

引用格式: 王颖舒, 张娟娟, 袁舒, 等. 基于无监督特征提取的辐射源识别 [J]. 电子科技大学学报, 2025, 54(4): 501-506.
WANG Y S, ZHANG J J, YUAN S, et al. Specific emitter identification based on unsupervised feature extraction[J]. Journal of University of Electronic Science and Technology of China, 2025, 54(4): 501-506.



基于无监督特征提取的辐射源识别

王颖舒¹, 张娟娟¹, 袁舒¹, 任未知¹, 熊文汇², 雷霞^{2*}

(1. 贵州电网有限责任公司 贵阳供电局, 贵阳 550004; 2. 电子科技大学 通信抗干扰全国重点实验室, 成都 611731)

摘要: 发射机模拟元器件的非完美特性会导致射频信号的失真, 这些失真可以作为特定辐射源识别 (SEI) 的指纹特征用于辐射源识别。SEI 特征通常基于失真模型的方法或基于机器学习的方法提取。该文将这两种方法联合起来进行辐射源的特征提取。将专业知识 (即失真模型) 集成到神经网络中, 提出了一种级联网络的模式来提取辐射源的同相-正交不平衡和相位噪声模型参数, 既保证了特征的可解释性, 又提高了识别精度。数字仿真结果表明, 该方法在特征提取性能上优于传统单纯基于失真模型和机器学习的方法。

关键词: 无监督特征提取; 特定发射器识别; 同相-正交不平衡; 相位噪声

中图分类号: TN918

文献标志码: A

DOI: 10.12178/1001-0548.2024111

Specific emitter identification based on unsupervised feature extraction

WANG Yingshu¹, ZHANG Juanjuan¹, YUAN Shu¹, REN Weizhi¹, XIONG Wenhui², and LEI Xia^{2*}

(1. Guiyang Power Supply Bureau, Guizhou Power Grid Co., Ltd., Guiyang 550004, China;

2. National Key Laboratory of Wireless Communications, University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract: Imperfections in the analog components of emitters cause distortions in the transmitted signals. These distortions serve as unique fingerprints for the purpose of specific emitter identification (SEI). Features for SEI are typically extracted using either a distortion-models based method or a machine learning based method. In this study, these two methods for feature extraction from emitters are investigated. Incorporating specialist knowledge, the distortion model, into the neural network, a cascade network mode is proposed to extract the parameters in-phase/quadrature imbalance and phase noise models of the emitter, which not only ensures the interpretability of the extracted features and enhance identification accuracy. Simulation results demonstrate that this scheme outperforms both the conventional distortion-models-based and the machine learning-based methods in terms of feature extraction performance.

Key words: unsupervised feature extraction; specific emitter identification (SEI); in-phase/quadrature imbalance; phase noise

特定辐射源识别 (specific emitter identification, SEI) 是一种基于射频指纹 (radio frequency fingerprints, RFFs) 识别目标发射器的技术。其最早于 20 世纪 60 年代中期被提出, 目前仍是军用和民用领域的研究热点, 如雷达识别和无线安全等^[1-2]。

典型的 SEI 处理通常包括信号的前期预处理、关键特征提取以及最终的分类处理, 其中, 特征提

取是其最关键的部分, 决定了 SEI 系统的性能。为了识别不同的发射器, 需要精确提取与信息无关的硬件相关特征。这些特征会反映在传输信号的失真上, 并难以被篡改或伪造。

经典的特征提取方法采用基于失真模型来提取特征。文献 [2] 通过频率误差和 I/Q 不平衡 (I/Q imbalance) 来识别不同的发射器。文献 [3] 则讨论

收稿日期: 2024-05-14

基金项目: 国家级基金项目 (G022023KP01602); 南方电网科技创新基金项目 (GZKJXM20220026)

作者简介: 王颖舒, 高级工程师, 主要从事面向电网的宽带无线通信技术方面的研究。

*通信作者 E-mail: leixia@uestc.edu.cn

了仅采用 I/Q 不平衡参数作为 RFFs 的性能指标。文献 [4] 论证了利用相位噪声来识别发射器的可行性。文献 [5] 采取了一种新的面向射频损伤的统计模型, 新模型中的射频损伤不再受到单一参数分布变化的影响, 从而解决了针对某个特殊参数的泛化难题。这些基于失真模型的方法不需要训练数据进行特征提取, 但需要全面而精确地研究发射机的畸变机理, 并仔细处理畸变因素之间耦合的影响。

另一类提取特征的方法是基于机器学习 (machine learning, ML) 的方法。基于 ML 的方法不是对发射器硬件的物理特性进行建模, 而是通过大量数据来学习发射器的特征。文献 [6] 将雷达波形转换成时频图像, 采用卷积神经网络 (convolutional neural networks, CNN) 学习其特征。文献 [7] 使用信息最大化生成对抗网络 (information generative adversarial networks, InfoGANs) 和射频指纹嵌入来提取发射器的特征。文献 [8] 构建了深度残差网络, 从希尔伯特谱图中学习特征。这些基于 ML 的方法以牺牲训练数据量和特征的可解释性为代价, 在不需要先验知识的情况下获得了良好的识别性能。文献 [9] 在时域、频域、小波域等多域变换后的信号中提取多信号的特征并完成识别。文献 [10] 提出了一种通过傅里叶变换、注意力机制和逆傅里叶重建信号的高频分量, 并利用循环神经网络提取高频分量中蕴含的射频指纹。文献 [11] 提出了一种基于离散小波变换的射频频谱指纹提取方法, 并采用复值生成对抗网络应对信号中包含的多普勒频移。

这些基于 ML 的方法直接从数据入手提取辐射源的射频指纹, 由于没有使用已有的畸变模型, 故需要大量数据以支持训练, 导致运算复杂度高。本文提出一种用于 SEI 的无监督特征提取方案。将畸变模型的先验知识与 CNN 的数据表征能力相结合, 以提高特征提取的准确性。

1 射频信号失真模型

1.1 I/Q 不平衡模型

对于理想的正交调制器, 同相 (in-phase, I) 分量和正交 (quadrature, Q) 分量具有相同的幅度和正交相位。然而, 在实践中, 硬件缺陷将导致发射机遭受本振 (local oscillator, LO) 失配的影响, 被称为 I/Q 不平衡。

假设基带等效离散发射信号为 $x(n) = x_I(n) + jx_Q(n)$, 则 I/Q 不平衡可以表示为:

$$\begin{cases} x_I(n) = s_I(n)(1 + \varepsilon)\cos\varphi + s_Q(n)(1 - \varepsilon)\sin\varphi \\ x_Q(n) = s_I(n)(1 + \varepsilon)\sin\varphi + s_Q(n)(1 - \varepsilon)\cos\varphi \end{cases} \quad (1)$$

式中, $s_I(n)$ 和 $s_Q(n)$ 分别为符号的 I 和 Q 分量; ε 和 φ 为 I/Q 不平衡模型的增益和相位参数。


1.2 相位噪声模型

为获得稳定的频率信号, 发射机多采用锁相环 (phase-locked loops, PLL) 技术利用参考信号合成稳定频率。参考信号由自由振荡器产生, 其相位噪声可以建模为 Wiener 过程^[12]。


对于整个 PLL 工作带宽, 输出相位 $\theta(n)$ 主要受压控振荡器相位噪声的影响。因此可以用一阶自回归移动平均过程对其建模, 不失一般性, 假设 $\theta(n)$ 初始值为 $\theta(n) = 0$, 可以用参数 a 为基于 PLL 的频率合成器的相位噪声建模, 其表达式为:

$$\theta(n) = a\theta(n-1) + (1-a)\delta(n) \quad (2)$$

图 1 为信噪比 (signal to noise ratio, SNR) 为 20 dB 时, I/Q 不平衡和相位噪声对星座图的影响。从图 1 可以观察到, I/Q 不平衡使发射符号的幅度和相位产生变化, 相位噪声使星座图旋转。不同失真条件下的发射器所产生的信号具有不同特性。



a. 只有 I/Q 不平衡



b. 只有相位噪声失真

图 1 不同失真条件下的 QPSK 信号星座图

2 SEI 无监督特征提取算法

本文所提方案框架如图2所示, 它由同步和解调的预处理模块、特征提取模块和联合分类识别模块构成。

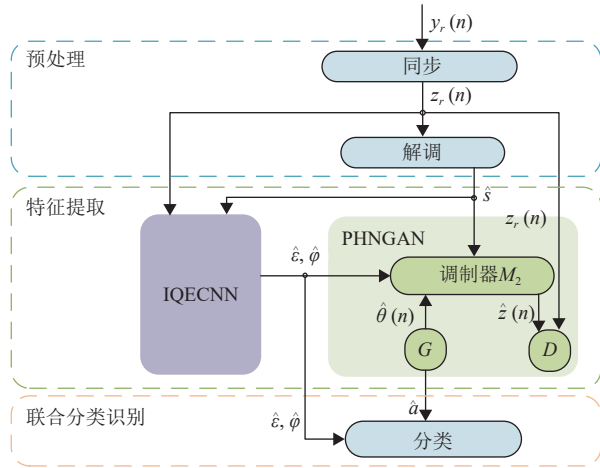


图2 算法模型框架

信号预处理：完成接收信号 $y_r[n]$ 的频率/时间同步, 以得到纠正了频偏/时偏的离散信号, 并通过解调模块实现对传输信息符号 $\hat{s}(n)$ 的盲恢复。

特征提取：由于 I/Q 不平衡和相位噪声具有不同的畸变模型, 本文采用 I/Q 不平衡估计卷积神经网络 (I/Q imbalance estimation convolutional neural networks, IQECNN) 和相位噪声生成对抗网络 (phase noise generative adversarial networks, PHNGAN) 两个子网络共同提取 I/Q 不平衡和相位噪声的模型参数。首先, 利用 IQECNN 网络从频率/时间同步后的信号 $z_r(n)$ 中提取 I/Q 不平衡模型参数 ε 、 φ ; 随后, 将提取的参数 ε 、 φ 与解调模块输出的符号 $\hat{s}(n)$ 输入到相位噪声提取网络 PHNGAN 中进行相位噪声模型参数 a 的提取; 最后, 将 IQECNN 提取的 I/Q 不平衡参数 ε 、 φ 与 PHNGAN 提取的相位噪声参数 a 联立可得到该辐射源的特征向量。

分类识别：运用 CNN 对特征提取模块所提取的向量进行分类识别。

2.1 基于卷积神经网络的 I/Q 不平衡估计

现有许多基于 ML 的特征提取方法都具有优异的性能。如文献 [13] 利用模态分解的方法取得了 85% 的总体识别准确率和较低的计算成本。然而, 该方法所提取的特征无法与发射机的器件特性对应, 因此没有明确的物理意义。与该方法类似, 大多数 ML 方法提取的特征都不具备可解释性^[14-15]。目前, 大多数基于 ML 方法提取特征主要采用已知数据标签的监督学习方式, 但在实践中, 尤其是非合作场景下, 数据标签难以获取。

为解决特征标签有限和特征可解释的问题, 本文设计的 IQECNN 引入广义调制器实现非监督的 I/Q 不平衡参数提取, 如图3所示, IQECNN 结构如图4所示。首先, 通过 CNN 提取接收样本的 I/Q 不平衡参数 ε 、 φ ; 提取的 I/Q 不平衡参数、解调信号 $\hat{s}(n)$ 和给定的调制模型被送入广义调制器 M_1 。式(1)包含 I/Q 不平衡特性的“假” I/Q 样本 $\hat{z}_{fake}(n)$, 通过最小化广义调制器 M_1 生成的“假” I/Q 样本波形 $\hat{z}_{fake}(n)$ 与接收到的真实样本 $z_r(n)$ 之间的最小均方误差实现对 IQECNN 的训练。该网络的误差函数为:

$$\text{loss}_{\text{IQECNN}} = \sum_n (z_r(n) - \hat{z}_{fake}(n))^2 \quad (3)$$

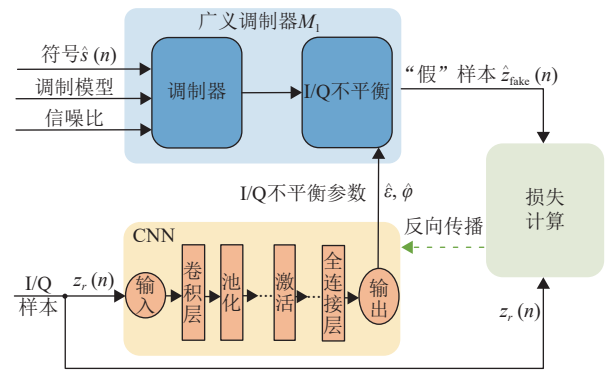


图3 IQECNN 训练模型




图4 IQECNN 结构

通过反向传播, IQECNN 的权值根据前一次迭代的损失进行微调。当损失足够小时, 认为 CNN

的输出足够准确, 结束训练。在广义调制器 M_1 的帮助下, 通过无监督学习方法, 能够在不知道真

实 I/Q 不平衡参数的情况下, 有效提取出 I/Q 不平衡的相关参数。

本文提出 IQECNN 模型中的 CNN 采用了 4 个二维卷积层和 2 个全连接层的结构, 如图 4 所示。在最后一个卷积层之后加入最大池化层, 每个隐藏层都以 leaky-ReLU 作为激活函数。

2.2 基于生成对抗网络的相位噪声参数提取

本文提出的 PHNGAN 将相位噪声失真模型融合到 GAN 中来估计模型的参数。PHNGAN 框图如图 5 所示, 算法采用广义调制器 M_2 产生包含相位噪声的“假” I/Q 采样。鉴别器 D 试图区分接收到的 I/Q 样本 $z_r(n)$ 与“假”样本 $\hat{z}_{\text{fake-PHN}}(n)$ 。受当前相位噪声序列值影响过去值的启发, 生成器 G 采用了类似于递归神经网络 (recurrent neural networks, RNN) 的结构。生成器 G 采用高斯噪声 $e(n)$ 作为输入, 利用式 (2) 所示的相位噪声模型产生一个“假”相位噪声序列 $\hat{\theta}(n)$ 。广义调制器 M_2 使用来自 IQECNN 的 $\hat{\varepsilon}$ 、 $\hat{\varphi}$ 和解调符号 $\hat{s}(n)$ 及生成器产生的相位信号 $\hat{\theta}(n)$, 如式 (4) 所示的“假” I/Q 样本 $\hat{z}_{\text{fake-PHN}}(n)$:

$$\hat{z}_{\text{fake-PHN}}(n) = [(\cos \hat{\varphi} + j \hat{\varepsilon} \sin \hat{\varphi}) \hat{s}(n) + (\hat{\varepsilon} \cos \hat{\varphi} + j \sin \hat{\varphi}) \hat{s}(n)] \exp(j \hat{\theta}(n)) \quad (4)$$

当 GAN 收敛时, 即 $\hat{z}_{\text{fake-PHN}}(n)$ 与 $z_r(n)$ 具有相似的分佈, 此时 G 能够生成与相位噪声具有相同分佈的随机样本。 G 的参数随输入数据的不同而变化。因此, GAN 收敛时, G 生成噪声的模型参数值可以作为相位噪声模型参数的估计。

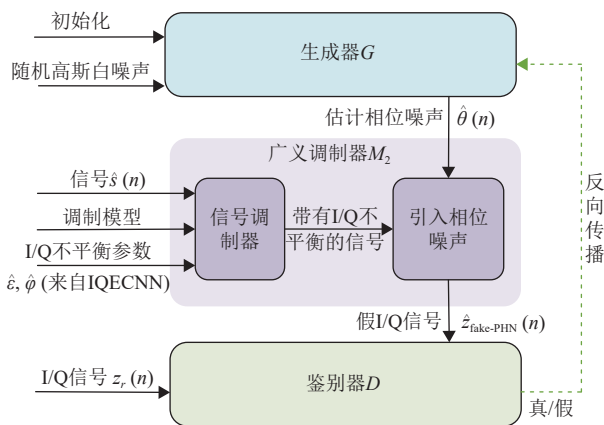


图 5 PHNGAN 框图

PHNGAN 的网络结构如图 6 所示。PHNGAN 的鉴别器 D 由 2 个卷积层 (2-Dimension, 2-D)、2 个全连接层和 sigmoid 分类器组成。每个隐藏层都有一个 leaky-ReLU 激活函数。

D 和 G 的损失函数分别定义为:

$$d_g = \mathcal{L}(D(\hat{z}_{\text{fake}}(n)), L_{\text{real}})$$

$$d_D = \mathcal{L}(D(\hat{z}_{\text{fake}}(n)), L_{\text{fake}}) + \mathcal{L}(D(z_r(n)), L_{\text{real}}) \quad (5)$$

式中, L_{fake} 、 L_{real} 代表学习率; $\mathcal{L}(x, y)$ 为二元交叉熵 (binary cross entropy, BCE), \mathcal{L} 表示为:

$$\mathcal{L}(x, y) = y \log(x) + (1 - y) \log(1 - x) \quad (6)$$

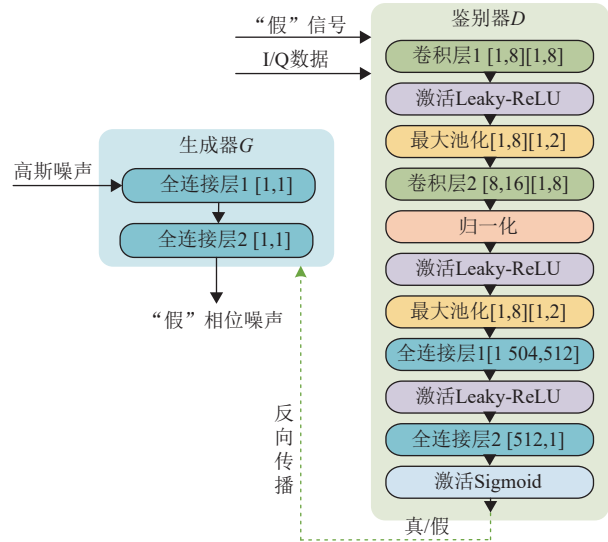


图 6 PHNGAN 网络结构

2.3 分类

在提取发射器特征后, 使用 2 层全连接层作为分类器对发射器进行识别。为了完成分类任务, 使用交叉熵作为该分类器的损失函数。

3 数值仿真结果及分析

3.1 信号生成和训练设置

本文以 QPSK 作为调制来证明所提方案的有效性。本文方案可以推广到其他正交调制。为了产生信号样本 $z_r(n)$, 本研究对随机比特调制后, 用滚降系数 0.35、过采样比为 8 的成型滤波器进行脉冲成型。采用文献 [15] 的参数对 5 个辐射源畸变进行了模拟, 其值如表 1 所示。

表 1 仿真参数

发射器序号	ε	$\varphi/(^\circ)$	α
1	0.05	0.5	0.993 8
2	0.10	1.0	0.975 6
3	0.15	1.5	0.926 8
4	0.20	2.0	0.903 4
5	0.25	2.5	0.956 5

网络的输入大小决定了在每次迭代中训练网络所涉及的样本点数量。图 7 显示了本文提出的网络输出归一化均方误差 (normalized mean square error, NMSE) 与输入样本数 (网络宽度) 的关

系。可以发现 IQECNN 的性能随着输入大小的增加而提高。但当输入大小增加到一定程度后, 性能增益不再明显。因此, 本文选择 300 个符号作为输入样本数。




图 7 网络输入大小对 IQECNN 性能的影响 (SNR=5 dB)

为了训练网络, 使用如表 2 所示的训练参数设置。由于 IQ 不平衡参数是离线训练的, 而相位噪声是在线提取的, 将两个网络串联连接, 即先将信号输入到预训练的 IQECNN 中, 然后将信号和 IQECNN 的输出 $\hat{\epsilon}$, $\hat{\varphi}$ 级联作为 PHNGAN 的输入。

表 2 训练参数

模型	训练次数	学习率	优化器	损失函数参数
IQECNN	4 000	$L_r = 2$ (每经过 1 000 次训练 $L_r \times 0.5$)	0.993 8	—
PHNGAN	2 000	$G : L_r = 0.000\ 95$ $D : L_r = 0.004\ 50$	0.975 6	$L_{fake} = 0.000\ 1$ $L_{real} = 0.999\ 9$

3.2 特征提取性能

将所提特征提取方案与文献 [3] (方法 1, 基于监督 CNN 的方法) 和文献 [15] (方法 2, 基于信号空间的方法) 进行比较。为了说明所提方案在该问题上的耦合效应和改进, 本文分两种情况讨论了 IQECNN 的性能。情形 1: 辐射源特征主要受到 I/Q 不平衡的影响; 情形 2: 辐射源特征同时受到相位噪声和 I/Q 不平衡的畸变。

具体来说, 如图 8 所示, 在所有方法中, 情形 1 的 NMSE 都低于情形 2, 说明相位噪声影响了 IQECNN 的性能。然而, 本文方案在两种不同情境下均使 NMSE 的最小化降低, 这充分显示了 IQECNN 对于相位噪声干扰的稳健性。当信噪比较高时, 方法 2 的 NMSE 较为优秀, 但当信噪比降低时, 方法 2 的性能会迅速下降。

图 9 对比了相位不平衡参数 φ 的估计性能, 如图所示, 方法 2 对 φ 提取的性能较差。在情形 1 和情形 2 中, PHNGAN 的 NMSE 均具有最优的性能。在相同数据量条件下, 图 10 比较了 PHNGAN

方案和基于奇异值分解最小二乘法 (singular value decomposition-least squares, SVD-TLS) 的方案^[16]。如图 10 所示, 在不同信噪比下, PHNGAN 方案的 NMSE 均低于 0.12%, 而当信噪比小于 15 dB 时, SVD-TLS 方案的 NMSE 大于 1%。由此可见, 如果发送信号受到 I/Q 不平衡的影响, 则会严重降低 SVD-TLS 方案的性能。按照本文给出的仿真条件, 在图 8 和图 9 中显示 I/Q 不平衡提取性能。可以看出, 对于所有方法, 情形 2 的 NMSE 都比情形 1 的 NMSE 差, 但本文方案的性能下降最小, 这意味着所提方案对相位噪声具有鲁棒性。

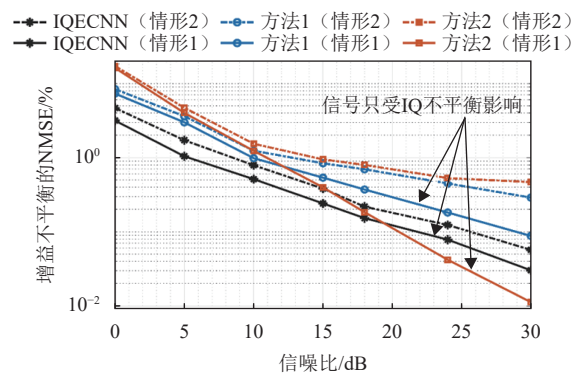


图 8 IQ 增益不平衡参数的 NMSE




图 9 IQ 相位不平衡参数的 NMSE

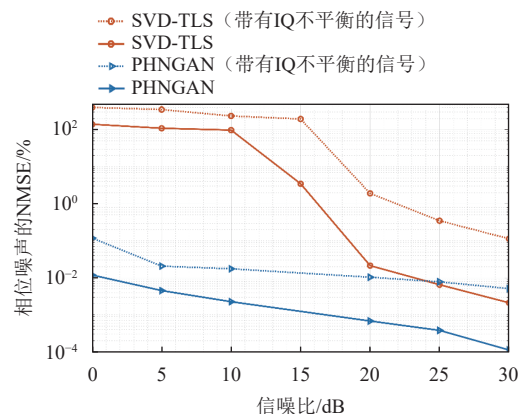


图 10 PHNGAN 的 NMSE

最后, 本文使用方法 1 和方法 2 提取的特征来测试发射器识别的分类性能。通过相同的 2 层分类器对 3 种不同方案提取的特征进行区分。分类性能如图 11 所示。结果表明, 本文方案性能最好, 其次是方法 1 和方法 2, 信噪比在 5~26 dB 之间。对于所有信噪比, 本文所提出的基于 IQECNN 和 PHNGAN 的方案分类准确率为 95%, 当信噪比小于 10 dB 时, 方法 1 和方法 2 的分类准确率均低于 93%。

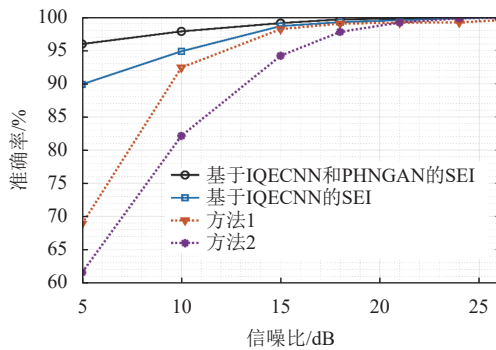


图 11 分类准确率

4 结束语

本文提出了一种基于 CNN 和 GAN 的 SEI 无监督特征提取方案。该方案的基本思想是将失真模型作为构建网络的先验知识, 充分发挥了基于失真模型和基于机器学习的特征提取方案的优势。本文方案在保证特征物理意义的同时, 提高了 SEI 的精度。最后, 通过数字仿真验证了本方案的有效性, IQECNN 显著提高了相位不平衡参数的提取性能, 且对畸变耦合的影响具有更强的鲁棒性。

参考文献

- [1] DUDCZYK J, KAWALEC A, OWCZAREK R. An application of iterated function system attractor for specific radar source identification[C]//MIKON 2008-17th International Conference on Microwaves, Radar and Wireless Communications. Wroclaw: IEEE, 2008: 1-4.
- [2] 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.
- [3] URETEN O, SERINKEN N. Wireless security through RF fingerprinting[J]. Canadian Journal of Electrical and Computer Engineering, 2007, 32(1): 27-33.
- [4] 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.
- [5] RUBINO R. Wireless device identification from a phase noise perspective[D]. Padova: University of Padova, 2010.
- [6] RAJENDRAN S, SUN Z. RF impairment model-based IoT physical-layer identification for enhanced domain generalization[J]. IEEE Transactions on Information Forensics and Security, 2022, 17: 1285-1299.
- [7] DING L, WANG S, WANG F, et al. Specific emitter identification via convolutional neural networks[J]. IEEE Communications Letters, 2018, 22(12): 2591-2594.
- [8] GONG J, XU X, LEI Y. Unsupervised specific emitter identification method using radio-frequency fingerprint embedded InfoGAN[J]. IEEE Transactions on Information Forensics and Security, 2020, 15: 2898-2913.
- [9] ZHAO S, WANG W, ZENG D, et al. A novel aggregated multipath extreme gradient boosting approach for radar emitter classification[J]. IEEE Transactions on Industrial Electronics, 2022, 69(1): 703-712.
- [10] LIAO Y, LI H, CAO Y, LIU Z, et al. Fast fourier transform with multihead attention for specific emitter identification[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-12.
- [11] ZENG M, GAO X, YANG H. RFF template design: Adaptively decreasing both doppler shifts and noise for complex-valued signals[J]. IEEE Transactions on Cognitive Communications and Networking, 2024, 10(6): 2149-2163.
- [12] PAN Y, YANG S, PENG H, et al. Specific emitter identification based on deep residual networks[J]. IEEE Access, 2019, 7: 54425-54434.
- [13] VANNICOLA V, VARSHNEY P. Spectral dispersion of modulated signals due to oscillator phase instability: White and random walk phase model[J]. IEEE Transactions on Communications, 1983, 31(7): 886-895.
- [14] TAMURA H, YANAGISAWA K, SHIRANE A, et al. Wireless devices identification with light-weight convolutional neural network operating on quadrant IQ transition image[C]//2020 18th IEEE International New Circuits and Systems Conference (NEWCAS). Montred: IEEE, 2020: 106-109.
- [15] WANG X, HUANG G, MA C, et al. Convolutional neural network applied to specific emitter identification based on pulse waveform images[J]. IET Radar, Sonar & Navigation, 2020, 14(5): 728-735.
- [16] WANG P, WANG J, WANG G. Specific emitter identification method based on I/Q imbalance with SNR estimation using wavelet denoising[C]//2021 IEEE 21st International Conference on Communication Technology (ICCT). Tianjin: IEEE, 2021: 1057-1062.

编辑 刘飞阳