

DOI:10.19651/j.cnki.emt.2416469

融合双注意力的小样本辐射源个体识别网络^{*}

刘佳乐¹ 郭志涛^{1,2} 王宏¹ 张森¹

(1. 河北工业大学电子信息工程学院 天津 300130; 2. 河北工业大学创新研究院(石家庄) 石家庄 050299)

摘要: 特定辐射源识别在军事和民用领域中发挥着越来越重要的作用。随着深度学习技术的飞速发展,SEI方法的识别性能得到了显著提升。然而这些方法往往依赖于大量的辐射源样本数据,在样本数量有限的实际应用场景中表现不佳。针对这一问题,本研究提出了一种新颖的深度学习网络模型CRCPA-GCN用于实现小样本场景下的SEI。该模型在多层复数卷积神经网络中融合了CPCA和GCNet注意力模块,采用类重建和对抗训练的方法显著提升了小样本场景下的识别性能。本研究在公开数据集上进行了一系列实验验证,并与当前主流的SEI网络模型进行了比较。实验结果表明,在20 shot的学习条件下,所提出的CRCPA-GCN网络模型达到了95.81%的准确率,优于其他主流SEI网络,并且在鲁棒性方面表现出色。

关键词: 特定辐射源识别;小样本学习;注意力模块;类重建;对抗训练

中图分类号: TN975;TN92 **文献标识码:** A **国家标准学科分类代码:** 510.4010

Small sample radiation source individual recognition network with dual attention fusion

Liu Jiale¹ Guo Zhitao^{1,2} Wang Hong¹ Zhang Sen¹

(1. College of Electronic Information Engineering, Hebei University of Technology, Tianjin 300130, China;

2. Innovation Research Institute, Hebei University of Technology (Shijiazhuang), Shijiazhuang 050299, China)

Abstract: Specific emitter identification is playing an increasingly important role in the military and civilian sectors. With the rapid development of deep learning technology, the recognition performance of SEI method has been significantly improved. However, these methods often rely on a large number of radiation source sample data, and perform poorly in practical application scenarios with limited sample size. To solve this problem, this study proposes a novel deep learning network model CRCPA-GCN to achieve SEI in small-sample scenarios. The model integrates CPCA and GCNet attention modules in a multi-layer complex convolutional neural network, and the recognition performance in small-shot scenarios is significantly improved by using the methods of class reconstruction and adversarial training. In this study, a series of experiments were carried out on public datasets and compared with the current mainstream SEI networks. Experimental results show that the proposed CRCPA-GCN network model achieves an accuracy of 95.81% under the learning condition of 20 shot, which is better than other mainstream SEI networks and performs well in robustness.

Keywords: specific emitter identification; small-sample scenarios; attention modules; class reconstruction; adversarial training

0 引言

随着5G技术的快速发展和物联网技术的日益成熟,正步入一个“万物互联”的时代,这一时代给人类带来便利的同时,也带了新的安全挑战。辐射源数量和种类的不断增加,对特定辐射源识别(specific emitter identification, SEI)技术提出了更为复杂的场景要求和更高的技术目

标^[1]。SEI技术通过辐射源固有的特征进行身份验证,其固有特征被称为射频指纹特征,包括但不限于信号的调制方式、功率谱密度以及硬件的非理想特性等。研究辐射源信号的深层特征分布以及如何构建高效的分类模型成为亟待解决的问题^[2]。

早期的SEI技术依赖于传统的信号处理,如利用傅里叶变换和频谱分析来提取和比较信号的特征^[3]。随着深度

收稿日期:2024-07-19

*基金项目:河北工业大学创新研究院(石家庄)石家庄市科技合作专项基金(SJZZXB23005)项目资助

学习的不断发展,具备强大特征学习和提取能力的深度学习技术成为各个领域的研究热点,卷积神经网络(convolutional neural network,CNN)是目前应用最广泛的特征提取网络,该网络的有效性已经在多个领域得到了验证。曾浩南等^[4]将基于卷积神经网络的辐射源识别方法与自适应信道均衡技术相结合,解决了神经网络易受信道指纹干扰的问题,并对 6 个无线路由器识别准确率达到了 96%以上。唐震等^[5]提出了一种基于深度残差收缩网络的辐射源个体识别方法,对 20 类 ADS-B 辐射源的总体识别率达到了 98.2%。

在射频信号处理领域,信号通常以复数形式的 IQ 数据表示,其中实部和虚部分别对应信号的幅度和相位信息。传统的卷积神经网络无法直接处理复数信号,通常需要通过预处理将复数信号转换为实数形式,再进行特征提取和分类。然而,这种转换过程忽略了 I 路和 Q 路数据之间的相关性,无法充分捕捉复数信号的内在特征,从而可能导致对信号特征提取的准确性和完整性不足。复数卷积神经网络^[6](complex-valued convolutional neural network,CVCNN)则是一种能够同时处理信号的实部和虚部的神经网络结构。通过复数卷积操作,CVCNN 可以保留信号的完整信息,包括幅度和相位,从而使其在捕捉信号路径之间的相关性时更加全面。

尽管 CVCNN 已经在复数信号处理方面展现出较强的优势,但其仍存在一些不足,尤其容易忽略一些细微但关键的特征。此外,由于 CVCNN 需要处理复数运算,这使得网络架构设计和参数调优比传统实值网络更加复杂,优化难度更大。针对这些问题,Tao 等^[7]通过引入端到端稀疏特征选择框架,在 CVCNN 的全连接层中加入稀疏参数,减少了冗余特征和模型参数,提高了模型在资源受限环境下的特征提取效率和性能。Yao 等^[8]引入非对称掩码自编码器,利用掩码机制在自监督训练过程中增强了 CVCNN 的特征提取能力,并结合迁移学习技术,有效提升了模型在小样本场景下的泛化性能,取得了较为理想的识别效果。复数卷积神经网络在小样本的 SEI 领域具有巨大的潜力,但在实际复杂的通信环境中仍然面临着诸多挑战,如信号干扰、噪声以及多径效应,也对 SEI 网络的准确性和鲁棒性提出了更高的要求。

为了应对辐射源小样本学习场景下 SEI 技术面临的挑战,本研究提出了一种新颖的 SEI 网络模型 CRCPA-GCN(class-reconstruction channel prior convolutional attention global contextual network),该模型将 CPCPA 注意力模块^[9]和 GCNet 注意力模块^[10]融合到复数卷积神经网络中,目的是增强模型对辐射源信号的特征提取和信号重构能力。CPCA 注意力模块能够动态调整通道特征的权重,突出关键特征;而 GCNet 注意力模块则有助于捕捉和整合全局信息,提升了模型在复杂信号环境中应对复杂环境变化的能力。此外,该网络模型结合类重构和对抗训练的方法,

显著提升了小样本学习条件下的 SEI 性能,本研究的主要贡献包括以下几点:

- 1) 提出了一种新颖的 SEI 网络模型 CRCPA-GCN,该模型在复数卷积神经网络中融合了 CPCPA 和 GCNet 注意力模块,能够有效的处理小样本 SEI 学习问题。
- 2) 通过结合类重建和对抗训练的方法,生成与原始数据同一类别的样本,无需辅助数据集的支持,提高了模型的鲁棒性。
- 3) 在公开的数据集上验证了该模型的有效性,与主流 SEI 网络模型相比取得了更好的识别性能和鲁棒性。

1 CRCPA-GCN 模型架构

1.1 模型总体架构及训练流程

本研究提出的 CRCPA-GCN 模型用于在小样本辐射源数据场景下的识别和分类,该模型在复数卷积神经网络中融合了 CPCPA 和 GCNet 注意力模块,采用类重建和对抗训练的方法来增强小样本学习场景下的 SEI 性能。该模型如图 1 所示,模型整体由 CPCPA-CVCNN 特征提取网络、GCNet-CVCNN 数据重构网络、对抗样本生成网络以及分类器组成。

在训练过程中,输入样本 X (包括信号的实部和虚部)先通过对抗样本生成网络生成对抗样本 X_A ,将 X 和 X_A 输入到 CPCPA-CVCNN 特征提取网络,得到对抗样本和原始样本的特征 Z_A 和 Z_B ,然后将这些特征通过两个不同的路径进行处理,即识别分类路径和数据重构路径。

识别分类路径是将 Z_A 和 Z_B 输入到分类器网络中得到输出 Y_A 和 Y_B , Y_A 和 Y_B 分别表示原始样本 X 和对抗样本 X_A 的预测类别的概率, Y 表示每个输入样本对应的真实类别标签。通过交叉熵损失函数计算得到相应的分类损失 Lce ,定义如下:

$$Lce = -E(Y \log Y_A) - E(Y \log Y_B) \quad (1)$$

数据重构路径是将特征表示 Z_A 和 Z_B 输入到 GCNet-CVCNN 数据重构网络中,其目标是生成 \bar{X} ,即输入数据的类别中心,生成数据表示为 X_{A1} 和 X_{B1} ,并且在训练过程中不断更新类别中心。通过均方误差损失函数进行数据重构损失的计算,有助于模型更好地学习到每个类别的代表性特征,进而可以更好进行信号重构。数据重构损失 Lre 定义如下:

$$Lre = -E(\|\bar{X} - X_{A1}\|_2^2) + E(\|\bar{X} - X_{B1}\|_2^2) \quad (2)$$

最终分类损失和数据重构损失通过不同的权重相加,然后进行反向传播,更新模型的参数。该网络模型的总损失 $Ladd$ 定义如下:

$$Ladd = \alpha Lce + \beta Lre \quad (3)$$

其中, α 和 β 为分类损失和数据重构损失的权重,用于平衡两种损失对模型训练的影响。

1.2 对抗样本生成网络

对抗训练是一种通过在训练过程中引入对抗性样本来

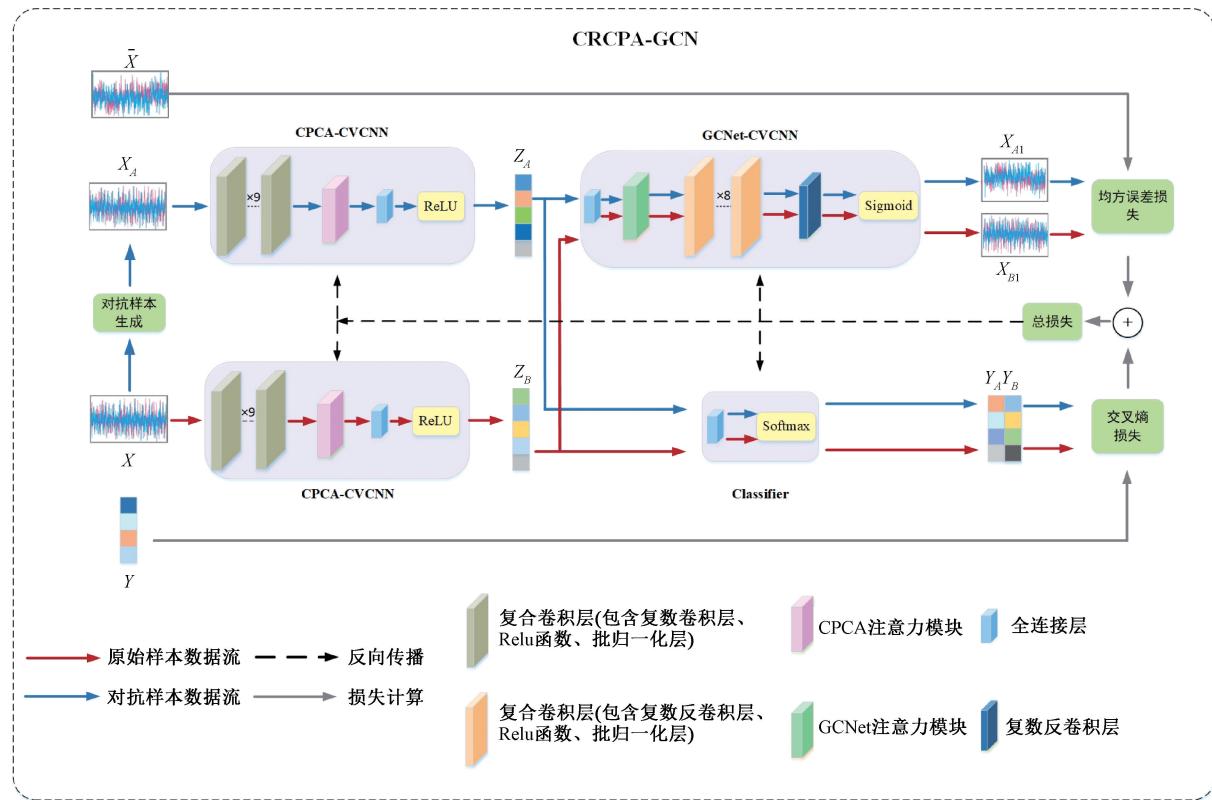


图 1 CRCPA-GCN 网络模型结构图

Fig. 1 CRCPA-GCN Network model structure diagram

增强神经网络鲁棒性的方法^[11], 对抗性样本是指在原始信号数据上添加精心设计的微小扰动 r_a , 这些扰动对于人类来说可能难以察觉, 但却能够误导模型做出错误的预测。在对抗训练中, 模型会尝试最大化对抗损失, 即让模型在对抗性样本上的预测与真实标签之间的差异最大化, 即:

$$r_a = \operatorname{argmax} L(f(x + r; \theta), y) \quad (4)$$

由于模型的非线性和梯度的不稳定性, 通常很难获得 r_a 的确定值。为解决该问题, 本研究借鉴了虚拟对抗训练(VAT)的思想^[12], 使扰动的方向遵循梯度的方向来近似计算对抗性扰动。该扰动可以近似为:

$$r_a \approx \epsilon \frac{m}{\| m \|_2}, m = \nabla r L[f(x + n; \theta), y] \quad (5)$$

式中: ϵ 是扰动大小的限制, n 是加性高斯白噪声, θ 是模型的参数。

类似旋转、翻转、加噪声等可以看作数据驱动的增强, 而该对抗性生成网络可以看作模型驱动的增强。图 2 所示为该模型的对抗样本生成网络, 对抗训练的核心思想是让模型在训练过程中不断面对这些对抗性扰动, 从而学会适应并抵抗这些扰动。这样, 即使在实际应用中遇到类似扰动, 模型也能够保持较高的识别性能。

1.3 CPCCA-CVCNN 特征提取网络及分类器

CPCCA-CVCNN 特征提取网络是 CRCPA-GCN 模型的前端部分, 如图 3 所示, 该网络负责从输入的复数辐射源信

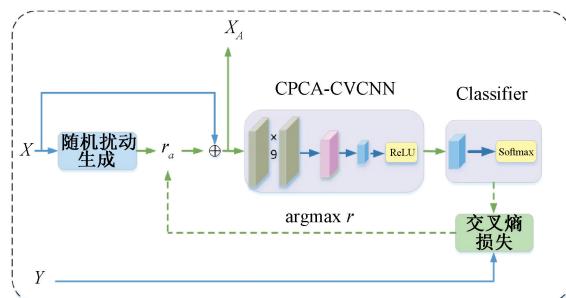


图 2 对抗样本生成网络结构

Fig. 2 Adversarial sample generation network structure

号中提取出关键特征。该网络由 9 层复合卷积层、CPCA 注意力模块、全连接层以及 ReLU 激活函数构成。传统的 CNN 没有充分利用 IQ 信号路径之间的相关信息, 复数卷积能够同时处理信号的实部和虚部, 可以充分获得 IQ 信号路径之间的相关信息, 为后续的信号重构和分类任务提供支持。该网络引入了 CPCCA 注意力模块, 能够增强网络对辐射源信号中关键特征的识别和提取性能, 提升模型的特征表征能力。此外, CRCPA-GCN 模型的分类器通过一个全连接层和 Softmax 激活函数将该网络提取的 1 024 维特征向量映射为每个辐射源的概率分布, 进而实现 SEI 的分类。

为了有效地识别和提取辐射源信号的关键特征, 本研究引入了 CPCCA 注意力模块, 该模块是对 SENet 注意力模

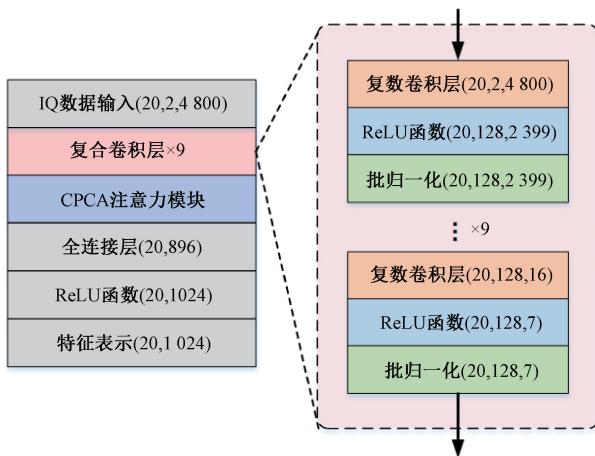


图 3 CPC-A-CVCNN 特征提取网络结构图

Fig. 3 CPC-A-CVCNN feature extraction network structure diagram

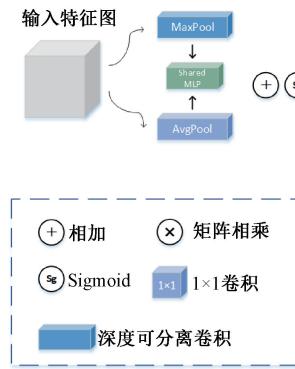
块^[13]和 CBAM 注意力模块^[14]的进一步改进。其中 SENet

图 4 CPC-A 注意力模块示意图

Fig. 4 CPC-A attention module diagram

CPCA 注意力模块通过其创新的通道和空间注意力机制以及深度可分离卷积的高效特征提取能力,给 SEI 领域提供了一种强大的特征提取方法。该模块为 CRCPA-GCN 模型的识别分类和数据重构任务提供了更好的特征表示,使得模型能够在复杂的信号环境中实现更精确的识别和更可靠的数据重构。

1.4 GCNet-CVCNN 数据重构网络

GCNet-CVCNN 数据重构网络是 CRCPA-GCN 模型的关键组成部分,负责将特征提取网络提取的特征转换回同类的原始信号表示,这一过程有助于模型学习到更加鲁棒的特征表示。如图 5 所示,该网络采用了一系列复数反卷积层、ReLU 激活函数以及批归一化层来逐步重建信号。在每个复数反卷积层后,使用 ReLU 激活函数来引入非线性,有助于模型学习复杂的信号特征。批归一化层用于归一化信号的特征,有助于加速模型的训练过程,并提高模型对输入变化的稳定性。此外,在复合卷积层之前引入了 GCNet 注意力模块,这些网络的融合实现了从特征表示到

注意力模块未考虑到空间信息,因此会导致特征图丢失部分细节特征。CBAM 注意力模块虽然结合了通道注意力和空间注意力,但其在所有的特征通道上执行同样的空间注意力权重,导致空间注意力权重不能基于每个特征通道进行动态调整。CPCA 注意力模块实现了在通道和空间维度上动态分配注意力权重,自适应地调整权重的大小,从而可以更加有效地提取辐射源信号的特征。

CPCA 注意力模块如图 4 所示,其中通道注意力部分通过全局平均池化(global average pooling, GAP)和全局最大池化(global max pooling, GMP)获取通道的信息,然后通过共享多层感知器和 Sigmoid 激活函数来计算每个通道的权重。空间注意力通过不同尺寸的深度可分离卷积块来捕获不同尺度的空间特征,然后在空间卷积的基础上,通过 1×1 卷积进一步细化特征,实现特征的通道混合。最后将通道注意力和空间注意力的权重应用到原始特征上,实现特征的加权和重构。

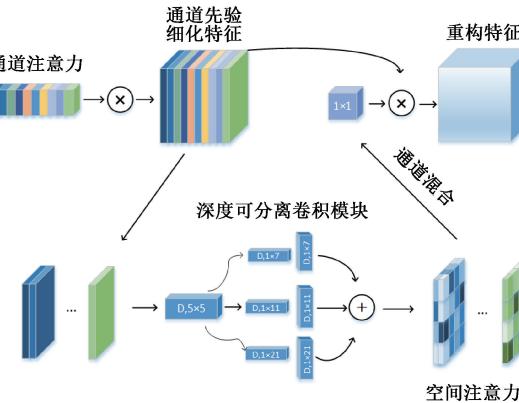


图 5 GCNet-CVCNN 数据重构网络结构图

Fig. 5 GCNet-CVCNN data reconstruction network

structure diagram

重构数据的转换。

捉信号的整体特征;另一部分是通道权重变换模块,它以较小的参数计算量对通道特征进行精细调整,允许模型动态调整不同通道的特征权重,优化了信号的局部细节。这种设计充分利用了全局上下文建模的强大特征提取能力和通道权重变换的计算效率。

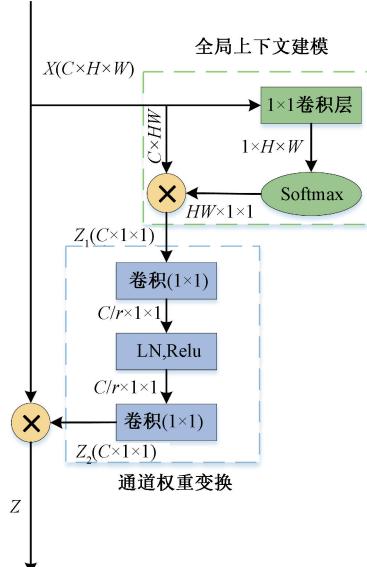


图 6 GCNet 注意力模块示意图

Fig. 6 GCNet Attention module diagram

作为数据重构网络的关键组成部分,GCNet 注意力模块通过整合全局上下文信息,提升了信号重构的质量,与复数反卷积共同实现了从局部到全局特征的有效合。这种整合不仅优化了重构信号的细节和准确性,还加深了模型对信号整体结构的理解,提升了模型对复杂信号环境的适应性,在数据重构网络中发挥着重要的作用。

2 实验设计与结果分析

2.1 数据集介绍

本研究采用由美国东北大学收集的 WIFI 数据集进行训练和测试^[15],该数据集从 16 个 USRP X310 发射机的无线传输中进行信号收集,发射机和发射机之间的距离为 182.88 cm,发射机和接收机之间的距离为 1 889.76 cm。该数据集的详细信息如表 1 所示。

表 1 数据集相关信息

Table 1 Data set related information

参数	相关内容
标准	IEEE 802.11a
维度	2×4 800
中心频率	2.45 GHz
采样速率	5 Mbps
发射机	16 USRP X310
接收机	1 USRP B210

2.2 评价指标

识别准确度(accuracy, ACC)用于度量模型在分类任务中的性能。它表示被正确分类的样本数量占总样本数量的比例。在辐射源个体识别任务中,识别准确度反映了模型准确地将辐射源分配到其正确的类别中的能力,ACC 越高表示模型对辐射源的分类准确率越高。

轮廓系数(silhouette coefficient,SC)被用来衡量数据聚类的质量。轮廓系数是一种衡量数据聚类效果的指标,它结合了聚类的凝聚度和分离度。对于每个样本,轮廓系数定义为其与同一类内其他样本的平均距离(凝聚度)与最近的其他类的样本的平均距离(分离度)之间的差异,取值范围为[-1,1],SC 越接近 1 表示样本聚类得越好,越接近 -1 表示样本更可能被分配到错误的类别中。轮廓系数计算公式如下:

$$S(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (6)$$

其中, $a(i)$ 代表样本点内聚度, 计算公式如下

$$a(i) = \frac{1}{n-1} \sum_{j \neq i}^n distance(i, j) \quad (7)$$

其中, j 代表与样本 i 在同一个类内的其他样本点, $distance$ 代表了 i 与 j 的距离。

综合使用轮廓系数和识别准确度可以更全面地评估模型的性能,深入理解其在聚类和分类任务上的表现,为模型选择、参数调整和性能优化提供依据。

2.3 实验环境及参数配置

本研究所有实验均在 NVIDIA GeForce RTX 3080 GPU 上的 PyTorch 环境下进行。为验证 CRCPA-GCN 模型在小样本场景下的识别性能,本研究使用上述 WIFI 数据集中收集的 16 类 WIFI 辐射源作为数据集。此外,为模拟小样本学习的场景,本研究在每类中随机抽取 3、5、10、15、20 个数据进行训练,训练集和验证集的比例为 7:3。在 SEI 的小样本的学习中,测试数据应远多于训练数据^[16],所以本研究在每类训练和验证数据之外随机抽取了 200 个数据进行测试,得到相应的测试结果来评价该模型的性能。为了保证结果的可靠性,排除样本随机性对实验结果的影响,本研究所得出的识别准确率为 50 次随机选取测试数据的平均值。

本研究中 CRCPA-GCN 网络模型的训练参数设置如下:迭代次数为 300 次($T=300$),批处理大小为 20($B=20$),学习率为 0.001($lr=0.001$),损失函数的加权系数 α 和 β 分别设置为 0.125 和 1.875,并选择 Adam 作为该模型的优化器。

2.4 对比实验

1) 识别精度及特征可视化

为了验证 CRCPA-GCN 模型的性能,本研究介绍了以下五种方法用于和 CRCPA-GCN 进行比较,即 CVCNN^[6],Mixup^[17],SSRCNN^[18],RFIDNet^[19] 和 DRCN-AT^[20]。以上这些方法涵盖了当前辐射源识别领域中的几

种重要技术路线,如复数卷积网络结构、数据增强以及半监督与自监督学习等主流 SEI 方法。它们在小样本辐射源学习任务中表现突出,具有较高的代表性和参考价值。

考虑到公平性,在不改变这些方法的核心思想的情况下,本研究使用相同的训练样本、测试样本、优化器、学习

率进行公平的对比实验。如表 2 所示,该表展示了不同模型在小样本学习场景下的识别准确率,由该表可知,相较于其他 5 个对比实验,CRCPA-GCN 模型在所有小样本学习场景下均展现出了最高的识别准确率,表明其在小样本学习条件下具有显著的优势。

表 2 主流辐射源个体识别网络性能对比

Table 2 Comparison of individual recognition network performance of mainstream radiation sources

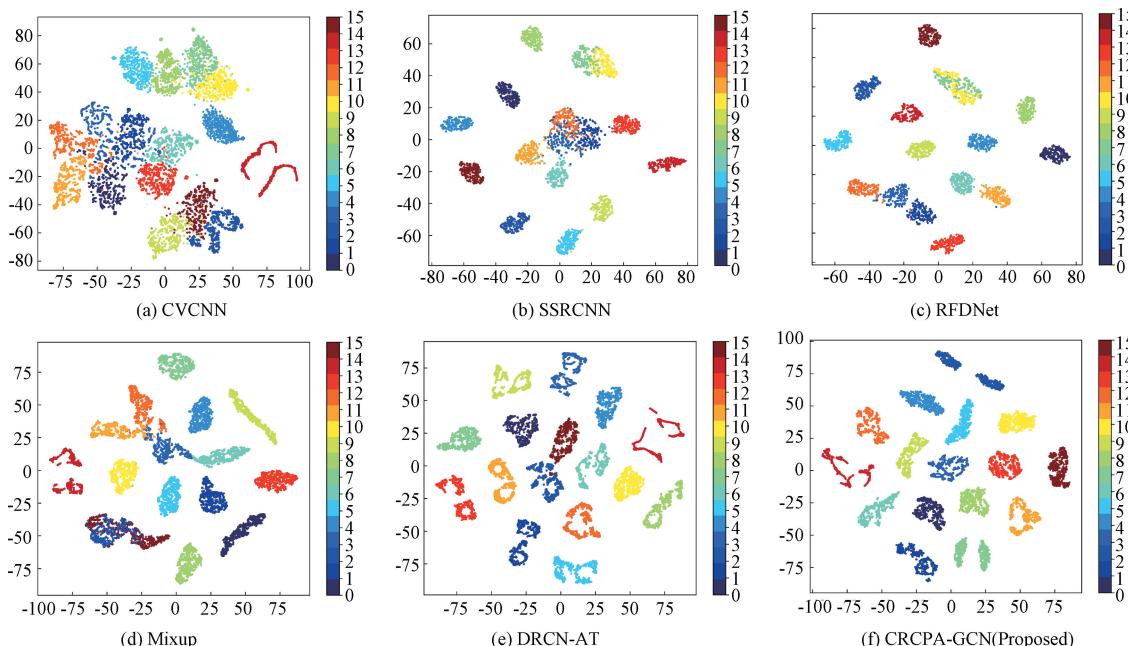
%

模型	3 shot	5 shot	10 shot	15 shot	20 shot
CVCNN	19.06	25.47	32.34	36.06	43.56
Mixup	32.06	45.97	69.13	84.94	91.88
SSRCNN	33.66	51.94	66.56	70.34	84.31
RFDNet	21.50	36.86	68.41	77.81	89.53
DRCN-AT	31.78	44.47	64.72	76.03	92.28
CRCPA-GCN	34.50	53.09	70.63	87.47	95.81

注:其中 shot 代表每类中所取辐射源样本的数量。

此外,随着信号样本数量的增加,CRCPA-GCN 模型的准确率稳步提升。特别在 20 shot 的学习场景下,CRCPA-GCN 达到了 95.81% 的识别准确率,进一步证明该模型在处理更多数据时的优异性能。特别值得注意的是,Mixup 方法虽然在 10 shot 场景下取得了较好的效果,但由于其生成样本的方式容易引入噪声,在训练数据更为充足的情况下,其性能表现不如 CRCPA-GCN。SSRCNN 和 RFDNet 虽然通过半监督和自监督学习在小样本条件下提升了模型的泛化能力,但在无标签数据的质量和数量上有较强的依赖性,限制了其在某些场景下的适用性。

为了更为直观地表示射频指纹特征的聚类效果,本研究通过 t 分布随机邻域嵌入(t-SNE)将该模型提取的射频指纹特征的维数降低到 2 维^[21],可视化如图 7 所示,从射频指纹特征的可视化可以看出,CVCNN、SSRCNN 以及 RFDNet 提取的特征有许多重叠部分,因此该部分的样本类别无法进行有效区分。相比之下,DRCN-AT、Mixup 和 CRCPA-GCN 提取的特征具有相对优异的类间可判别性。与 DRCN-AT 和 Mixup 相比,CRCPA-GCN 在类内更紧凑,即聚类效果更好,便于分类器在分类阶段的学习。



注:CVCNN,SSRCNN,RFDNet,Mixup,DRCN-AT,CRCPA-GCN 的轮廓系数分别为 0.099 2,0.319 5,0.353 0,0.559 2,0.584 0,0.686 7

图 7 特征可视化图

Fig. 7 Feature visualization diagram

此外,本研究对不同模型的聚类效果进行了评估,通过轮廓系数来量化其性能。其中 CVCNN 的轮廓系数仅为 0.099 2,而 CRCPA-GCN 的轮廓系数为 0.686 7,高于各对比模型的轮廓系数值。因此,由轮廓系数的对比可知 CRCPA-GCN 的聚类性能最优。

CRCPA-GCN 模型的性能优势主要在于其创新的网络结构和训练方法设计,包括 CPCa 和 GCNet 注意力模块的引入以及类重构和对抗训练的方法,这些都为模型提供了更好的特征学习以及重构数据。该模型不仅在小样本情况下表现出色,而且在样本数量增加时也能保持较高的识别性能,展现出其良好的泛化能力。

2) 对抗鲁棒性

为了验证不同模型在遭受对抗攻击后的鲁棒性,本研究将 CRCPA-GCN 方法与上述 5 种方法进行了比较,即 CVCNN, DRCN-AT, Mixup, SSRCNN 和 RFDNet, 本研究选择 Foolbox 工具包中的 FGSM 算法作为白盒攻击^[22], 使用上述测试集数据进行模型鲁棒性评估, 攻击系数为 0.001、0.002、0.003, 不同强度的对抗性攻击下的模型精度如图 8 所示。

由图 8 可知, 随着 FGSM 系数的增加, 即对抗性攻击强度增加, 各个模型的分类精度显著降低, 表明神经网络容易受到对抗性攻击。当攻击系数为 0.003 时, CVCNN 模型准确率已经接近 0, 其他各个模型的准确率也出现了不同程度的下降, 而 CRCPA-GCN 模型仍可以保持在 60% 左右的准确率, 性能最优。该实验表明本研究的 CRCPA-GCN 模型具有更好的对抗鲁棒性。

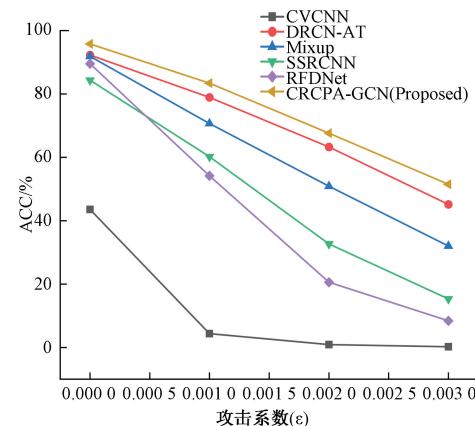


图 8 不同攻击强度对抗下的识别性能图

Fig. 8 Recognition performance under different attack intensities

2.5 消融实验

为了更好的评估模型组成部分对最终性能的影响,本章通过一系列消融实验来评估模型中关键模块的作用。这些实验有助于明确哪些模块对于模型的识别精度有显著影响。

本消融实验主要通过逐步移除模型中的某些部分来执行, 具体的模型实验如表 3 所示, 模型 1 是在 CRCPA-GCN 整体网络中同时移除了 CPCa 注意力模块和 GCNet 注意力模块的模型; 模型 2 是在 CRCPA-GCN 整体网络中移除了 CPCa 注意力模块的模型; 模型 3 是在 CRCPA-GCN 整体网络中移除了 GCNet 注意力模块的模型。以上各个模型均在相同的实验环境下进行。

表 3 消融后各模型的分类性能

Table 3 Classification performance of each model after ablation

%

模型	3shot	5shot	10shot	15shot	20shot
模型 1	26.19	35.56	59.78	78.94	90.68
模型 2	27.90	39.44	60.75	83.25	93.72
模型 3	33.84	48.59	68.81	86.34	94.13
CRCPA-GCN	34.50	53.09	70.63	87.47	95.81

由表 3 实验结果可知, 移除 CPCa 注意力模块后即模型 2, 对 CRCPA-GCN 模型的性能有显著影响, 特别是在 10 shot 的条件下, 识别准确率下降了近 10%, 这一现象突出了 CPCa 注意力模块在特征提取过程中的关键作用。同样, 当 GCNet 注意力模块被移除时即模型 3, CRCPA-GCN 模型在各个小样本的学习场景下, 准确率均有不同程度的下降, 表明 GCNet 注意力模块捕捉的全局上下文信息对于模型准确率进一步提高有显著作用。

消融实验结果表明, CRCPA-GCN 模型中的每个关键模块都对最终的性能有相应的贡献。CPCa 和 GCNet 注意力模块的引入显著增强了模型的特征提取和识别能力。

通过本章的消融实验, 证明了 CRCPA-GCN 模型中关键模块重要性。同时消融实验的结果强调了在设计高性能 SEI 网络模型时, 考虑多尺度特征提取和全局上下文信息整合的必要性。

此外, 在评估 CRCPA-GCN 模型分类效果时, 混淆矩阵提供了一种直观的方法来理解模型在不同样本数量下的分类性能。图 9 为 CRCPA-GCN 模型在 20 shot 条件下模型测试结果的混淆矩阵, 由图可知, 该学习场景下混淆矩阵的对角线值明显增加, 表明模型随着训练样本数量的增加模型的分类性能也有所提高, 进一步验证了该模型的识别分类性能。

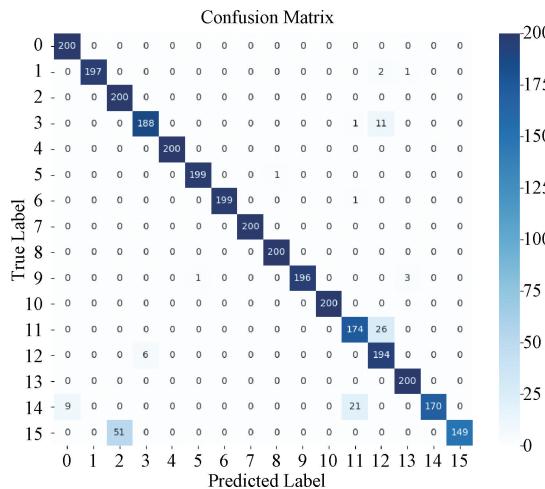


图 9 20 shot 条件下测试结果混淆矩阵

Fig. 9 Confusion matrix of test results under 20 shot condition

3 结 论

本研究提出了一种高效的 SEI 模型 CRCPA-GCN, 它在小样本学习场景下展现出了优异的性能。通过精心设计特征提取网络和数据重构网络, 将复数卷积与 CPCA 和 GCNet 注意力模块相结合, 实现了对信号关键特征的高效提取和整合。此外, 通过类重构和对抗训练策略, CRCPA-GCN 模型在抵御攻击方面展现出了更高的鲁棒性。尽管 CRCPA-GCN 模型已取得显著成果, 但其仍有改进和扩展的空间, 如何在不降低模型性能的前提下, 降低计算资源的需求, 可以作为 CRCPA-GCN 模型未来的拓展研究方向。

参考文献

- [1] 许敏, 李博涵, 王凯, 等. 特定辐射源个体识别算法研究[J]. 电子测量与仪器学报, 2021, 35(10):116-123.
XU M, LI B H, WANG K, et al. Research on individual identification method of specific emitter[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10):116-123.
- [2] 普运伟, 陈新杰, 余永鹏, 等. 基于模糊函数多维结构度量特征的雷达辐射源信号流在线分选[J]. 仪器仪表学报, 2023, 44(8):277-288.
PU Y W, CHEN X J, YU Y P, et al. Online sorting of radar emitter signal stream based on multidimensional structural measurement features of ambiguity function[J]. Chinese Journal of Scientific Instrument, 2023, 44(8):277-288.
- [3] 王诗, 朱笑莹, 孙浩, 等. 认知物联网基于边缘计算的频谱感知-分配方法[J]. 电子测量与仪器学报, 2023, 37(7):81-92.
WANG SH, ZHU X Y, SUN H, et al. Spectrum
- [4] 曾浩南, 谢跃雷. 一种去信道指纹的 IEEE802.11a 信号辐射源识别方法[J]. 电子测量技术, 2023, 46(17):125-130.
ZENG H N, XIE Y L. An IEEE802.11a signal radiation source identification method with channel fingerprint removal [J]. Electronic Measurement Technology, 2023, 46(17):125-130.
- [5] 唐震, 乔晓强, 张涛, 等. 基于深度残差收缩网络的辐射源个体识别方法[J]. 电子测量技术, 2022, 45(9):168-174.
TANG ZH, QIAO X Q, ZHANG T, et al. Individual radiator identification method based on deep residual shrinkage network [J]. Electronic Measurement Technology, 2022, 45(9):168-174.
- [6] WANG Y, GUI G, GACANIN H, et al. An efficient specific emitter identification method based on complexvalued neural networks and network compression[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(8): 2305-2317.
- [7] TAO M Y, FU X, LIN Y, et al. Resource-constrained specific emitter identification using end-to-end sparse feature selection[C]. GLOBECOM 2023-2023 IEEE Global Communications Conference, 2023: 6067-6072.
- [8] YAO ZH SH, FU X, GUO L T, et al. Few-shot specific emitter identification using asymmetric masked auto-encoder [J]. IEEE Communications Letters, 2023, 27(10):2657-2661.
- [9] HUANG H J, CHEN Z G, ZOU Y, et al. Channel prior convolutional attention for medical image segmentation[J]. Computers in Biology and Medicine, 2024, 178: 108784.
- [10] CAO Y, XU J R, LIN S, et al. GCNET: Non-local networks meet squeeze-excitation networks and beyond[C]. IEEE/CVF International Conference on Computer Vision Workshops, 2019.
- [11] 刘丰汇, 张治中, 张涛, 等. 辐射源个体识别中的对抗攻击研究[J]. 电子测量技术, 2023, 46(16):16-23.
LIU F H, ZHANG ZH ZH, ZHANG T, et al. The research of adversarial attacks in specific emitter identification[J]. Electronic Measurement Technology, 2023, 46(16):16-23.
- [12] HUANG L, PAN W J, ZHANG Y, et al. Data augmentation for deep learning-based radio modulation

sen-spectrum allocation strategy based on edge computing for cognitive-radio internet of things network[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(7):81-92.

[4] 曾浩南, 谢跃雷. 一种去信道指纹的 IEEE802.11a 信号辐射源识别方法[J]. 电子测量技术, 2023, 46(17):125-130.

ZENG H N, XIE Y L. An IEEE802.11a signal radiation source identification method with channel fingerprint removal [J]. Electronic Measurement Technology, 2023, 46(17):125-130.

[5] 唐震, 乔晓强, 张涛, 等. 基于深度残差收缩网络的辐射源个体识别方法[J]. 电子测量技术, 2022, 45(9):168-174.

TANG ZH, QIAO X Q, ZHANG T, et al. Individual radiator identification method based on deep residual shrinkage network [J]. Electronic Measurement Technology, 2022, 45(9):168-174.

[6] WANG Y, GUI G, GACANIN H, et al. An efficient specific emitter identification method based on complexvalued neural networks and network compression[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(8): 2305-2317.

[7] TAO M Y, FU X, LIN Y, et al. Resource-constrained specific emitter identification using end-to-end sparse feature selection[C]. GLOBECOM 2023-2023 IEEE Global Communications Conference, 2023: 6067-6072.

[8] YAO ZH SH, FU X, GUO L T, et al. Few-shot specific emitter identification using asymmetric masked auto-encoder [J]. IEEE Communications Letters, 2023, 27(10):2657-2661.

[9] HUANG H J, CHEN Z G, ZOU Y, et al. Channel prior convolutional attention for medical image segmentation[J]. Computers in Biology and Medicine, 2024, 178: 108784.

[10] CAO Y, XU J R, LIN S, et al. GCNET: Non-local networks meet squeeze-excitation networks and beyond[C]. IEEE/CVF International Conference on Computer Vision Workshops, 2019.

[11] 刘丰汇, 张治中, 张涛, 等. 辐射源个体识别中的对抗攻击研究[J]. 电子测量技术, 2023, 46(16):16-23.

LIU F H, ZHANG ZH ZH, ZHANG T, et al. The research of adversarial attacks in specific emitter identification[J]. Electronic Measurement Technology, 2023, 46(16):16-23.

[12] HUANG L, PAN W J, ZHANG Y, et al. Data augmentation for deep learning-based radio modulation

- classification[J]. IEEE Access, 2019, 8: 1498-1506.
- [13] HU J, SHEN L, SUN G. Squeeze-and-excitation neworks[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [14] WOO S, PARK J, LEE J, et al. CBAM: Convolutional block attention module[C]. European Conference on Computer Vision(ECCV), 2018: 3-19.
- [15] SANKHE K, BELGIOVINE M, ZHOU F, et al. No radio left behind: Radio fingerprinting through deep learning of physical-layer hardware impairments[J]. IEEE Transactions on Cognitive Communications and Networking, 2019, 6(1): 165-178.
- [16] WANG Y, GUI G, LIN Y, et al. Few-shot specific emitter identification via deep metric ensemble learning[J]. IEEE Internet of Things Journal, 2022, 9 (24): 24980-24994.
- [17] XU X J, CHEN ZH ZH. Mixing signals: Data augmentation approach for deep learning based modulation recognition[J]. ArXiv preprint ArXiv: 2204.03737, 2022.
- [18] DONG Y H, JIANG X H, CHENG L, et al. SSRCNN: A semi-supervised learning framework for signal recognition[J]. IEEE Transactions on Cognitive Communications and Networking, 2021, 7(3): 780-789.
- [19] XU L, SHI W J, FU X, et al. Few-shot specific emitter identification method using rotation feature decoupling for secure 6G [C]. 2023 IEEE 23rd International Conference on Communication Technology(ICCT). IEEE, 2023: 490-494.
- [20] LIU CH, FU X, GE Y L, et al. A robust few-shot seimethod using class-reconstruction and adversarial training[C]. 2022 IEEE 96th Vehicular Technology Conference. IEEE, 2022: 1-5.
- [21] CAI T T, MA R. Theoretical foundations of t-SNE forvisualizing high-dimensional clustered data [J]. Journal of Machine Learning Research, 2022, 23 (1): 13581-13634.
- [22] RAUBER J, BRENDL W. Foolbox: A python toolbox to benchmark the robustness of machine learning models [J]. ArXiv preprint arXiv: 1707.04131, 2017.

作者简介

刘佳乐,硕士研究生,主要研究方向为辐射源射频指纹识别、深度学习。

E-mail:hblgdx0116@163.com

郭志涛(通信作者),教授,主要研究方向为物联网、智能传感器、智能优化算法。

E-mail:2002089@hebut.edu.cn

王宏,硕士研究生,主要研究方向为智能信息处理。

E-mail:w_hong1710@163.com

张森,硕士研究生,主要研究方向为嵌入式系统设计。

E-mail:1570678595@qq.com