

基于多域特征融合的通信辐射源个体识别方法

谢 军

合肥工业大学计算机与信息学院, 安徽 合肥

收稿日期: 2025年2月13日; 录用日期: 2025年3月12日; 发布日期: 2025年3月19日

摘 要

辐射源个体识别(SEI)作为一种重要的物理层认证技术,通过提取无线设备硬件固有缺陷产生的射频指纹来实现设备的唯一识别,在无线电监测领域具有广泛应用。近年来,深度学习技术的引入显著提升了辐射源个体识别的效率。然而,现有方法大多局限于单一信号域的特征提取,未能充分利用信号多域特征间的互补信息。针对这一局限性,本文提出了一种基于多域特征融合的辐射源个体识别方法(MDFF-SEI)。该方法创新性地构建了双分支神经网络架构,分别从不同信号域中提取特征,并通过设计的特征融合模块实现多域特征的有机整合,从而获得更全面的信号表征。为验证所提方法的有效性,我们在通信无线电数据集和包含LTE及可变信道条件的开源数据集上进行了实验评估,结果表明该方法在识别性能上具有显著优势。

关键词

辐射源个体识别, 融合模块, 多域特征融合

Specific Emitter Identification Method Using Multi-Domain Feature Fusion

Jun Xie

School of Computer Science and Information Engineering, Hefei University of Technology, Hefei Anhui

Received: Feb. 13th, 2025; accepted: Mar. 12th, 2025; published: Mar. 19th, 2025

Abstract

Specific Emitter Identification (SEI) represents a pivotal physical layer authentication technique in communications, which utilizes Radio Frequency Fingerprints (RFFs) stemming from intrinsic hardware imperfections to uniquely identify wireless devices, thus playing an indispensable role in radio monitoring. The advent of deep learning techniques has significantly enhanced the efficiency of SEI. Nonetheless, the majority of existing methodologies are confined to extracting features from

a single signal domain, overlooking the synergistic potential of multi-domain signal features. Addressing this gap, this paper proposes a novel Multi-Domain Feature Fusion SEI (MDFF-SEI) approach. At its core, we architect a dual-branch neural network to delve deeper into the manually extracted multi-domain signal features. Following this, we employ an Adaptive Feature Fusion Module (AFFM) to amalgamate these features, achieving a more holistic depiction of the signal characteristics. The efficacy of our proposed method is corroborated through rigorous evaluation on a dedicated communication radio dataset and an open-source real-world RFF dataset that encompasses LTE and variable channel conditions, showcasing cutting-edge recognition performance.

Keywords

Specific Emitter Identification, AFFM, MDFF-SEI

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

辐射源个体识别(Specific Emitter Identification, SEI)是一种基于信号外部特征识别辐射源的关键技术[1],在现代军事[2]、民用应用以及认知无线电[3]等领域具有广泛的应用前景。然而,随着战场电磁环境的日益复杂和辐射源数量的急剧增加,传统 SEI 算法已难以满足高精度识别的需求。近年来,深度学习技术在无线通信领域展现出巨大潜力,为提升 SEI 性能提供了新的解决方案。多种深度学习方法,如残差网络(ResNet)、度量对抗训练[4]、生成对抗网络(GAN)[5][6]、对比学习[7]和元学习[8],已在 SEI 任务中展现出显著的优势。

在 SEI 任务中,特征提取主要集中在时域和频域。针对时间序列分类设计的神经网络已被广泛应用于 SEI,以实现特征的自动提取。频域和时域特征在 SEI 中具有互补性;频域特征能够有效捕捉信号的频率信息,但对噪声和失真较为敏感;而时域特征则侧重于信号的时间响应和波形特性,需要在信号持续时间和采样频率之间进行权衡。

在基于时间序列的方法中,Chen 等人[9]提出直接将 IQ 信号输入神经网络,避免了复杂的预处理步骤。Zhu 等人[10]则引入了时序卷积网络(TCN)以专门处理 SEI 任务。此外,一种轻量化的 Transformer 架构[11]被提出,可直接从原始信号中提取射频指纹。尽管长短期记忆网络(LSTM) [12] [13]在 SEI 领域得到了广泛应用,但其对训练数据量的依赖较高,且在处理长序列时存在局限性。在基于变换域的方法中,许多研究[14]-[16]聚焦于利用时频分布(如短时傅里叶变换 STFT、Wigner-Ville 分布 WVD 和 Choi-Williams 分布 CWD)提取频域特征。然而,这些方法对神经网络设计的高度依赖性限制了其鲁棒性,且需要针对不同数据类型开发专用网络。

为解决上述问题,本文提出了一种多域特征融合的 SEI 方法。该方法采用双分支卷积神经网络架构,分别从短时傅里叶变换(STFT)中提取频域特征,并从 IQ 时域功率[17]中提取时域特征。此外,我们还设计了一个高效的特征融合模块,以实现多域特征的深度融合,从而提升识别的准确性和鲁棒性。

工作的主要贡献可归纳如下:

- 1) 针对单一信号域特征提取导致的特定辐射源识别(SEI)精度不足的问题,创新性地提出了一种基于多域特征融合的 SEI 方法,有效提升了识别准确率。
- 2) 特征提取阶段,通过引入短时傅里叶变换(STFT)和时域功率计算(ITPC)技术,分别获取辐射源的

时频谱特征和能量分布特征，并采用双分支卷积神经网络架构实现特征的并行提取。

3) 设计了一个特征融合模块，该模块不仅能够有效整合多域特征，还具备关键特征增强功能，从而显著提升了特征的表征能力。

4) 通过在通信电台数据集和开源数据集上的系统性实验验证，本方法相较于传统单一特征提取方法展现出显著的性能优势，为 SEI 领域提供了新的解决方案。

本文的结构安排如下：第 2 节详细阐述所提出的多域特征融合 SEI 方法；第 3 节展示实验结果与分析；第 4 节总结全文并展望未来研究方向。

2. 基于多域特征融合的辐射源个体识别算法

2.1. 短时傅里叶变换

STFT 是一种经典而直接的时频分析方法。STFT 既能捕捉信号的瞬时频率特性，也能捕捉这些频率随时间的变化。它是对长信号进行窗口操作，对窗口内的信号进行傅里叶变换。窗口在时间轴上移动，以逐步分析信号并形成局部频谱。

STFT 的定义为

$$X(n, w) = \sum_{m=-\infty}^{\infty} x(m)w(n-m)e^{-jwm} \quad (1)$$

$x(m)$ 、 $w(n)$ 分别表示输入信号和窗口函数， n 表示滑动窗口的长度。

2.2. 时域功率计算

假设只有一个接收器能收集到应用于 SEI 的发射器发射的无线信号。如果发射器发射的信号表示为 $s_k(t)$ ，则相应的连续时间信号可表示为

$$r_k(t) = h_k(t) * s_k(t) + n_k(t) \quad (2)$$

其中 $h_k(t)$ 表示发射器和接收器之间信道的脉冲响应，“*”表示卷积运算， $n_k(t)$ 表示高斯白噪声。

该模型通过利用发射器固有的同相(I)和正交(Q)分量不平衡特性(即 IQ 不平衡)，学习可用于识别辐射源“指纹”的独特特征。这些特征主要源于硬件非线性特性和传输过程中的各种损伤，它们都被完整地保留在接收信号中。具体而言，IQ 不平衡主要体现在相位和振幅两个维度：在振幅方面，解调过程中出现的振幅失衡会导致信号失真；在相位方面，解调后的 IQ 分量失去严格的正交性，造成信号重叠。这种 IQ 不平衡现象表明理想的正交关系在实际系统中难以完全实现，而这种固有的非理想特性恰恰为模型提供了可学习的鉴别特征基础，使其能够捕捉到不同辐射源的细微差异。

$$x(t) = x_I(t) + j x_Q(t) \quad (3)$$

$$q(t) = \cos 2\pi f_c t + j(1+u)\sin(2\pi f_c t + \alpha) \quad (4)$$

$$y(t) = \text{Real}[x(t)q(t)] = x_I(t)\cos 2\pi f_c t - x_Q(t)(1+u)\sin(2\pi f_c t + \alpha) \quad (5)$$

$$y_I(t) = \text{LPF}[y(t)\cos(2\pi f_c t)] = [x_I(t) - x_Q(t)(1+u)\sin \alpha]/2 \quad (6)$$

$$y_Q(t) = \text{LPF}[y(t)\sin(2\pi f_c t)] = -x_Q(t)(1+u)\cos \alpha/2 \quad (7)$$

$$p(t) = y_I^2(t) + y_Q^2(t) \quad (8)$$

其中 f_c 表示调制器的工作频率，参数 u 、 α 表示硬件非线性引起的振幅和相位失衡。 $x_I(t)$ 和 $x_Q(t)$ 分别

表示同相和正交分量。 $q(t)$ 表示载波信号， $x(t)$ 、 $y(t)$ 表示输入和输出信号； $y_I(t)$ 、 $y_Q(t)$ 分别表示解调后的同相信号和正交信号。假设输入信号是理想模拟信号，则 $x_I(t)$ 、 $x_Q(t)$ 分别对应于 $A\cos 2\pi f_c t$ 和 $A\sin 2\pi f_c t$ 。I信号和Q信号的波形变化是相对的，具体来说，如果I信号在 t 时刻发生变化，Q信号也会在同一时间 t 时刻发生相应的变化。I信号和Q信号的振幅和相位变化完全与参数 u 、 α 有关，表明它们之间存在一定的相关性。假定任何给定时间 t 的时域功率 $p(t)$ ，从等式(6)和(7)可以分析出，在理想条件下， $p(t)$ 的值保持恒定 A^2 ；然而，当存在I/Q失配时， $p(t)$ 的值将随参数 u 、 α 的变化而变化。因此 $p(t)$ 的波形与参数 u 、 α 有关，这种变化是唯一的，是识别通信辐射源的特征。

2.3. 网络框架

多域特征融合 SEI 方法的网络结构如图 1 所示。我们利用短时傅里叶变换和 IQ 时域功率计算来获取频域和时域分量。对辐射源信号进行 STFT 和 ITPC 的公式为

$$X_{\text{STFT}}^{(i)} = \text{STFT}(x^{(i)}) \quad (9)$$

$$X_{\text{ITPC}}^{(i)} = \text{ITPC}(x^{(i)}) \quad (10)$$




Figure 1. Multi-domain feature fusion SEI

图 1. 多域特征融合 SEI 框架

1) 特征提取模块：本模块采用卷积神经网络(CNN)与全连接层(FC)相结合的架构，旨在从 I/Q 信号中挖掘深层次的隐含特征。在 MDFF-SEI 方法中，该模块创新性地采用了双分支并行结构，分别负责不同信号域的特征提取任务。具体而言，我们设计了一个双分支卷积神经网络，其中一个分支专注于提取辐射源的频域特征，另一个分支则致力于捕获时域特征，通过这种并行的特征提取机制，确保能够全面而有效地获取辐射源的多维度特征信息。

2) 融合模块：由于不同特征域的信息具有异构性，无法直接用于分类器的决策过程。为此，我们创新性地设计了特征融合模块，以实现多域特征的有机整合。作为 MDFF-SEI 方法的核心，该模块通过融合机制将来自不同域的射频指纹(RFF)特征进行深度融合，生成具有更强判别性的融合 RFF 特征。如图 2 所示，该模块采用注意力机制等策略，使模型能够自适应地聚焦于辐射源的关键鉴别特征，从而提升特征的代表能力和分类性能。

3) 识别模块：在识别模块中，融合特征被输入分类器。然后得到最终的辐射源类型。融合特征定义为

$$X_{\text{fused}} = w * f(X_{\text{STFT}}^{(i)}) + (1-w) * f(X_{\text{ITPC}}^{(i)}) \quad (11)$$

$$w = \text{Relu}\left\{\bigcup\left[f\left(X_{\text{STFT}}^{(i)}\right)+f\left(X_{\text{ITPC}}^{(i)}\right)\right]*\cap\left[f\left(X_{\text{STFT}}^{(i)}\right)+f\left(X_{\text{ITPC}}^{(i)}\right)\right]\right\} \quad (12)$$

其中， Relu 是激活函数， $\cup$ 和 $\cap$ 分别表示图 2 的两个通道。




Figure 2. Fusion module
图 2. 融合模块

3. 实验测试与结果分析

3.1. 实验参数与数据处理

在我们的实验中，网络是在 Python 3.7 的 Pytorch 中构建的，并在 NVIDIA GeForce GTX 3070 GPU 上使用 Adam 优化器[18]进行训练。损失函数为交叉熵。STFT 选择的窗口是汉明窗口，窗口长度设为 128，重叠长度设为 80。其他配置参数详见表 1。实验在两个数据集上进行。

Table 1. Algorithm configuration
表 1. 算法配置

训练集	测试集	学习率	样本长度	Batchsize	Epoch
800	200	1e-3	2048	64	100

1) 通信无线电台数据集：通信无线电台数据集是我们利用短波和超短波通信无线电台从四种不同信道类型(室内直射、室内绕射、室外直射和室外绕射)采集数据的数据集。我们采用了室外绕射采集环境，使用单个接收器采集三个超短波通信电台在不同载波频率下发射的信号，载波频率分别为 310 MHz、350 MHz 和 420 MHz，带宽为 160 KHz。接收器的采样频率为 200 Ksps。此外，室外绕射采集环境设置如下：接收器位于体育场看台建筑前方，发射器位于同一建筑的另一侧，距离接收器约 100 米，由于看台建筑的阻挡，发射器和接收器之间没有直接的视线路径，绕射路径沿线有多棵树木。

2) 考虑到 LTE 和可变信道的真实 RFF 数据集：我们在[19]提供的公开数据集上进行了实验，以证明我们的方法的优越性。数据集由两部分组成：发射端数据和接收端数据。在接收端数据中，存储了与发射器相对应的数据。每个信道环境中使用五个发射器。每次发射和接收持续 4 小时，收集 400 个样本。

每个样本的长度为 28,796。使用 10 个不同的 XSRP 存储 10 次发送和接收后，存储的数据将合并为一个数据集。

3.2. 实验结果分析

一般来说，SEI 可以如下表述。 $W_t = \{(x_1, y_1), (x_2, y_2), (x_3, y_3), \dots, (x_N, y_N)\}$ 为一组训练数据，其中 x_i 表示第 i 个辐射源样本， y_i 表示第 i 个辐射源的标签。算法包括以下几个部分：信号处理、特征提取、特征融合和分类。

首先，将信号划分为固定长度。然后，使用 STFT 和 ITPC 处理固定长度的信号。然后对模型进行训练，从信号的不同域中提取特征，并将这些特征融合后输入分类器进行分类。

我们通过大量实验评估了所提方法的性能效率，并证明了它在解决 SEI 挑战方面的卓越表现。我们在两个数据集上进行了对比实验。数据集随机分为 80% 的训练集和 20% 的测试集。我们的方法在时域和频域都实现了优势互补。

表 2 显示了各种方法在开源数据集上识别不同数量辐射源的识别率。

表 3 中，我们证明了在使用不同载波频率的通信电台数据集的实验中，我们的方法比单一域的识别方法获得了更高的识别率。

我们认为，数据集本身的属性会对模型性能产生影响。我们通过实验分析了输入样本长度对识别准确率的影响。表 4 显示了模型的识别性能随样本长度的变化而变化。

CNN-*：我们选择了 MDFF-SEI 中的一个分支，并删除了融合模块作为基准，命名为 CNN。CNN 的输入来自 STFT 和 ITPC 输出的特征，即 CNN-STFT 和 CNN-ITPC。

Table 2. The recognition accuracy of different numbers of emitters on the Dataset Provided in [19]

表 2. 在[19]提供的数据集识别不同数量辐射源的准确率

方法/类别数	4	6	8	10
MDFF-SEI	0.975	0.963	0.959	0.943
CNN-STFT	0.883	0.902	0.939	0.912
CNN-ITPC	0.875	0.845	0.812	0.791

Table 3. The recognition accuracy of different carrier of emitters on the Communications Radio Dataset

表 3. 在通信无线电台数据集上识别不同载波辐射源的准确率

方法/载波	260MHz	310MHz	350MHz	420 MHz
MDFF-SEI	0.893	0.873	0.909	0.830
CNN-STFT	0.777	0.773	0.777	0.637
CNN-ITPC	0.693	0.887	0.813	0.363

Table 4. The recognition accuracy of different sample length of emitters on the Dataset Provided in [19]

表 4. 在[19]提供的数据集识别不同样本长度辐射源的准确率

方法/样本长度	1024	2048	3072
MDFF-SEI	0.945	0.943	0.969
CNN-STFT	0.879	0.912	0.924
CNN-ITPC	0.693	0.791	0.729

4. 结束语

在本文中,我们提出了一种多域特征融合 SEI 方法。通过对所采集的短波通信进行 STFT 和 ITPC,提取辐射源不同域的特征。两个数据集的实验结果表明,我们提出的方法比单一特征的方法有着更高的识别准确率。

基金项目

这项工作部分得到了国家自然科学基金的资助,基金项目号:62071479。

参考文献

- [1] Polak, A.C. and Goeckel, D.L. (2015) Identification of Wireless Devices of Users Who Actively Fake Their RF Fingerprints with Artificial Data Distortion. *IEEE Transactions on Wireless Communications*, **14**, 5889-5899. <https://doi.org/10.1109/twc.2015.2443794>
- [2] Guo, S., Akhtar, S. and Mella, A. (2021) A Method for Radar Model Identification Using Time-Domain Transient Signals. *IEEE Transactions on Aerospace and Electronic Systems*, **57**, 3132-3149. <https://doi.org/10.1109/taes.2021.3074129>
- [3] Dobre, O. (2015) Signal Identification for Emerging Intelligent Radios: Classical Problems and New Challenges. *IEEE Instrumentation & Measurement Magazine*, **18**, 11-18. <https://doi.org/10.1109/mim.2015.7066677>
- [4] Gong, J., Xu, X. and Lei, Y. (2020) Unsupervised Specific Emitter Identification Method Using Radio-Frequency Fingerprint Embedded Infogan. *IEEE Transactions on Information Forensics and Security*, **15**, 2898-2913. <https://doi.org/10.1109/tifs.2020.2978620>
- [5] Gong, J., Xu, X., Qin, Y. and Dong, W. (2019) A Generative Adversarial Network Based Framework for Specific Emitter Characterization and Identification. 2019 11th International Conference on Wireless Communications and Signal Processing (WCSP), Xi'an, 23-25 October 2019, 1-6. <https://doi.org/10.1109/wcsp.2019.8927888>
- [6] Wu, Z., Wang, F. and He, B. (2023) Specific Emitter Identification via Contrastive Learning. *IEEE Communications Letters*, **27**, 1160-1164. <https://doi.org/10.1109/lcomm.2023.3247900>
- [7] Yang, N., Zhang, B., Ding, G., Wei, Y., Wei, G., Wang, J., et al. (2022) Specific Emitter Identification with Limited Samples: A Model-Agnostic Meta-Learning Approach. *IEEE Communications Letters*, **26**, 345-349. <https://doi.org/10.1109/lcomm.2021.3110775>
- [8] Wang, X., Zhao, J., Yang, T. and Xu, F. (2022) Specific Emitter Identification Based on Multi-Input Convolutional Neural Network. 2022 IEEE/CIC International Conference on Communications in China (ICCC), Sanshui, 11-13 August 2022, 412-416. <https://doi.org/10.1109/iccc55456.2022.9880738>
- [9] Zha, X., Chen, H., Li, T., Qiu, Z. and Feng, Y. (2022) Specific Emitter Identification Based on Complex Fourier Neural Network. *IEEE Communications Letters*, **26**, 592-596. <https://doi.org/10.1109/lcomm.2021.3135378>
- [10] Wong, L.J., Headley, W.C. and Michaels, A.J. (2019) Specific Emitter Identification Using Convolutional Neural Network-Based IQ Imbalance Estimators. *IEEE Access*, **7**, 33544-33555. <https://doi.org/10.1109/access.2019.2903444>
- [11] Danev, B., Zanetti, D. and Capkun, S. (2012) On Physical-Layer Identification of Wireless Devices. *ACM Computing Surveys*, **45**, 1-29. <https://doi.org/10.1145/2379776.2379782>
- [12] Peng, L., Hu, A., Zhang, J., Jiang, Y., Yu, J. and Yan, Y. (2019) Design of a Hybrid RF Fingerprint Extraction and Device Classification Scheme. *IEEE Internet of Things Journal*, **6**, 349-360. <https://doi.org/10.1109/jiot.2018.2838071>
- [13] Chen, Y., Zhu, L., Yu, L. and Yao, Y. (2020) Individual Identification of Communication Radiation Sources Based on Inception and LSTM Network. *Journal of Physics: Conference Series*, **1682**, Article 012052. <https://doi.org/10.1088/1742-6596/1682/1/012052>
- [14] Zhu, C., Liu, L. and Peng, X. (2023) Specific Emitter Identification Based on Temporal Convolutional Network Sequence Processing. *IEEE Communications Letters*, **27**, 2667-2671. <https://doi.org/10.1109/lcomm.2023.3312390>
- [15] Rajendran, S., Meert, W., Giustiniano, D., Lenders, V. and Pollin, S. (2018) Deep Learning Models for Wireless Signal Classification with Distributed Low-Cost Spectrum Sensors. *IEEE Transactions on Cognitive Communications and Networking*, **4**, 433-445. <https://doi.org/10.1109/tccn.2018.2835460>
- [16] Wang, X., Huang, G., Zhou, Z. and Gao, J. (2017) Radar Emitter Recognition Based on the Short Time Fourier Transform and Convolutional Neural Networks. 2017 10th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), Shanghai, 14-16 October 2017, 1-5. <https://doi.org/10.1109/cisp-bmei.2017.8302111>

-
- [17] Chen, T., Jin, W. and Chen, Z. (2009) Feature Extraction Using Wavelet Transform for Radar Emitter Signals. 2009 *WRI International Conference on Communications and Mobile Computing*, Kunming, 6-8 January 2009, 414-418. <https://doi.org/10.1109/cmc.2009.202>
 - [18] Kingma, D.P. and Ba, J. (2014) Adam: A Method for Stochastic Optimization. <http://arxiv.org/abs/1412.6980>
 - [19] Zhang, S., Zhang, Y., Zhang, X., Peng, Y., Sun, J., Gui, G., *et al.* (2023) Radio Frequency Signal Dataset Generation Based on LTE System and Variable Channels. *IEEE INFOCOM 2023-IEEE Conference on Computer Communications Workshops*, Hoboken, 20 May 2023, 1-5. <https://doi.org/10.1109/infocomworkshps57453.2023.10225784>