

A Perturbation-Aware Method for Radio Frequency Fingerprint Identification of Specific Emitters

ZHAO Yulu, LI Zhigang, ZHA Haoran, HAN Yu*, LIN Yun

(College of Information and Communication Engineering, Harbin Engineering University, Harbin 150001, China)

Abstract: Specific emitter identification (SEI) leverages the inherent hardware imperfections of wireless device RF front-ends to achieve device identification, serving as a crucial technology for ensuring wireless communication security. However, in complex electromagnetic environments, various perturbations such as carrier frequency offset, sampling clock deviation, gain fluctuation, time shift, and chirp modulation collectively cause distribution shifts in signal features, thereby weakening the stability of RF fingerprint representation and degrading identification performance. To address these issues, this paper proposes a perturbation-aware modulated convolutional neural network (PAM-CNN). This method first utilizes a perturbation-aware branch to jointly estimate the perturbation state and its parameters in the input signal, and then performs sample-adaptive modulation of the convolution kernels based on the estimation results. This enables the network to structurally suppress the impact of perturbations during the feature extraction process. Simultaneously, a multi-task joint training framework is constructed, incorporating device identification, perturbation detection, and parameter regression, to enhance the model's robust representation capability under complex perturbation conditions. Experimental results on a real over-the-air ADS-B baseband dataset and its offline perturbation-augmented data demonstrate that, under various superimposed perturbation conditions, the proposed method achieves an identification accuracy of 95.39% at a signal-to-noise ratio (SNR) of 15 dB and outperforms comparison methods across the full SNR range. The results indicate that this method can effectively enhance the robustness of SEI in complex electromagnetic environments.

Highlights:

1. This paper proposes a perturbation-aware modulated convolutional neural network for robust specific emitter identification, where five typical perturbations, including carrier frequency offset, sampling clock deviation, gain fluctuation, time shift, and chirp modulation, are explicitly modeled and used to guide sample-adaptive convolution kernel modulation.
2. This paper builds a multi-task learning framework that jointly optimizes emitter classification, perturbation detection, and parameter regression. Experiments on real over-the-air ADS-B baseband data and perturbation-augmented data demonstrate that the proposed method improves recognition robustness under multiple perturbations and different SNR conditions.

Key words: specific emitter identification (SEI); radio frequency fingerprint; perturbation awareness; modulated convolutional network; multi-task learning

Foundation item: Independent Research Project of the National Key Laboratory of Space Intelligent Manipulation Technology(No. 2025-JCJQ-LC-020-24).

Received: 2026-03-15; **Revised:** 2026-04-27

***Corresponding author, E-mail:** yu.han1001@hrbeu.edu.cn.

基于扰动感知的辐射源射频指纹识别方法

赵雨露, 李志刚, 查浩然, 韩宇, 林云

(哈尔滨工程大学信息与通信工程学院, 哈尔滨 150001)

摘要: 辐射源个体识别(Specific emitter identification, SEI)通过挖掘无线设备射频前端固有的硬件非理想特性实现设备身份辨识,是保障无线通信安全的重要技术。然而,在复杂电磁环境下,载波频偏、采样时钟偏差、增益波动、时间平移及线性调频等多类扰动会共同引起信号特征分布偏移,进而削弱射频指纹表征的稳定性并降低识别性能。针对上述问题,本文提出一种扰动感知调制卷积神经网络(Perturbation-aware modulated convolutional neural network, PAM-CNN)。该方法首先利用扰动感知分支对输入信号中的扰动状态及其参数进行联合估计,再依据估计结果对卷积核进行样本自适应调制,使网络能够在特征提取过程中对扰动影响进行结构化抑制;同时,构建设备识别、扰动检测与参数回归的多任务联合训练框架,以提升模型在复杂扰动条件下的鲁棒表征能力。在真实空口ADS-B基带数据集及其离线扰动增强数据上的实验结果表明,在多种扰动叠加条件下,所提方法在15 dB信噪比(Signal-to-noise ratio, SNR)下的识别准确率达到95.39%,并在全SNR范围内整体优于对比方法。结果表明,该方法能够有效提升复杂电磁环境下SEI的鲁棒性。

关键词: 辐射源个体识别;射频指纹;扰动感知;调制卷积网络;多任务学习

中图分类号: TN929.5 **文献标志码:** A

引用格式: 赵雨露,李志刚,查浩然,等.基于扰动感知的辐射源射频指纹识别方法[J].数据采集与处理,2026,41(3):674-686. ZHAO Yulu, LI Zhigang, ZHA Haoran, et al. A perturbation-aware method for radio frequency fingerprint identification of specific emitters[J]. Journal of Data Acquisition and Processing, 2026, 41(3):674-686.

引言

无线通信技术的快速发展,使电磁频谱成为支撑关键基础设施与军事信息化的核心战略资源。在军事领域,电磁频谱作为新型作战空间,其控制能力直接影响战场态势感知,已成为大国战略博弈的关键领域。在民用层面,物联网设备的爆发式增长在推动社会深度互联的同时,也导致频谱资源日趋紧张、电磁环境日益复杂^[1]。传统加密认证机制在资源受限设备中面临密钥管理复杂、计算开销大等局限,且难以有效抵御软件无线电的物理层攻击^[2]。在此背景下,个体辐射源识别技术利用设备硬件差异实现身份精准辨识,为破解电磁空间设备识别难题提供了有效路径,在军民领域均具有重要研究价值与应用前景。

辐射源个体识别(Specific emitter identification, SEI)又称射频指纹识别(Radio frequency fingerprinting identification, RFFI),是物理层安全领域实现设备身份认证的关键技术,其基本原理在于,每台无线设备的射频前端因制造工艺公差、元器件参数漂移及老化效应等因素,会在发射信号中引入难以复现的无意调制特征,形成与设备唯一对应的硬件指纹^[3]。与依赖上层协议或加密算法的传统认证方式相

比,RFFI无需设备额外配合,具有抗仿冒能力强、附加开销低的优势,在频谱监测、物联网终端管控及军事目标识别等领域具有重要应用价值^[4]。该领域研究主要可分为基于人工特征工程的方法和基于深度学习的方法。前者侧重人工设计具有物理意义的统计或变换域特征,后者则依托数据驱动方式实现从原始信号到识别结果的端到端学习^[5]。

早期研究主要围绕人工设计特征展开,重点从瞬态信号或稳态信号中提取能够表征硬件差异的特征描述。针对瞬态信号,Shaw等^[6]利用多重分形谱分析其尺度特性,Hall等^[7]通过相位轨迹刻画制造误差引起的畸变;但瞬态信号持续时间短、捕获困难,在非合作场景下应用受限^[8]。随后研究逐步转向更易获取的稳态信号,并引入希尔伯特-黄变换、小波分析和高阶谱等方法提取统计特征^[9-12]。尽管这类方法在受控条件下能够取得一定效果,但其性能高度依赖人工经验,且对调制方式和信道环境较为敏感,跨场景鲁棒性有限。

随着深度学习技术的发展,SEI逐步由手工特征驱动转向数据驱动范式,相关研究主要围绕输入表征设计与网络结构优化两个方面展开。早期工作将卷积神经网络直接用于I/Q信号建模,验证了端到端学习相较手工特征方法的性能优势^[13];随后,研究者通过差分星座轨迹图、误差信号等输入形式抑制调制内容干扰,以突出硬件指纹特征^[14-15]。在此基础上,复值卷积网络、多尺度卷积以及融合注意力机制的混合模型进一步提升了对复域关联信息、局部细粒度特征和长时序依赖的建模能力,在受控条件下取得了较好的识别效果^[16-20]。

然而,现有深度学习方法大多侧重提升特征提取能力,通常默认训练与测试样本服从相同分布,对复杂电磁环境下的载波频偏、采样时钟偏差及时间平移等扰动缺乏显式建模与自适应抑制能力。当多种扰动耦合作用时,模型容易出现特征分布偏移、类内一致性下降和识别性能退化。尽管已有研究尝试通过信道补偿^[21]、域适应^[22]等策略增强鲁棒性,但这类方法往往依赖额外估计步骤或先验假设,在复杂多扰动场景下仍存在适用性不足的问题。

针对上述问题,本文提出一种扰动感知调制卷积神经网络(Perturbation-aware modulated convolutional neural network,PAM-CNN)。该方法首先建立5类典型环境扰动的参数化建模框架,并在此基础上设计扰动分支感知模块;随后,引入卷积核自适应调制机制,使网络能够依据估计到的扰动信息动态调整特征提取算子,从而在特征学习阶段实现对扰动影响的结构化抑制;最后,构建融合设备分类、扰动检测与参数回归的多任务联合优化策略,以提升模型在复杂扰动环境下的综合识别能力。本文的主要贡献如下:

(1)建立了面向鲁棒SEI的扰动几何建模框架,将载波频偏、采样时钟偏差、增益波动、时间平移和线性调频这5类典型扰动统一表示为可参数化数学变换。

(2)设计了扰动感知分支与调制卷积层协同机制,通过联合建模扰动激活状态与参数信息,引导卷积算子进行样本自适应调整,从而增强特征表示在复杂扰动条件下的一致性。

(3)构建了多任务联合训练框架,将辐射源分类、扰动检测和参数回归纳入统一优化目标,有效提升了模型在复杂电磁环境中的鲁棒识别能力。

1 问题定义与扰动建模

在无线通信系统中,射频前端通过下变频与正交解调将发射机输出的带通信号转换为基带形式,便于数字域处理。设理想情况下的接收带通信号可表示为

$$x(t) = A(t) \cos(2\pi f_c t + \phi(t)) \quad (1)$$

式中: $A(t)$ 表示包络幅度, f_c 为载波频率, $\phi(t)$ 为相位项。经正交解调与低通滤波后,可得复基带信号

$$x_b(t) = I(t) + jQ(t) = A_b(t) e^{j\varphi(t)} \quad (2)$$

式中: $I(t)$ 与 $Q(t)$ 分别为同相与正交分量, $A_b(t)$ 与 $\varphi(t)$ 分别为对应的幅相表示。

本文以复基带 I/Q 序列为输入,利用硬件非理想引入的稳定个体差异实现辐射源识别。考虑到实际接收过程中本振失配、采样时钟偏差、增益起伏、同步误差及频率缓慢漂移等因素会导致信号特征分布偏移,本文选取载波频偏、采样时钟偏差、增益波动、时间平移和线性调频这 5 类典型扰动进行参数化建模。上述扰动分别作用于 I/Q 轨迹的相位、时间尺度、幅度、位置和非线性相位结构,能够较为全面地表征复杂接收条件下影响射频指纹稳定性的主要变化形式。下面分别给出其物理含义及数学描述。

(1) 载波频偏。载波频偏由收发端本振失配引起,该扰动会使复基带信号产生随时间累积的相位旋转,从而改变 I/Q 点云的整体几何结构,并削弱相位相关射频指纹特征的稳定性,因此需要重点建模与抑制,其数学模型可表示为

$$x_{\text{cfo}}(t) = x_b(t) e^{j2\pi\Delta f t} \quad (3)$$

式中 Δf 表示残余频率偏差,单位为 Hz。 Δf 的取值范围依据收发链路中可能存在的本振失配程度设定,在数据增强时控制在不破坏样本基本可识别性的合理区间内以模拟实际接收中常见的线性相位旋转扰动。

(2) 采样时钟偏差。采样时钟偏差由接收端采样时钟与理想时钟不一致引起,该扰动会导致采样点漂移与局部时序错位,从而增加特征对齐难度并降低类内一致性,对时序相关指纹特征影响更为显著,其数学模型可表示为

$$x_{\text{sfo}}(t) = x_b((1 + \alpha)t) \quad (4)$$

式中,相对偏差为无量纲量 α ,时间伸缩系数为 $1 + \alpha$ 。当 $\alpha > 0$ 时表示采样时间轴拉伸,当 $\alpha < 0$ 时表示时间轴压缩。 α 的取值通常设为零附近的小范围偏差,用于模拟实际系统中较常见的轻微采样失配。

(3) 增益波动。增益波动主要由发射功率变化、接收增益起伏或信道衰落引起。该扰动主要影响幅度相关特征,对信号相位结构本身不产生直接改变,在低信噪比条件下会加剧样本间差异,其数学模型为

$$x_{\text{gain}}(t) = \rho x_b(t) \quad (5)$$

式中 ρ 表示幅度缩放系数,为无量纲量。 ρ 一般围绕 1 附近波动,其取值范围依据接收链路中常见的幅度起伏情况设定,用于模拟实际场景中的增益变化。

(4) 时间平移。时间平移由同步误差、起始点截取偏差或缓存延迟引起。时间平移会改变信号在观测窗口中的位置,导致特征出现位置偏置,影响网络对局部模式的稳定提取。时间平移本身不改变信号的幅相规律,但会显著影响依赖局部位置关系的特征表示,其数学模型为

$$x_{\text{shift}}(t) = x_b(t - \tau) \quad (6)$$

式中 τ 为时间平移量,单位为 s。离散采样条件下写为 $\tau = n_0 T_s$,其中 n_0 为偏移采样点数, T_s 为采样周期。 τ 的取值范围通常按采样点级偏移设置,以反映实际接收中常见的同步偏差和窗口截取误差。

(5) 线性调频。线性调频用于描述频率随时间缓慢变化所对应的二次相位扰动。与载波频偏造成的匀速相位旋转不同,线性调频会导致 I/Q 轨迹产生非均匀旋转和形态扭曲,从而破坏依赖相位演化规律的射频指纹特征。该扰动主要作用于信号的高阶相位结构,在多扰动叠加条件下会进一步加剧特征分布偏移,其模型表示为

$$x_{\text{chirp}}(t) = x_b(t) e^{j\pi a t^2} \quad (7)$$

式中 a 为二次相位系数,控制相位弯曲强度。 a 的取值通常设为零附近的小量,用于模拟实际接收过程中缓慢频率漂移或相位畸变带来的影响。

2 扰动感知调制卷积神经网络

为应对多类型扰动叠加对 RFFI 带来的挑战,本节研究网络模型的自适应问题,提出一种端到端训练的 PAM-CNN 架构,其整体网络流程架构如图 1 所示。

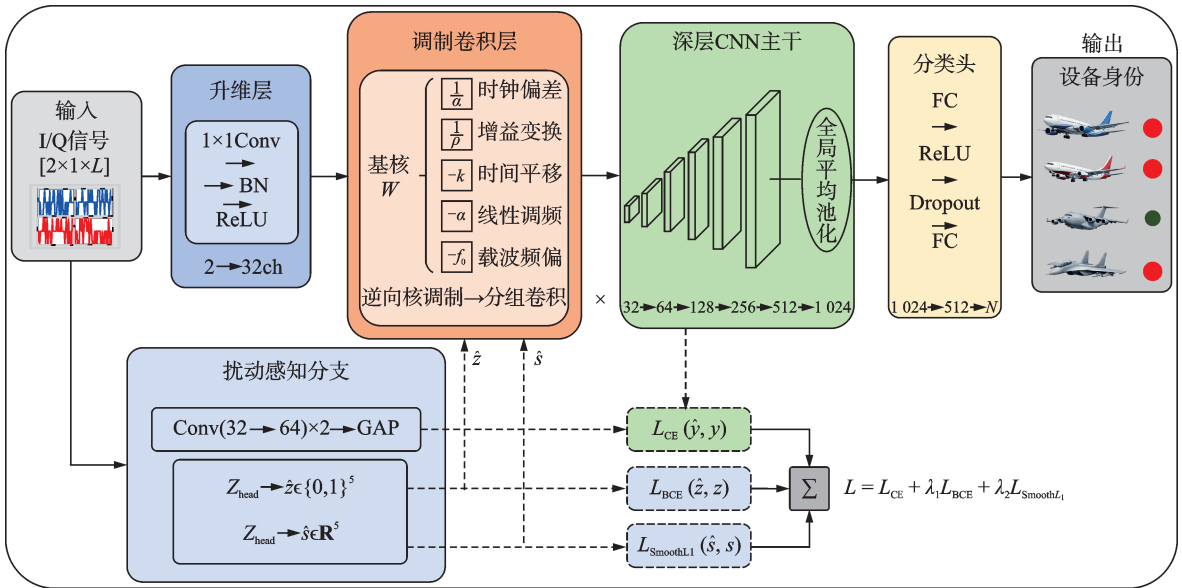


图1 整体网络流程架构图
Fig.1 Overall network architecture diagram

如图1所示,整体框架由升维层、扰动感知分支、调制卷积层、深层特征提取网络和分类头组成。输入I/Q信号首先经过升维映射,扰动感知分支根据输入信号估计扰动状态,并引导调制卷积层对卷积算子进行自适应调整;随后,深层特征提取网络进一步提取高层射频指纹特征,并完成辐射源类别识别。该框架将扰动补偿由输入端处理转化为特征提取过程中的算子自适应调制,从而增强模型在复杂环境下的识别鲁棒性。

2.1 扰动感知分支

扰动感知分支用于从输入I/Q信号中提取全局扰动表征,并输出扰动激活状态与参数估计两类结果。具体而言,输入I/Q信号首先经过升维层映射为32通道特征。升维层由一个 1×1 的二维卷积、批归一化(Batch normalization, BN)、ReLU激活函数和Dropout2d组成,其中卷积层输入通道数为2,输出通道数为32,步长为1,不使用偏置项,Dropout2d的失活概率设为0.05。该过程在保持时序长度不变的前提下,将原始I/Q双通道输入映射到更高维特征空间,为后续扰动建模提供更充分的表征基础。

在此基础上,升维后的特征送入扰动感知分支。该分支由两层串联的二维卷积构成,两层卷积的卷积核大小均为 1×3 ,填充方式均为(0,1),不使用偏置项。第一层卷积将通道数由32映射为64,第二层卷积保持64通道不变;每层卷积后均依次接入BN和ReLU激活函数。由于卷积核尺寸为 1×3 ,该分支主要沿时间维提取局部扰动模式,同时保持I/Q结构在另一维度上的一致性。为减轻过拟合,在第二层卷积后进一步引入Dropout2d,失活概率设为0.1。

经过上述卷积变换后,特征图通过自适应全局平均池化层(1,1)压缩为张量,大小为 $[B, 64, 1, 1]$,其中 B 为批大小。随后,经展平操作得到64维全局扰动表征向量。由于输入特征的空间高度为1,因此该全局平均池化实质上主要对时间维进行全局聚合,从而获得样本级的扰动统计表征。

基于全局扰动表征向量,构建两个并行预测头,扰动激活判别头 Z_{head} 和扰动参数回归头 S_{head} 得到扰动参数向量。扰动激活判别头采用“Linear(64,64)+ReLU+Dropout($p=0.2$)+Linear(64,5)”的结

构,用于输出5类扰动对应的激活判别结果 $\hat{z} \in \{0, 1\}^5$,分别对应载波频偏、采样时钟偏差、增益波动、时间平移和线性调频这5种扰动状态。扰动参数回归头采用“Linear(64, 64)+ReLU+Linear(64, 5)”的结构,用于输出5类扰动参数的预测结果 $\hat{s} \in \mathbf{R}^5$ 。为保证参数估计结果具有物理可行性,参数回归头输出后先通过tanh函数进行限幅,再映射到各扰动参数的预设取值范围。最终,扰动感知分支同时输出扰动激活结果和参数估计结果,并将其作为后续调制卷积层的显式扰动先验。

2.2 扰动感知调制卷积

为使卷积算子能够随输入样本的扰动状态自适应变化,本文引入可转向核补偿机制构造调制卷积层作为网络第一层卷积。调制卷积层建立在扰动建模与扰动感知分支输出的基础上。设基础卷积核为

$$\mathbf{W} \in \mathbf{R}^{C_{\text{out}} \times C_{\text{in}} \times 1 \times K} \quad (8)$$

式中: \mathbf{W} 为基础卷积核, C_{in} 和 C_{out} 分别表示输入通道数和输出通道数, $1 \times K$ 为卷积核尺寸, K 表示沿时序方向的卷积核长度。

可转向核补偿机制在每个样本上依据 (\hat{z}, \hat{s}) 构造样本特定的卷积核 \mathbf{W}' ,再用 \mathbf{W}' 对输入进行卷积,其本质是将扰动变换由输入端显式校正转化为卷积算子端的自适应调制,从而提高不同扰动条件下特征表示的一致性。具体而言, \hat{z} 用于判断各类扰动是否激活,起到门控选择作用; \hat{s} 用于控制相应变换的幅度。当某类扰动未被激活时,对应核变换退化为恒等映射;当其被激活时,相应的核域调制参与复合变换过程

$$\hat{s} = [\widehat{\Delta f}, \hat{\xi}, \hat{\rho}, \hat{n}_0, \hat{a}]^T \quad \hat{\xi} = 1 + \hat{a} \quad (9)$$

式中各分量分别对应载波频偏、时间伸缩系数、增益缩放系数、离散时间平移量和线性调频二次相位系数。为避免未激活扰动对卷积核产生无效修正,定义有效扰动参数为

$$\bar{p}_i = \hat{z}_i \hat{p}_i + (1 - \hat{z}_i) p_i^{(0)} \quad i = 1, 2, \dots, 5 \quad (10)$$

式中中性参数取 $[\Delta f^{(0)}, \xi^{(0)}, \rho^{(0)}, n_0^{(0)}, a^{(0)}] = [0, 1, 1, 0, 0]$ 。

在实现中,5类扰动按SCALE→CFO→CHIRP→GAIN→SHIFT的顺序依次作用于基础卷积核,因此每个样本对应的卷积核可表示为

$$\mathbf{W}' = \mathcal{T}_{\text{shift}}(\bar{n}_0) \circ \mathcal{T}_{\text{gain}}(\bar{\rho}) \circ \mathcal{T}_{\text{chirp}}(\bar{a}) \circ \mathcal{T}_{\text{cfo}}(\bar{\Delta f}) \circ \mathcal{T}_{\text{scale}}(\bar{\xi})(\mathbf{W}) \quad (11)$$

式中 $\mathcal{T}_{\text{shift}}(\bar{n}_0)$ 、 $\mathcal{T}_{\text{gain}}(\bar{\rho})$ 、 $\mathcal{T}_{\text{chirp}}(\bar{a})$ 、 $\mathcal{T}_{\text{cfo}}(\bar{\Delta f})$ 和 $\mathcal{T}_{\text{scale}}(\bar{\xi})$ 分别表示时间尺度调制、载波频偏调制、线性调频调制、增益调制和时间平移调制对应的核域变换算子。式(11)中的上画线参数表示经扰动激活门控后的有效调制参数;当对应扰动未激活时,其取中性值,使相应变换退化为恒等映射。

时间尺度调制通过两次线性插值实现,即

$$K' = \max\left(1, \text{round}\left(\frac{K}{\bar{\xi}}\right)\right) \quad (12)$$

式中: K 为原始卷积核沿时间维的长度, K' 为经插值后的中间长度, $\bar{\xi}$ 为时间尺度调制系数。即先将长度为 K 的卷积核插值到 K' ,再插值回原长度 K 。

增益调制采用乘性缩放,时间平移调制采用沿时间维的循环平移,载波频偏和线性调频调制分别采用线性相位项和二次相位项,即

$$\phi^{\text{cfo}}(n) = 2\pi \frac{\bar{\Delta f}}{f_s} n \quad (13)$$

$$\phi^{\text{chirp}}(n) = \pi \bar{a} \left(\frac{n}{f_s} \right)^2 \quad (14)$$

式中: $\phi^{\text{cfo}}(n)$ 和 $\phi^{\text{chirp}}(n)$ 分别为第 n 个离散位置处的线性相位项和二次相位项, f_s 为采样率。

得到批内样本特定卷积核后,将输入与卷积核重排,并采用分组卷积实现并行计算。可转向核补偿机制将扰动补偿由输入域转移到卷积核域,使卷积算子能够依据样本扰动状态进行自适应调整,从而提高复杂扰动条件下特征提取的一致性与鲁棒性。

经过调制卷积层后,特征进一步送入深层特征提取网络提取高层射频指纹表示,并由分类头完成辐射源类别判别。前端可转向核补偿机制负责对主要扰动进行结构化抑制,后端深层特征提取网络负责判别特征学习,二者共同提升复杂环境下的识别鲁棒性。

2.3 多任务联合损失函数

为同时优化辐射源分类性能与扰动估计能力,本文采用多任务联合学习框架。训练过程中,模型同时分别监督分类、扰动激活判别与扰动参数回归这3个学习目标。总损失函数由3部分构成,可表示为

$$L = L_{\text{CE}} + \lambda_1 L_{\text{BCE}} + \lambda_2 L_{\text{Smooth}_{L_1}} \quad (15)$$

式中, λ_1 与 λ_2 为权重系数,用于平衡不同任务对优化的贡献。

本文将设备识别作为主任务,因此分类损失在联合优化中占主导。扰动激活判别任务用于为卷积核调制提供显式先验,故赋予中等权重;参数回归任务优化难度更高,且对训练稳定性更敏感,因此采用更保守的加权方式。综合任务功能定位与训练稳定性考虑,本文取 $\lambda_1 = 0.5, \lambda_2 = 0.1$ 。

(1)辐射源分类损失。分类损失采用交叉熵形式,其计算公式为

$$L_{\text{CE}}(\hat{y}, y) = -\frac{1}{C} \sum_{c=1}^C \sum_{n=1}^N y_{c,n} \log \hat{y}_{c,n} \quad (16)$$

式中: C 为批量样本数, N 为辐射源类别数, $y_{c,n}$ 为样本真实标签, $\hat{y}_{c,n}$ 为模型预测的类别概率。

(2)扰动激活识别损失。扰动激活识别损失采用多标签二分类形式,使模型能够同时判断5类扰动是否存在,即

$$L_{\text{BCE}}(\hat{z}, z) = -\frac{1}{C} \sum_{c=1}^C \sum_{i=1}^5 [z_{c,i} \log \hat{z}_{c,i} + (1 - z_{c,i}) \log (1 - \hat{z}_{c,i})] \quad (17)$$

式中: $z_{c,i}$ 为第 c 个样本中第 i 类扰动的真实激活状态, $\hat{z}_{c,i}$ 为模型预测的激活概率。

(3)扰动参数回归损失。扰动参数回归损失仅在对对应扰动被激活时进行计算,即采用门控机制对损失进行掩码,其计算公式为

$$L_{\text{Smooth}_{L_1}}(\hat{s}, s) = \frac{1}{C} \sum_{c=1}^C \sum_{i=1}^5 \text{smooth}_{L_1}(\hat{s}_{c,i} - s_{c,i}) \quad (18)$$

式中: $\hat{s}_{c,i}$ 与 $s_{c,i}$ 分别表示第 c 个样本第 i 类扰动参数的预测值与真实值, $\text{smooth}_{L_1}(\cdot)$ 为平滑 L_1 损失函数。该损失通过平均各类扰动参数误差来约束参数回归,并在计算前按维标准化回归目标,以减小量纲差异的影响。

2.4 训练与推理策略

考虑到实际场景中扰动状态通常不可直接获取,本文采用不同形式的训练与推理流程:训练阶段联合利用辐射源标签、扰动激活标签和扰动参数标签进行多任务优化,由扰动感知分支估计扰动信息;调制卷积层完成自适应补偿;深层特征提取网络提取特征并输出分类结果;各项损失共同更新模型参数。

为减小训练与推理阶段扰动信息可得性差异带来的影响,训练中采用逐步过渡策略:前期更多使用真实扰动信息,并优先优化分类与扰动激活判别任务;后期逐步过渡到使用预测扰动信息,同时引入扰动参数回归约束,以提升训练稳定性和实际场景下的鲁棒性。在实际测试过程中,真实扰动状态未知时,模型首先估计扰动激活状态和参数,再据此驱动卷积层进行补偿,最终完成辐射源识别。

3 仿真实验结果

3.1 数据集

本文实验采用 Tu 等^[23]构建的真实空口 ADS-B 基带 I/Q 数据集。该数据集基于软件无线电平台在开放空域采集,经自动解码、CRC 校验和聚类标注,标签对应飞机 ICAO 地址。数据采集频点为 1 090 MHz,采样率 50 MHz,带宽 10 MHz,接收增益 30 dB,硬件平台由 1 090 MHz 全向天线和 SM200B SDR 组成。数据集共包含 100 个辐射源类别、72 000 个样本,每个样本为长度 4 800 的双通道 I/Q 序列,训练集、验证集和测试集按 8:1:1 划分。

由于原始数据主要采集于机场周边开阔环境,视距链路占主导,干扰和噪声较弱。为贴近实际接收场景并使扰动情况可控,本文在原始样本上离线构造增强数据:对每个样本随机叠加 3 类扰动,并在预设范围内独立采样扰动参数,随后进行均方功率匹配以保持平均功率一致,最后按目标信噪比随机加入复高斯白噪声,使增强样本的 SNR 分布于 -5 dB 和 20 dB 之间。

为在离线增强过程中构造可控且具有工程合理性的复杂扰动样本,对上述 5 类扰动分别在预设范围内采样参数,并随机叠加其中 3 类扰动以形成增强样本。参数范围的设定范围如表 1 中所示,设定原则包括:(1)扰动强度应覆盖实际接收链路中常见的轻度至中度失真;(2)扰动不能强到完全破坏样本的基本可识别性;(3)不同类型的扰动在量级上应与其物理作用方式相匹配,以保证模型学习到的扰动估计结果具有可解释性。

表 1 5 类典型扰动的取值范围

Table 1 Value ranges of five typical perturbations

扰动类别	载波频偏/kHz	采样时钟偏差	增益波动	时间平移	线性调频
参数符号	Δf	$1 + \alpha$	ρ	n_0	a
取值范围	$[-50, 50]$	$[0.95, 1.05]$	$[0.7, 1.3]$	$[0, 0.1T]$	$\left[-\frac{\Delta f_c}{T}, \frac{\Delta f_c}{T} \right]$

注: $T=L/f_s$ 表示输入序列时长,且 L 表示输入序列包含的采样点数; Δf_c 表示线性调频在序列末端对应的最大频率漂移,本文取 $\Delta f_c=20$ kHz。

3.2 性能对比

为验证本文方法的鲁棒性,选取 C2C-UNet^[24]、ResNet-LSTM^[25]和 RSBU-LSTM^[26]这 3 种典型深度学习模型作为对比方法。其中,RSBU-LSTM 代表基于残差收缩的序列建模方法,ResNet-LSTM 结合了残差网络与长短期记忆网络以捕获时序依赖,C2C-UNet 则采用编解码结构实现信号特征的层次化提取。所有模型在相同的数据划分与扰动条件下训练和测试,以确保对比的公平性。表 2 给出了各方法在不同信噪比下的识别准确率。从表 2 可以看出,总体上,本文提出的 PAM-CNN 在各 SNR 条件下均优于对比方法,且在低信噪比和多扰动叠加条件下优势更明显;而在较高信噪比下,由于 ADS-B 调解与 SEI 并非同一任务:15 dB 虽能满足报文解调,但多类扰动仍会影响细粒度射频指纹表征,使类间可分性尚未完全饱和。RSBU-LSTM 缺乏对扰动的显式建模,在低信噪比下易出现类内分散;ResNet-LSTM 的卷积算子固定,难以适应扰动导致的分布偏移;C2C-UNet 偏重通用多尺度特征提取,

表2 各方法在不同SNR下的识别准确率
Table 2 Recognition accuracy of different methods at various SNRs

方法	SNR/dB					
	-5	0	5	10	15	20
Ours	71.19	90.68	94.38	94.99	95.39	94.69
RSBU-LSTM	54.64	68.51	72.46	73.79	71.67	73.81
ResNet-LSTM	52.03	74.74	78.75	82.89	80.71	79.43
C2C-UNet	46.81	73.72	82.81	82.21	87.04	85.19

对复杂扰动补偿不足,因此易产生类间混叠和类内扩散。相比之下,本文方法通过扰动感知分支估计扰动状态,并利用调制卷积层对卷积算子进行自适应调整,从而有效抑制扰动影响,提升了复杂条件下的识别性能。

图2展示了不同模型在各SNR条件下的识别准确率热力分布,其中横轴为SNR,纵轴为模型类别,颜色越深表示准确率越高。总体来看,PAM-CNN在整个SNR范围内均表现较优,且在低SNR条件下优势更为明显。

图3(a)展示了PAM-CNN相对于ResNet-LSTM在各SNR条件下的准确率提升。可以看出,PAM-CNN在全部SNR条件下均取得正向增益,提升幅度为12.1~19.2个百分点,其中SNR=-5 dB时增益最大,说明其在低SNR条件下优势更为明显。图3(b)进一步比较了各模型在0~20 dB范围内的整体性能,其中不同颜色表示不同模型,各辐射轴表示不同SNR,半径越大表示准确率越高。可以看出,PAM-CNN的曲线整体位于最外侧且分布较均衡,表明其在各SNR条件下均保持了较好的识别性能和稳定性。

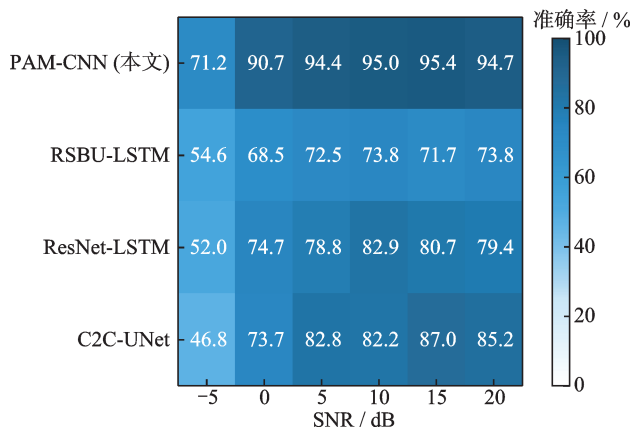




图2 不同模型在不同SNR下识别准确率的热力图
Fig.2 Heatmap of recognition accuracy of different models at various SNRs



(a) PAM-CNN相较于ResNet-LSTM的准确率提升
(a) Accuracy improvement of PAM-CNN compared to ResNet-LSTM



(b) 各方法在不同SNR下的性能雷达图
(b) Performance radar chart of different methods at various SNRs

图3 对比算法在不同SNR下性能

Fig.3 Performance of comparison algorithms at different SNRs

3.3 训练过程分析

图4展示了3种方法在SNR=15 dB条件下的训练与验证准确率曲线。从图4可以看出,相比RSBU-LSTM和ResNet-LSTM,PAM-CNN收敛更快,且在训练集和验证集上均可取得更高的最终准确率。其验证集曲线与训练集趋势基本一致,未出现明显过拟合,说明模型具有较好的收敛性与泛化能力。

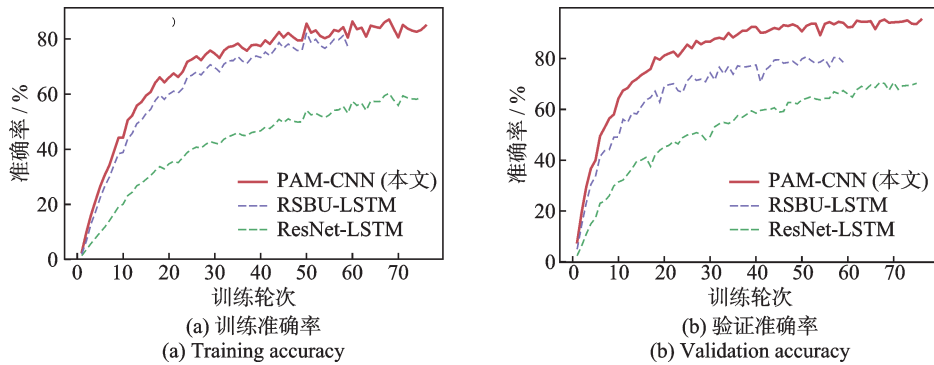


图4 在SNR=15 dB下3种模型准确率曲线

Fig.4 Accuracy curves of three models at SNR=15 dB

3.4 消融实验

为验证各模块的贡献,本文设计了以下消融配置:(1)PAM-CNN完整模型;(2)无调制模块(移除扰动感知分支后的自适应调制);(3)真实参数调制(直接将真实扰动参数作为调制信号输入)。消融实验结果如表3所示。

表3 消融实验结果

Table 3 Ablation experiment results

配置	SNR/dB					
	-5	0	5	10	15	20
Ours	71.19	90.68	94.38	94.99	95.39	94.69
无调制模块	73.11	91.06	94.64	94.17	94.46	94.53
真实参数调制	72.89	88.79	93.14	94.38	94.74	95.10

从表3可以看出,本文模型与无调制模块在低信噪比区间(-5~5 dB)性能接近,且后者在部分点上略优。这主要是因为低SNR下噪声影响占主导,调制机制的收益尚未充分体现;相比之下,无调制模块结构更简单,表现更稳定。随着SNR提升至10 dB及以上,扰动逐渐可辨,调制卷积的优势开始显现,因此完整模型取得更优性能。此外,真实参数调制仅为对照设置,并非严格意义上的性能上界;该设置直接使用真实扰动参数,而本文方法通过端到端联合训练学习更贴合识别目标的调制条件,因此其性能未优于本文方法。

3.5 特征可视化

3.5.1 多模型特征对比

图5给出了3种模型在SNR=10 dB下的t-SNE特征分布比较。从图5可以看出,PAM-CNN的类内聚集更紧凑、类间分离更明显;RSBU-LSTM存在较多类别重叠,判别能力较弱;ResNet-LSTM的分离效果有所改善,但整体仍不及PAM-CNN。该结果从特征空间角度说明了PAM-CNN的性能优势。

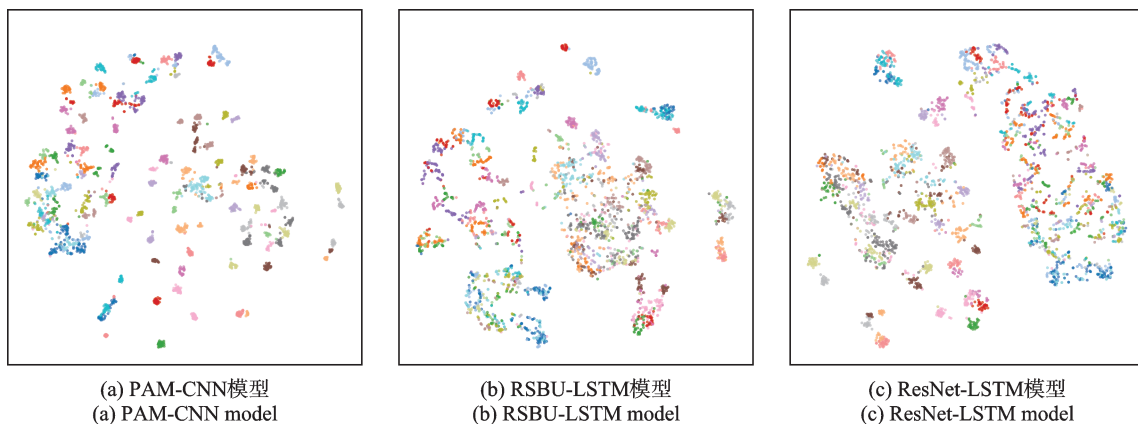


图5 3种模型在SNR=10 dB下的t-SNE特征分布

Fig.5 t-SNE feature distributions of three models at SNR=10 dB

3.5.2 不同SNR下的特征变化

图6展示了PAM-CNN在0 dB、10 dB和20 dB下的特征分布变化。从图6可以看出,随着SNR的提升,特征聚类由相对模糊逐渐转为清晰分离,类间分离度和类内紧凑性均不断增强。这表明PAM-CNN在不同噪声条件下均能提取有效判别特征,且信道条件改善后特征表示质量进一步提升。




图6 3种模型在不同SNR下的特征分布变化

Fig.6 Changes in feature distributions of three models at different SNRs

4 结束语

本文针对复杂扰动条件下SEI性能易退化的问题,提出了PAM-CNN方法。该方法通过扰动感知分支联合估计扰动状态及参数,并以此引导卷积核进行样本自适应调制,从而在特征提取阶段抑制载波频偏、采样时钟偏差、增益波动、时间平移和线性调频等扰动对射频指纹表征的影响;同时结合设备分类、扰动检测与参数回归的多任务联合训练,提升模型在复杂环境下的鲁棒识别能力。

在真实空口ADS-B基带数据及离线扰动增强数据上的实验结果表明,所提方法在全SNR范围内整体优于C2C-UNet、ResNet-LSTM和RSBU-LSTM,在15 dB条件下识别准确率达到95.39%,并在低信噪比和多扰动叠加条件下表现出较好的稳定性。训练过程、消融实验和特征可视化结果进一步说明,扰动感知分支与卷积核自适应调制机制能够有效增强特征可分性和模型鲁棒性。

本文方法并不针对 ADS-B 报文调解或协议层身份字段识别问题。对于高 SNR、同步良好且扰动较弱的 ADS-B 信号,基于脉冲结构或调解信息的常规方法可能已经具有较高识别能力。本文的研究重点在于不依赖协议层身份字段的原始 I/Q 射频指纹识别,并关注多类扰动叠加导致的指纹表征不稳定问题。同时本文方法适用于能够获取基带 I/Q 序列、协议和频段相对固定,但同时存在频偏、时钟偏差及时间失配等复杂扰动的非协作辐射源识别场景。后续工作将在现有 5 类独立扰动建模基础上,引入扰动耦合项与未知扰动表征,构建面向多扰动叠加场景的统一参数化建模与自适应补偿机制,并进一步验证其在跨场景、跨接收机条件下的泛化能力。

参考文献:

- [1] 查浩然,孙露,尚佳颖,等. 动态电磁环境中具身频谱感知技术研究[J/OL]. 通信学报: 1-14[2026-03-12]. <https://link.cnki.net/urlid/11.2102.TN.20260212.1737.022>.
ZHA Haoran, SUN Lu, SHANG Jiaying, et al. Research on embodied spectrum sensing technology in dynamic electromagnetic environments[J/OL]. *Journal on Communications*: 1-14[2026-03-12]. <https://link.cnki.net/urlid/11.2102.TN.20260212.1737.022>.
- [2] LIN Yun, ZHAO Haojun, MA Xuefei, et al. Adversarial attacks in modulation recognition with convolutional neural networks [J]. *IEEE Transactions on Reliability*, 2021, 70(1): 389-401.
- [3] 肖易寒,王博煜,于祥祯,等. 基于双路射频指纹卷积神经网络与特征融合的雷达辐射源个体识别[J]. 电子与信息学报, 2024, 46(8): 3238-3245.
XIAO Yihan, WANG Boyu, YU Xiangzhen, et al. Specific emitter identification of radar emitters based on dual-channel radio frequency fingerprint convolutional neural network and feature fusion[J]. *Journal of Electronics & Information Technology*, 2024, 46(8): 3238-3245.
- [4] HAN Yu, CHEN Xiang, WANG Manxi, et al. GP-DGECN: Geometric prior dynamic group equivariant convolutional networks for specific emitter identification[J]. *IEEE Open Journal of the Communications Society*, 2024, 5: 6802-6816.
- [5] LIN Yun, TU Ya, DOU Zheng, et al. Contour Stella image and deep learning for signal recognition in the physical layer[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2021, 7(1): 34-46.
- [6] SHAW D, KINSNER W. Multifractal modelling of radio transmitter transients for classification[C]//*Proceedings of IEEE WESCANEX 97: Communications, Power, and Computing*. Winnipeg, Canada: IEEE, 1997: 306-312.
- [7] HALL J, BARBEAU M, KRANAKIS E. Detection of transient in radio frequency fingerprinting using signal phase[C]//*Proceedings of the 3rd IASTED International Conference on Wireless and Optical Communications*. Banff, Canada: ACTA Press, 2003: 13-18.
- [8] 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.
- [9] YUAN Yingjun, HUANG Zhitao, WU Hao, et al. Specific emitter identification based on Hilbert-Huang transform-based time-frequency-energy distribution features[J]. *IET Communications*, 2014, 8(13): 2404-2412.
- [10] KLEIN R W, TEMPLE M A, MENDENHALL M J. Application of wavelet-based RF fingerprinting to enhance wireless network security[J]. *Journal of Communications and Networks*, 2009, 11(6): 544-555.
- [11] YAO Yanyan, YU Lu, CHEN Yiming. Specific emitter identification based on square integral bispectrum features[C]//*Proceedings of 2020 IEEE 20th International Conference on Communication Technology*. Nanning, China: IEEE, 2020: 1311-1314.
- [12] WU Longwen, ZHAO Yaqin, WANG Zhao, et al. Specific emitter identification using fractal features based on box-counting dimension and variance dimension[C]//*Proceedings of 2017 IEEE International Symposium on Signal Processing and Information Technology*. Bilbao, Spain: IEEE, 2018: 226-231.
- [13] DING Lida, WANG Shilian, WANG Fanggang, et al. Specific emitter identification via convolutional neural networks[J]. *IEEE Communications Letters*, 2018, 22(12): 2591-2594.

- [14] PENG Linning, ZHANG Junqing, LIU Ming, et al. Deep learning based RF fingerprint identification using differential constellation trace figure[J]. IEEE Transactions on Vehicular Technology, 2020, 69(1): 1091-1095.
- [15] 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.
- [16] WANG Yu, GUI Guan, 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.
- [17] WANG Shufei, WAN Hong, WANG Fan, et al. TFMix: A robust time-frequency mixing approach for domain generalization in specific emitter identification[J]. IEEE Transactions on Cognitive Communications and Networking, 2025, 11(6): 3981-3992.
- [18] 杨宁,王桁,张邦宁,等. 基于有向图连通性的无监督辐射源个体识别方法[J]. 数据采集与处理, 2025, 40(5): 1250-1260.
YANG Ning, WANG Heng, ZHANG Bangning, et al. Unsupervised specific emitter identification method based on directed graph connectivity[J]. Journal of Data Acquisition and Processing, 2025, 40(5): 1250-1260.
- [19] WANG Rong, ZHUANG Xu, ZHOU Weixi, et al. SepNet: Deep convolutional neural network for specific emitter identification with high accuracy[C]//Proceedings of ICASSP 2025—2025 IEEE International Conference on Acoustics, Speech and Signal Processing. Hyderabad, India: IEEE, 2025: 1-5.
- [20] ZHOU Mingsheng, KONG Mingming, TIAN Yuan, et al. Mixed CNN and transformer for specific emitter identification[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 1-10.
- [21] PAN Rui, CHEN Hui, CHEN Hongyang, et al. Equalization-assisted domain adaptation for radio frequency fingerprint identification[J]. IEEE Wireless Communications Letters, 2024, 13(7): 1868-1872.
- [22] 查浩然,刘畅,王巨震,等. 面向无人机辐射源个体识别的域适应模型设计[J]. 信号处理, 2024, 40(4): 650-660.
ZHA Haoran, LIU Chang, WANG Juzhen, et al. Design of domain adaptation model for specific emitter identification of UAVs[J]. Journal of Signal Processing, 2024, 40(4): 650-660.
- [23] TU Ya, LIN Yun, ZHA Haoran, et al. Large-scale real-world radio signal recognition with deep learning[J]. Chinese Journal of Aeronautics, 2022, 35(9): 35-48.
- [24] XIE Lingnan, PENG Linning, ZHANG Junqing, et al. Channel2Channel: Towards robust radio frequency fingerprint extraction and identification[J]. IEEE Journal on Selected Areas in Communications, 2025, 43(11): 3737-3751.
- [25] MOHAMMAD A, ASHRAF M, VALKAMA M, et al. Learning-based RF fingerprinting for device identification using amplitude-phase spectrograms[C]//Proceedings of 2023 IEEE 98th Vehicular Technology Conference. Hong Kong, China: IEEE, 2023: 1-6.
- [26] LING Haoran, ZHU Fengchao, YAO Minli. A RSBU-LSTM network for radio frequency fingerprint identification relying on multiple features[J]. EURASIP Journal on Advances in Signal Processing, 2024, 2024(1): 72.

作者简介:



赵雨露(2002-),女,硕士研究生,研究方向:特定辐射源识别,E-mail:2782684130@qq.com。



李志刚(1979-),男,副教授,硕士生导师,研究方向:宽带信号的检测、处理与识别等。



查浩然(1996-),男,博士生,研究方向:射频指纹、信号处理。



韩宇(1986-),通信作者,男,副教授,硕士生导师,研究方向:电磁环境数据挖掘与智能模型建模、电磁频谱地图生成等,E-mail:yu.han1001@hrbeu.edu.cn。



林云(1980-),男,教授,博士生导师,研究方向:智能无线电技术、人工智能和机器学习、大数据分析挖掘、软件和认知无线电、信息安全与对抗、智能信息处理。