出对掩码、噪声与插值操作具有不变性的深层特征,而微调过程则将这些高级特征映射到任务具体的辐射源类别上。该阶段通过将计算量大的通用特征

学习与具体任务分离,实现了小样本场景下模型性能的快速收敛与提升。后续实验表明,该方法能够在样本量有限的情况下,利用预训练特征提取器提供的强特征提取能力,实现较高的识别精度。小样本微调阶段流程如算法 2 所示。

算法 2 小样本微调训练流程

输入: 目标域的 IMF 分量数据集 D_{target}

输出: 分类器 C_{θ}

数据与模型准备

加载目标域数据集 $D_{\text{support}}^{\text{train}}$

加载预训练好的特征提取器 F_{θ}

初始化分类器: C_{θ}

定义损失函数: $\mathcal{L}_{\text{classifier}}$

定义优化器与学习率调度器: optimizer, scheduler

数据处理

应用无损 VMD 分解

主循环训练

FOR batch in $D_{\text{support}}^{\text{train}}$

从训练集中抽取样本 $\mathbf{X}, Y_{\text{labels}}$

提取特征 $\mathbf{X}_{\text{feature}} = F_{\theta}(\mathbf{X})$

outputs = $C_{\theta}(\mathbf{X}_{\text{feature}})$

$\mathcal{L}_{\text{classifier}} = \text{CrossEntropyLoss}(\text{outputs}, Y_{\text{labels}})$

$C_{\theta} = \text{optimizer.zero_grad}(C_{\theta}, \mathcal{L}_{\text{classifier}})$

END

保存分类器

END

2 实验设置

2.1 数据集

本文使用 WiSig 数据集中的一个预打包好的子集, WiSig 数据集是一个大规模、被广泛使用的 Wi-Fi 信号集合, 专门为独立于接收机和信道的射频指纹识别任务而设计, 具有明确的多接收机、多日期采集的特性。所采用的 ManyTX 子集涵盖了 150 个不同的 Wi-Fi 发射机, 其信号被 18 个不同的 USRP 接收机在 4 个不同的日期下捕获, 每个发射机-接收机-日期组合至少提供 50 个信号样本, 总数据量约 2.5 GB。所有信号样本均遵循 IEEE 802.11a/g 协议标准, 统一采样率为 25 Ms/s, 每段序列长度为 256 个采样点的标准化 I/Q 序列, 且均通过 MMSE 信道均衡处理, 在一定程度上抑制了无线信道状态对指纹特征的干扰, 从而在数据层面上增强了对不同信道条件的泛化能力。

为使该数据集能够适应所提出的深度学习框架, 对该子集进行了预处理。首先, 以发射机类别为唯一标识, 将来自不同接收机和日期的信号样本合并; 随后, 将全部 150 个发射机划分为两部分, 前 130 个类别用于特征网络的自监督预训练阶段, 后 20 个类别用

于后续的小样本微调任务。该划分方案旨在模拟真实场景中模型在已知类别上学习通用特征后,面对新增类别时仅凭极少标注样本进行快速适应的过程,从而有效验证本文方法在小样本场景下的识别与泛化能力。

2.2 参数设置

原始 ManyTX 数据集信号的采样率与符号率分别为 $f_{\text{sample}} = 25 \text{ Ms/s}$ 和 $f_{\text{symbol}} = 2 \text{ Ms/s}$, 由此可以计算得到基频对应 DFT 索引 $k_0 = 12.5$ 。对数据集信号进行频谱分析可知,最后一个频谱峰值出现在 DFT 索引 $6k_0 = 75$ 附近。因此对 VMD 的每个模态分量设置中心频率时,需要尽可能在频率轴上均匀分布,并确保每个中心频率均为 k_0 的整数倍。最终无损 VMD 中不同 k 值对应的中心频率设置如表 1 所示。

表 1 中心 DFT 索引选择

Table 1 Central DFT index selection

模态分量数 k	中心 DFT 索引
2	$\{2k_0, 4k_0\}$
3	$\{k_0, 3k_0, 5k_0\}$
4	$\{0, 2k_0, 4k_0, 6k_0\}$
5	$\{0, k_0, 3k_0, 5k_0, 6k_0\}$
6	$\{k_0, 2k_0, 3k_0, 4k_0, 5k_0, 6k_0\}$
7	$\{0, k_0, 2k_0, 3k_0, 4k_0, 5k_0, 6k_0\}$

自监督学习阶段模型的结构参数见表 2。对比损失和分类损失的占比权重 $\lambda_c = \lambda_s = 0.5$ 。优化器选用 Adam, 初始学习率为 1×10^{-3} 。学习率调度器在验证损失连续 10 个 epoch 未下降时将学习率乘以因子 0.1 衰减, 并设置最低学习率阈值 1×10^{-5} , 当学习率低于该阈值时触发早停。所有数据集的批次大小均为 32, 训练最多进行 1 000 个 epoch, 并选取验证损失最低的模型用于后续任务。

CNN 特征提取器中, 2 个 ResConv1d 块的卷积核大小分别设置为 $k_t = 3$ 和 $k_f = 15$, 用于捕获输入信号

表 2 自监督学习阶段模型结构参数

Table 2 Self-supervised learning stage model structure parameters

参数	取值
对比损失权重 λ_c	0.5
分类损失权重 λ_s	0.5
初始学习率 lr	1×10^{-3}
最小学习率 $\text{lr}_{\min}$	1×10^{-5}
卷积核大小 k_t	3
卷积核大小 k_f	15
卷积核大小 k_e	4
特征维度 d_m	64
通道扩展因子 e	2

的短时细节和长程序模式, 特征维度 d_m 设为 64。Mamba 线性流编码器使用单层 Mamba 块, 其内部选择性状态空间模型的状态维度 $d_s = 15$, 卷积核大小 $k_e = 4$, 通道扩展因子 $e = 2$, 以权衡模型的表达能力与计算开销。

自监督训练中应用的数据增强策略参数如表 3 所示, 所采用的 3 种数据增强方法具体如下: 随机掩码比例分别为 20%、30%、40%; 加性高斯噪声方差分别为 0.01、0.02、0.03; 线性样本插值系数 $\alpha \in (0.2, 0.8)$ 。小样本微调阶段的参数设置如表 4 所示, 训练仅进行 1 个 epoch, 优化器选用 Adam, 学习率设置为 0.001, 数据集批次大小为 1。本文所有实验均在一块配备 24 GB 显存的 NVIDIA GeForce RTX4090 显卡上完成。

表 3 数据增强参数

Table 3 Data augmentation parameters

参数	取值
随机掩码比例/%	20, 30, 40
高斯噪声方差	0.01, 0.02, 0.03
线性插值系数	(0.2, 0.8)

表 4 小样本微调阶段参数

Table 4 Few-shot fine-tuning stage parameters

参数	取值
训练 epoch	1
学习率 lr	1×10^{-3}
批次大小	1

3 实验结果与分析

3.1 对比实验分析

为系统评估所提方法在小样本射频指纹识别任务中的有效性与泛化能力, 本文在 ManyTX 数据集的后 20 个类别中随机选取 6 个发射机类别进行测试, 验证了不同预处理方法和网络框架组合下的模型性能。本节将所提出的模型与 3 种典型的小样本辐射源识别算法^[17-19]进行对比, 其中: 文献[17]通过基于对抗增强的自监督学习在无标签辅助数据集上预训练一个射频指纹特征提取器, 再以少量标注样本进行微调 (SA2SEI); 文献[18]通过插值度量学习在样本空间中挖掘更多隐含样本以提升模型泛化能力, 同时对特征空间距离施加约束 (IntelML); 文献[19]设计了一种双层数据增强的 SEI 方法, 在样本空间和特征空间同时进行相位偏移位置预测和流形切分混合 (P3MC)。图 3 为 4 种方法在不同数量支持集样本下的识别准确率曲线。

实验结果表明, 即使在支持集样本数为 1 的极端小样本设置下, 本文所提出的模型仍可达到 91.20%





图3 不同小样本识别算法识别准确率对比


Figure 3 Comparison of recognition accuracy for different few-shot recognition algorithms

的分类准确率,显著优于其他对比方法,充分验证了所提方法在小样本条件下对射频指纹特征的强大提取能力。随着支持集样本数增加至 20,模型准确率提升至 92.01%,表现出一定的数据利用效率,但性能提升趋于平缓,说明模型在少量标注样本下即可快速收敛至稳定状态。相比之下,基准方法 IntelML 和 P3MC 在支持集样本数为 1 时准确率仅为 51.26% 和 61.10%,虽然随着支持集样本数增加,模型性能显著提升,当样本数为 20 时准确率为 96.67% 和 91.02%,但其性能对样本数量高度敏感,稳定性不足。SA2SEI 方法在 1 个样本时表现良好,准确率为 81.34%,但在所有样本规模下性能始终低于本文所提



(a) 识别准确率对比

(a) Comparison of recognition accuracy



(b) 耗时对比

(b) Comparison of time consumption

图4 不同IMF分量下ADMM和无损VMD分解识别准确率和耗时

Figure 4 Recognition accuracy and time consumption for ADMM and lossless VMD decomposition under different IMF components

3.3 消融实验及计算复杂度分析

为验证本文所提算法中各组件的有效性,本节进行了消融实验。实验主要评估了3个关键部分的影响:移除自监督学习模块、移除预训练阶段的分类损失,以及仅保留单种数据增强策略。实验在 $k=2$ 的无损 VMD 分解设置下进行,并与完整模型进行对比,结果如图 5 所示。实验结果显示,当移除自监督学习

方法,进一步验证了本文方法在特征提取能力和小样本适应性上的优势。

3.2 关键参数对模型性能影响分析

为评估无损 VMD 和 ADMM 两种分解方法的性能,本节在支持集样本数为 1 的微调设置下,对比并分析了两种方法在 IMF 分量数 $k \in \{2, 3, 4, 5, 6, 7\}$ 区间内的分类准确率和分解耗时情况,结果如图 4 所示。实验结果表明,当 $k=2$ 时,无损 VMD 和 ADMM 均获得最优分类性能,准确率分别为 91.20% 和 88.38%。随着 k 的增大,两种方法识别准确率整体呈下降趋势,其中,无损 VMD 在 $k=5$ 时降至最低点 82.57%,ADMM 则在 $k=7$ 时降至最低点 83.21%。这一现象表明,适度限制模态分解数量有助于模型聚焦射频信号关键判别特征,而过度的模态分解可能引入较大的重建损失,干扰模型对有效射频指纹特征的学习。

值得注意的是,ADMM 在不同 k 值下表现出更强的稳定性,尤其在 $k \geq 4$ 时性能接近甚至局部超过无损 VMD,但峰值性能始终低于无损 VMD。在计算效率方面,无损 VMD 的分解耗时在不同 k 值下基本保持稳定,均值约为 2.5 ms,而 ADMM 的分解耗时随 k 增加呈指数级上升,从 $k=2$ 时的 5.40 ms 增至 $k=7$ 时的 87.11 ms,为无损 VMD 的 36 倍。这表明 ADMM 在模态数较高时的计算负担极大。综合考虑性能表现和计算效率, $k=2$ 的无损 VMD 为本研究中最优的模态分解设置。

模块,仅使用非自监督框架时,模型在目标任务上的最终分类准确率与完整框架基本持平,这表明即便不引入自监督学习,所提架构本身也具备较好的特征提取与分类能力。然而,引入自监督学习框架后,模型在预训练阶段展现出了更快的收敛速度,且不引入额外的模型复杂度。相比之下,当移除面向任务的分类损失,仅依赖对比损失进行优化时,模型的分类准确

率骤降至 48.01%。这表明分类损失对于引导模型学习任务判别性特征具有不可或缺的作用,确保模型在通用特征表示的基础上,更关注下游的分类任务。此外,若仅保留掩码的数据增强策略,模型性能亦显著下降至 72.95%,表明了支持集样本极少的条件下,数据增强对于扩充样本多样性,提升模型泛化与鲁棒性的关键作用。




图5 消融实验结果

Figure 5 Ablation experiment results

为进一步评估模型效率,本节将所提算法与传统的基于 Transformer 的模型^[15]从训练与推理方面进行了复杂度对比,结果如表 5 所示。分析可知,本文提出的基于 Mamba 的自监督学习框架在多个维度上均展现出显著优势:一方面,尽管本文模型单个训练周期耗时高于非自监督 Mamba 模型,这主要是因为自监督预训练中需要对原始信号及其增强视图分别进行前向传播,等效于数据量翻倍。然而,得益于对比学习带来的更优特征初始化,自监督框架下的 Mamba 算法收敛速度反而更快,整体训练时间仅为非自监督 Mamba 和 Transformer 的 73.48% 和 67.00%;另一方面,本文所提模型参数量为 93 024,是 Transformer 的 63.33%,推理单个样本耗时 0.11 ms,是 Transformer 的 25.58%。上述结果表明,本文所提算法能够在确保高识别性能的同时,在训练速度、模型轻量化和实时推理方面实现显著提升,在计算与存储资源受限的边缘设备上具有较好的应用前景。

3.4 混淆矩阵与特征分布可视化

为了更直观地展示本文所提方法在测试集上的分类性能和特征分布特性,本节采用 t -分布随机邻域嵌入 (t -distributed Stochastic Neighbor Embedding, t -SNE)^[20] 对模型提取的高维特征进行非线性降维处理,并在二维空间中进行可视化分析。 t -SNE 作为一种经典的非线性降维方法,能够在保留高维数据点间局部邻域结构的前提下,有效展示不同类别样本在特征空间中的聚类关系,因此被广泛应用于深度学习模型的特征表

表5 不同方法复杂度对比

Table 5 Comparison of complexity among different methods

指标	SSL-Mamba	Mamba	Transformer
单个 epoch 耗时/s	354	181	234
总训练耗时/h	2.66	3.62	3.97
单样本推理耗时/ms	0.11	0.11	0.43
特征提取器大小/KB	380	380	600
分类器大小/KB	2	2	2
参数量	93 024	93 024	146 876

注:加粗表示最优结果。

达能力评估。图 6 与图 7 分别展示了在两个不同测试集上的混淆矩阵与 t -SNE 特征分布可视化结果。从图 6 的混淆矩阵可见,对角线元素在各类别中均占主导地位,非对角线元素普遍较小且分布稀疏,表明模型在多类别分类任务中具备较高的识别准确率与较低的混淆度。从图 7 中的 t -SNE 可视化结果可见,不同颜色的点簇在二维空间中呈现出较明显的聚类结构,各类别样本在特征空间中高度聚集,仅在原点附近区域存在轻微重叠,说明模型所提取的特征具有良好的类间可分性与类内紧凑性。该可视化结果从几何分布的角度直观验证了本文所提方法能够在高维特征空间中有效分离不同类别,进一步佐证了其在射频指纹识别任务中的良好特征表达与判别能力。

3.5 泛化能力与局限性讨论

本节实验在跨发射机类别的小样本识别任务上验证了所提方法的优异性能。这种良好的泛化能力主要得益于两个方面:首先,所采用的 WiSig ManyTX 数据集包含了多接收机、多日期采集,以及基于 MMSE 的信道均衡处理设置,提供了丰富的训练数据;其次,在自监督预训练阶段,模型已从大规模辅助数据集中学习了面向多种信道退化的不变特征。需要指出的是,在小样本微调阶段,支持集样本数极少,且仅来自单一接收机和单一采集日期。然而模型在包含不同接收机和日期的整个测试集上表现出较高准确率,有力地证明了模型的强泛化能力。

尽管本文方法在受控数据集上展现出良好的泛化潜力,但距离在复杂的电磁环境中部署仍面临一定局限性。首先,跨场景泛化能力有待进一步验证。WiSig 数据集中的 MMSE 均衡主要是针对静态信道模型,而真实无线环境中的非线性畸变或剧烈动态变化可能超出模型所能表示的范围。其次,因设备老化,温度、电压波动等导致的射频特性漂移,依然是模型保持长期稳定识别所必须解决的问题。未来可以着眼于在预训练阶段引入基于信道模型的、更具对抗性的数据增强方法,或结合领域自适应等技术,以构建更具鲁棒性的通用特征提取器。




图6 不同测试集混淆矩阵

Figure 6 Confusion matrices for different test sets




图7 不同测试集t-SNE特征可视化

Figure 7 t-SNE feature visualization for different test sets

4 结束语

针对小样本场景下特定辐射源的高效识别问题,本文提出了一种基于自监督学习的低复杂度识别算法。首先,对原始I/Q信号进行了无损VMD分解,将原始信号映射为具有更强分辨能力的多通道时频表示;然后,构建了一种基于Mamba线性流编码器的自监督学习框架,在辅助数据集上预训练特征提取器,通过设计对比学习与监督学习结合的混合损失函数,促使模型学习对设备身份具有判别性的通用特征表示;最后,利用少量带标注的支持集样本,在冻结特征提取器参数的条件下微调一个线性分类器,以适应具体的下游分类任务。实验证明,本文所提出的算法


能够在较低计算量的情况下取得高精度、高鲁棒性的识别性能,验证了其在动态开放电磁环境中应对小样本识别任务的有效性。

参考文献

- [1] Talbot K I, Duley P R, Hyatt M H. Specific emitter identification and verification[J]. Technology Review Journal, 2003, 11(1): 113-133.
 - [2] 刘高辉, 席宏恩. 改进变分模态分解与多特征的通信辐射源个体识别方法[J]. 电子与信息学报, 2024, 46(10): 4044-4052.
- Liu Gaohui, Xi Hongen. Individual identification method for communication emitters based on improved variational

- modal decomposition and multiple features[J]. *Journal of Electronics & Information Technology*, 2024, 46(10): 4044-4052. (in Chinese)
- [3] 张振, 贾济铖, 康健, 等. 射频指纹识别技术方法综述[J]. *无线电通信技术*, 2021, 47(3): 249-258.
Zhang Zhen, Jia Jicheng, Kang Jian, et al. Overview of RF fingerprint identification technology methods[J]. *Radio Communications Technology*, 2021, 47(3): 249-258. (in Chinese)
- [4] 秦鑫, 黄洁, 查雄, 等. 基于扩张残差网络的雷达辐射源信号识别[J]. *电子学报*, 2020, 48(3): 456-462.
Qin Xin, Huang Jie, Zha Xiong, et al. Radar emitter signal recognition based on dilated residual network[J]. *Acta Electronica Sinica*, 2020, 48(3): 456-462. (in Chinese)
- [5] 桂冠, 陶梦圆, 王诚, 等. 面向特定辐射源识别的小样本学习方法综述[J]. *南通大学学报(自然科学版)*, 2023, 22(3): 1-16.
Gui Guan, Tao Mengyuan, Wang Cheng, et al. Survey of few-shot learning methods for specific emitter identification[J]. *Journal of Nantong University (Natural Science Edition)*, 2023, 22(3): 1-16. (in Chinese)
- [6] 刘旭, 罗鹏飞, 李纲. 基于拟合角特征及SVM的雷达辐射源个体识别[C]//第五届信号和智能信息处理与应用学术会议论文集. 银川: 中国高科技产业化研究会, 2011: 281-284.
Liu Xu, Luo Pengfei, Li Gang. Radar emitter individual identification based on fitting angle features and SVM[C]// *Proceedings of the 5th Academic Conference on Signal and Intelligent Information Processing and Application*. Yinchuan: China High-tech Industrialization Association, 2011: 281-284. (in Chinese)
- [7] 梁江海, 黄知涛, 袁英俊, 等. 一种基于经验模态分解的通信辐射源个体识别方法[J]. *中国电子科学研究院学报*, 2013, 8(4): 393-397.
Liang Jianghai, Huang Zhitao, Yuan Yingjun, et al. A method based on empirical mode decomposition for identifying transmitter individuals[J]. *Journal of China Academy of Electronics and Information Technology*, 2013, 8(4): 393-397. (in Chinese)
- [8] Merchant K, Revay S, Stantchev G, et al. Deep learning for RF device fingerprinting in cognitive communication networks[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2018, 12(1): 160-167.
- [9] Roy D, Mukherjee T, Chatterjee M, et al. RFAL: Adversarial learning for RF transmitter identification and classification[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2020, 6(2): 783-801.
- [10] Wang Yu, Gui Guan, Lin Yun, et al. Few-shot specific emitter identification via deep metric ensemble learning[J]. *IEEE Internet of Things Journal*, 2022, 9(24): 24980-24994.
- [11] Xie Cunxiang, Zhang Limin, Zhong Zhaogen. Few-shot specific emitter identification based on variational mode decomposition and meta-learning[J]. *Wireless Communications and Mobile Computing*, 2022, 2022: 4481416. DOI: 10.1155/2022/4481416.
- [12] Liu Pengfei, Wang Wei, Feng Ziqin, et al. Data-efficient few-shot specific emitter identification using bi-interpolative metric learning[J]. *IEEE Transactions on Information Forensics and Security*, 2025, 20: 6371-6382.
- [13] Hanna S, Karunaratne S, Cabric D. WiSig: A large-scale WiFi signal dataset for receiver and channel agnostic RF fingerprinting[J]. *IEEE Access*, 2022, 10: 22808-22818.
- [14] Dragomiretskiy K, Zosso D. Variational mode decomposition[J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [15] Liu Hanwen, Huang Yuhe, Gong Yifeng, et al. HyDRA: A hybrid dual-mode network for closed- and open-set RF-FI with optimized VMD[J]. *IEEE Internet of Things Journal*, 2025, 12(24): 53828-53841.
- [16] Gu A, Dao T. Mamba: Linear-time sequence modeling with selective state spaces[PP/OL]. V2. arXiv (2024-05-31)[2026-04-04]. <https://doi.org/10.48550/arXiv.2312.00752>.
- [17] Liu Chao, Fu Xue, Wang Yu, et al. Overcoming data limitations: A few-shot specific emitter identification method using self-supervised learning and adversarial augmentation[J]. *IEEE Transactions on Information Forensics and Security*, 2024, 19: 500-513.
- [18] Wang Cheng, Fu Xue, Wang Yu, et al. Interpolative metric learning for few-shot specific emitter identification[J]. *IEEE Transactions on Vehicular Technology*, 2023, 72(12): 16851-16855.
- [19] Xu Lai, Zhang Weijie, Tang Tiantian, et al. P3MC: Dual-level data augmentation for robust few-shot specific emitter identification[J]. *IEEE Internet of Things Journal*, 2025, 12(18): 38668-38679.
- [20] Van der Maaten L, Hinton G. Visualizing data using t-SNE[J]. *Journal of Machine Learning Research*, 2008, 9(86): 2579-2605.

作者简介



何文龙 男,2004年4月出生于湖南省岳阳市。现为东北大学计算机科学与工程学院硕士研究生。主要研究方向为辐射源识别技术及应用。

E-mail: hewl@mails.neu.edu.cn



毛浩阳 男,2006年2月出生于湖南省邵阳市。现为东北大学计算机科学与工程学院本科生。主要研究方向为辐射源识别技术及其应用。

E-mail: ueerscgg@icloud.com



陈 剑 男,1980年9月出生于湖南省邵阳市。现为东北大学计算机科学与工程学院教授、博士生导师。主要研究方向为智能可重构表面、设备到设备通信以及信号与图像处理。

E-mail: chenjian@mail.neu.edu.cn



贾 杰 女,1980年10月出生于辽宁省鞍山市。现为东北大学计算机科学与工程学院教授、博士生导师。主要研究方向为异构网络、物联网和认知无线网络。

E-mail: jiajie@mail.neu.edu.cn



尹宝鑫 男,1999年8月出生于吉林省延边朝鲜族自治州。现为东北大学计算机科学与工程学院博士研究生。主要研究方向为无线通信、信号与处理及其应用。

E-mail: yinbx1@mails.neu.edu.cn



王兴伟 男,1968年1月出生于内蒙古自治区包头市。现为东北大学计算机科学与工程学院教授、博士生导师。主要研究方向为云计算、未来网络等。

E-mail: wangxw@mail.neu.edu.cn