

小样本下基于对比学习的特定辐射源识别^{*}

黄逸飞 闫光辉 郑礼 汤春阳

(兰州交通大学电子与信息工程学院 兰州 730070)

摘要: 在通信特定辐射源识别任务中,针对深度学习网络在训练样本量不足时准确率低的问题,提出了一种基于时频数据增强和对比学习的特定辐射源识别方法。首先,从辐射源信号中提取 I/Q 信息,经过连续小波变换和 Welch 功率谱的时频数据增强构建多模态信息,以此对小样本数据进行扩充并送入改进的对比学习网络中进行特征提取,并且设计了一个由交叉熵、监督对比损失的加权和损失函数,充分提取特定辐射源信号的特征,确保两种特征向量分布具有余弦损失的一致性,训练结束后保存成最优模型,最后使用部分训练集数据对模型进行微调。所提出的方法在 ADS-B 数据集和 WiFi 数据集上进行了评估,与基线模型进行了比较,还对比了 28 种数据增强组合方式的效果。实验结果表明,本文所提出的方法比现有方法取得了更优异的效果,并且本文提出的数据增强组合方式效果最优。具体而言,当有标记训练样本数量与所有训练样本数量的比率为 5% 时,在 ADS-B 数据集上的识别准确率为 87.30%,相较于基线模型提升 6%;在 WiFi 数据集上的识别准确率为 94.07%,相较于基线模型提升 55.39%。

关键词: 对比学习;特定辐射源识别;数据增强;深度学习

中图分类号: TN839 文献标识码: A 国家标准学科分类代码: 510.4010

Specific emitter identification based on contrastive learning in limited samples

Huang Yifei Yan Guanghui Zheng Li Tang Chunyang

(School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: In order to solve the problem of low accuracy of deep learning network when the training sample size is insufficient, a specific radiation source recognition method based on time-frequency data enhancement and contrast learning is proposed. Firstly, I/Q information is extracted from the radiation source signal, and multi-modal information is constructed through continuous wavelet transform and time-frequency data of Welch power spectrum enhancement. In this way, the small sample data is expanded and sent into contrast learning networks for feature extraction. In addition, a weighting and loss function based on cross entropy and supervised contrast loss is designed. The features of specific radiation source signals are fully extracted to ensure that the two feature vector distributions have the consistency of cosine loss, and the optimal model is saved after training. Finally, part of the training set data is used to fine-tune the model. The proposed approach was evaluated on ADS-B dataset and WiFi dataset, compared with baseline models, and compared with 28 data enhancement combinations. Experimental results show that the method proposed in this paper achieves better results than the existing methods, and the data enhancement combination method proposed in this paper has the best effect. Specifically, when the ratio of the number of labeled training samples to the number of all training samples is 5%, the recognition accuracy on the ADS-B dataset is 87.30%, which is 6% higher than that of the baseline model. The recognition accuracy on WiFi data set is 94.07%, which is 55.39% higher than the baseline model.

Keywords: contrastive learning; specific emitter identification; data enhancement; deep learning

0 引言

随着通信技术的迅猛发展,越来越多的通信设备被投

入民用和军用,这在提高我们工作效率和改善生活条件的同时,也会产生一系列的通信安全隐患^[1],比如:民用设备身份欺骗、无线电频谱和军事电子干扰等。特定辐射源识

别(specific emitter identification, SEI)是指通过分析提取的无线电信号的特征来区分单个辐射源的过程^[2],无线电信号的特征称为射频指纹(radio frequency fingerprinting, RFF),由于对于每个辐射源来说都是固定且唯一的。因此,特定辐射源识别能有效识别外来非法通信设备,也能避免未知设备入侵窃取用户信息,它在军事和民用场景中都发挥着越来越重要的作用^[3]。

在目前的研究中,SEI 技术可以分为两类,即使用瞬态信号的方法和使用稳态信号的方法^[4]。基于瞬态的 SEI 技术是指使用发射机开始发射信号瞬间的无线电信号来对发射机的身份进行识别,发射机发射瞬间的信号与即将发射的信号无关,只与发射机的内部硬件的状态相关^[5]。Guo 等^[6]在 19 个雷达脉冲瞬态信号特征中选出了 3 个作为射频指纹,每个射频指纹由预先确定的特征子集组成,利用两种雷达数据集,采用五种分类算法对射频指纹的性能进行了评价。准确且一致地检测瞬态信号的起始点和结束点是正确识别的关键。然而,瞬态信号很难捕获,特别是在非合作通信环境中^[7]。

基于稳态的 SEI 技术是指使用发射机正常通信时的无线电信号来识别发射机的身份,与使用瞬态信号的方法不同,它是将提取到的稳态信号转换到另一个新的信号域,从而提取出独特且稳定的指纹特征^[8]。按照变换域类型,可分为四类^[9],第一类是时频,王检等^[10]在瑞利信道条件下将 ZigBee 信号的 Welch 功率谱作为 RFF 送入 CNN 网络中进行分类。第二类是高阶谱域^[11-12],Ding 等^[13]将接收信号的双谱作为一个独特的特征进行计算,然后使用有监督的降维方法来显著降低双谱的维度,最后,利用压缩双谱,采用卷积神经网络对特定辐射源进行识别。第三类是循环谱域,它是将信号的二阶和三阶循环累积量分别作傅里叶变换,从而可以得到对应的循环谱和循环双谱^[14];最后一类是希尔伯特谱域,韩洁等^[15]使用希尔伯特黄变换(Hilbert-Huang transform, HHT)算法得到信号的三维希尔伯特能量谱,然后利用分形理论得到特征向量,最后使用支持向量机分类器完成特定辐射源识别。在特定辐射源识别任务中,由于各个辐射源之间的特征差异不明显,目前的研究都是采用深度学习的方法学习辐射源类间的隐藏特征。Wang 等^[16]提出了一种基于 CVNN(complex-valued neural network)和网络压缩的高效 SEI 方法,前者是为了提高性能,后者是为了降低模型的复杂度和大小,同时保证了高识别率。深度学习能有良好表现的前提条件就是需要大量有标记的数据样本^[17]。然而,现有文献中的方法多是基于非公开的实测数据进行测试和评估,如:各种通信站数据、软件无线电平台数据、物联网设备数据等^[18]。在 SEI 领域缺乏标准的大规模数据集,这就限制了深度学习在 SEI 领域的创新和应用。

在有些时候,对于非合作的发射机身份识别,它们的信号发射时间很短暂,不能获取足够的数据^[19],如果仍使用

传统深度学习方法就会由于缺乏足够的数据而出现过拟合的问题,导致识别精度不高。刘康晟等^[20]将弱标注数据集拆分为小样本有标注数据集和大样本无标注数据集,利用小样本有标注数据集初步训练模型。张立民等^[21]为了解决单次样本学习花销较大的问题,提出了一种基于增量学习的 SEI 方法。有的学者从半监督学习的角度来解决此问题,Wang 等^[22]提出了一种基于迁移学习的半监督算法,由卷积自编码器和卷积神经网络组成的新型深度重构与分类网络(deep reconstruction and classification network, DRCN)结构。Dong 等^[23]提出了 SSRCNN(semi-supervised residual convolutional neural network)模型,它是一种基于半监督学习的自动调制分类方法,其中损失函数包括中心损失、交叉熵损失和 KL 散度损失。信号在传播过程中会受各种因素的影响,导致单个发射器的表征不准确,Gong 等^[24]提出了 TripleGAN (triple generative adversarial network)模型,它是使用三重生成对抗网络的新型半监督 SEI,可以提取隐藏在原始信号中的总体特征信息。Huang 等^[25]提出了 SimMIM (simple masked image modeling) 模型,它是一种基于掩码自动编码的无监督预训练方法用于 RFF 学习。半监督 SEI 方法用于提取无线电信号的判别性和广义语义特征的研究,Fu 等^[26]提出了一种使用度量对抗训练的半监督 SEI 方法,该研究在小样本数据集上的表现虽然相对于之前的研究有提高,但是在更小的数据集规模下,准确率并不高。

对比学习能够有效解决深度学习在大规模数据集训练和小样本情况下模型准确率较低的问题,这主要得益于其数据增强模块。然而,现有的数据增强方法通过向信号中加入随机干扰来生成新样本,但这种方式并未引入额外的有效信息。

基于以上问题,本文提出了一种基于时频数据增强和对比学习网络的特定辐射源识别方法(time frequency data enhancement supervised contrast learning, TF-SupCon),创新性地把连续小波变换(continuous wavelet transform, CWT)和 Welch 功率谱作为数据增强方式来构建时频域样本对,并设计了一个由交叉熵和监督对比损失组成的加权和损失函数来训练改进的对比学习网络,确保两种模态特征向量分布具有一致性,最后对模型进行微调。在 ADS-B (Automatic Dependent Surveillance-Broadcast) 数据集和 WiFi 数据集上进行了评估,还对比了 7 个不同的数据增强方法之间的效果。实验结果表明,在 CWT-Welch 的数据增强组合方式下,本文提出的 TF-SupCon 网络具有更高的识别率。

1 问题描述

1.1 辐射源指纹识别

在信号形成的过程中,由于发射机的硬件会在批量化生产时不可避免的产生一些缺陷,包括模数转换器产生的

量化误差、正交调制产生的相位噪声、I/Q 偏移、上变频器产生的载波频率偏移和功率放大器产生的非线性失真,这就使得同一批次、同规格的发射机发射的信号指纹特征也有细微差别。找到不同发射机 RFF 指纹的差别,就能区分发射机。

如图 1 所示,原本的基带信号首先经过数字信号处理后变成 I/Q 信号,用 $I(n)$ 和 $Q(n)$ 表示,在数模转换时,由于模拟信号精度有限且具有离散化的特性,导致输出的模拟信号和输入的数字信号之间存在差异,会产生量化误差,如式(1)和(2)所示。

$$I'(t) = \sum_{w=-\infty}^{+\infty} I(n) \times \delta(t - w(T_s + T')) \times \frac{\sin(\pi(f_o - f'/f_s))}{\pi(f_o - f'/f_s)} \quad (1)$$

$$Q'(t) = \sum_{w=-\infty}^{+\infty} Q(n) \times \delta(t - w(T_s + T')) \times \frac{\sin(\pi(f_o - f'/f_s))}{\pi(f_o - f'/f_s)} \quad (2)$$

其中, $f_o = f_n/f_s$, f_n 代表模数转换模块的输出频率, f_s 代表转换频率, f' 代表量化误差, 单位码元时间为 T_s 。

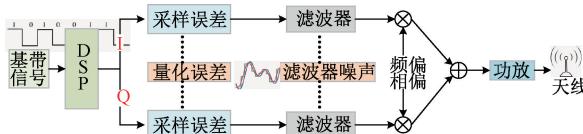


图 1 辐射源指纹识别形成原理

Fig. 1 Shows the formation principle of fingerprint recognition for radiation sources

除了在此过程中产生的量化误差,还会有孔径误差和毛刺脉冲^[27],这是在码元变换过程中不可避免的产生的高频信号,经过滤波器后的 I/Q 信号为:

$$I''(t) = \cos(2\pi f_{bz}t) \times \text{Low}(I'(t)) \quad (3)$$

$$Q''(t) = \sin(2\pi f_{bz}t) \times \text{Low}(Q'(t)) \quad (4)$$

其中, $\text{Low}(\cdot)$ 代表低通滤波器的函数,本振频率为 f_{bz} , 本振信号还存在一定的相位噪声,所以 $\sin(2\pi f_{bz}t)$ 和 $\cos(2\pi f_{bz}t)$ 中还会有一定的相位差,大小为 $\pi/2$,也会产生 I/Q 偏移,那么模拟信号新的表示为:

$$I'''(t) = \cos(2\pi f_{bz}t + \varphi(t)) \times \text{Low}(I'(t)) \quad (5)$$

$$Q'''(t) = \sin(2\pi f_{bz}t + \varphi(t)) \times \text{Low}(Q'(t)) \times \gamma \quad (6)$$

功放的放大倍数是会随时间进行变化的,所以调制信号也会由于功放而产生失真;以上是关于发射信号的失真及误差分析,同样的载波信号也会由于发射机的物理器件缺陷而产生频率偏移。在载波信号产生的过程中,晶振电路器件的物理缺陷是导致产生误差的主要原因,尽管是商用的具有温度补偿的晶振也会有一定的误差。总之,无论是发射信号还是承载发射信号的载波信号,或多或少都会由于发射机物理硬件缺陷产生一定的影响。

1.2 小样本下的特定辐射源识别

在小样本下实现特定辐射源识别任务具有较高的应用价值。深度学习在各种领域的应用能有良好表现的前提条件就是需要大量有标记的数据样本。深度学习模型优化的核心思想是学习样本空间(S_s)与标签空间(L_s)之间的映射关系($m: S_s \rightarrow L_s$)。而在小样本条件下,深度学习的训练集只占据整个样本空间的一小部分,这导致训练集和总样本空间存在很大的差别,数据集可表示为:

$$\text{Data_set}_{\text{train}} = \{(x_i, y_i), x_i \in S_s, y_i \in L_s\} \quad (7)$$

其中, (x_i, y_i) 为训练样本集, x_i 和 y_i 分别表示第 i 个样本和标签。深度学习模型通过最小化训练数据集 $\text{Data_set}_{\text{train}}$ 的期望损失对模型进行优化:

$$R_L(m) = \min_{m \in W} \frac{1}{L} \sum_{x_i \in S_s, y_i \in L_s} L(m(x_i), y_i) \quad (8)$$

其中, L 是模型的损失函数, W 是解空间,由式(7)可知,最优模型取决于训练集和解空间 W ,有些时候,对于非合作的发射机身份识别,它们的信号发射时间很短暂,不能获取足够的数据,可供算法选择的 W 过大,导致模型过拟合,泛化能力差,识别精度不高。

小样本的泛化问题可以从数据增强和模型角度来解决。

1.3 通过数据增强扩充样本

对于小样本的 SEI 任务,使用数据增强可以构造更多的数据使得模型学习在一定程度上接近真实的样本空间,可以提高网络的泛化能力。传统的数据增强方式有平移(Shifting)、翻转(Flipping)、旋转(Rotation)、加性白高斯噪声(additive white gaussian noise, AWGN)等,对于一维信号 $x(t)$ 来说,它们的描述为:

1) 平移

随机移动信号改变每个数据点的绝对位置,同时保持它们的相对位置。信号移位会破坏因果关系,但不会改变发射机的特性。

$$x_{\text{shifting}}(t) = x(t - \tau) \quad (9)$$

其中, τ 是平移的时间偏移量。

2) 翻转

数据翻转本质上是改变原始信号的强度,将其随机转换为正值或负值,从而得到翻转数据。

$$x_{\text{flipping}}(t) = x(-t) \quad (10)$$

3) 旋转

假设信号是一个复数形式的信号 $x(t) = A(t)e^{j\theta(t)}$, 旋转相当于改变信号的相位,保持幅度不变。旋转操作可以表示为:

$$x_{\text{rotation}}(t) = A(t)e^{j(\theta(t) + \Delta\theta)} \quad (11)$$

其中, $\Delta\theta$ 是旋转的相位变化。

4) 加性高斯白噪声

在原始信号中加入高斯白噪声是一种有效数据增强方法。然而,添加噪声本身并不会增加原始数据的信息含

量,并且可能由于噪声的存在而降低发射机识别的性能。

$$x_{addnoise}(t) = x(t) + n(t) \quad (12)$$

其中, $n(t)$ 表示加性高斯白噪声。

1.4 通过对比学习缩小解空间

对比学习的目标是通过正负样本学习映射 W ,使得相同事物样本的特征距离尽可能近,不同类别样本的特征距离尽可能远^[28]:

$$L(f(x), f(x_+)) > L(f(x), f(x_-)) \quad (13)$$

其中,对 x 和 x_+ 互为正样本,而对 x 和 x_- 互为负样本。通过对比学习,模型倾向于选择能够最小化对比损失并取得较好分类效果的算法^[29],提高了模型在小样本下的泛化能力。本文提出的基于时频数据增强的特定辐射源识别过程如图 2 所示。

2 改进对比学习网络的特定辐射源识别方法

2.1 提出的 TF-SupCon 模型框图

基于时频数据增强和对比学习网络的特定辐射源识别

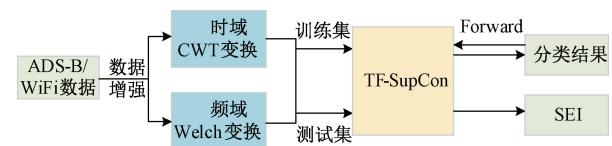


图 2 基于时频数据增强的特定辐射源识别

Fig. 2 Identification of specific radiation sources based on time-frequency data enhancement

模型的设计有 3 点:第一是选择合适的数据增强方法,在小样本下可以刺激对比学习网络的学习;第二是设计特征提取器以及优化损失函数,可以更准确的提取辐射源个体之间的隐藏特征;第三是将训练好的模型进行微调,可以提升模型识别准确率以及增强模型泛化性。本文提出的特定辐射源识别的整体方法及细节如图 3(b)所示。

在预训练阶段,首先加载辐射源 I/Q 信号,经过 CWT 和 Welch 数据增强分别送入到编码器中,得到特征向量 h_i 和 h_j ,在经过精心设计的全连接层和多层次感知机后,得到的向量会参与交叉熵损失和监督对比损失的计算,从而更

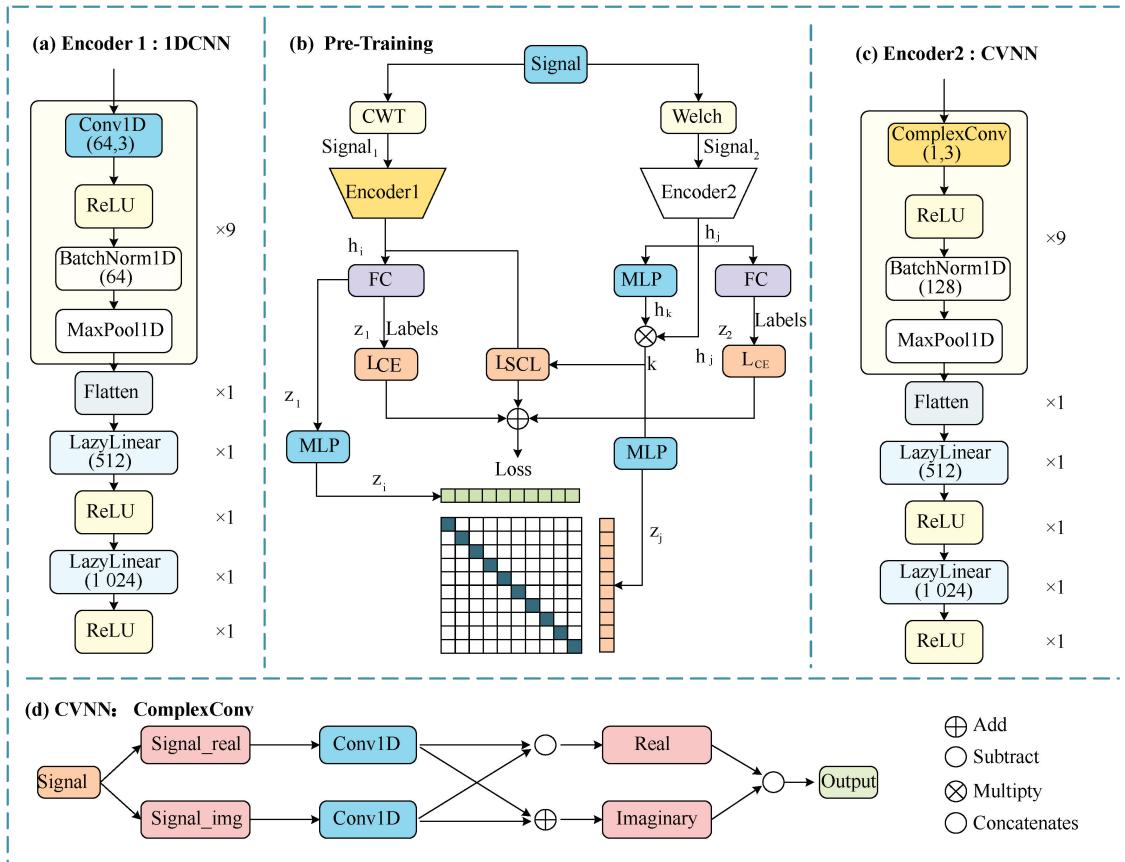


图 3 TF-SupCon 模型的整体与细节

Fig. 3 The overall and details of the TF-SupCon model

有效的对模型参数进行反向传递,最后训练结束后,冻结预训练模型参数,使用部分训练集对模型进行微调。

2.2 设计的不共享权重的编码器

本文没有使用传统的共享编码器权重的对比学习框

架。相反,使用基于复值神经网络和卷积神经网络代替传统的对比学习编码器。将有标签的样本组成的小样本训练集经过 CWT 数据增强后送入到编码器 1 中,编码器 1 是基于深度卷积神经网络的,它的结构如图 3(a)所示,它

被设计成 9 个卷积模块、展平层、懒惰全连接层和激活层组成,其中每个卷积模块由一维卷积层、ReLU(rectified linear unit)激活层、BN(batch normalization)层和最大池化层组成;其中第一层卷积的输入通道为 63,卷积核大小为 3。

复值卷积神经网络代替传统卷积。由于在 SEI 任务中信号被认为是复数,I/Q 分别代表信号的实部和虚部,因此我们使用具有复值权重和偏差的 CVNN 从 I/Q 数据中提取特征,同时保留 I/Q 信号之间的相关性。将有标签的样本组成的小样本训练集经过 Welch 数据增强后送入到编码器 2 中,编码器 2 使用的是复值神经网络,它的结构如图 3(c)所示,与编码器 1 不同的是,每个卷积模块的卷积层被替换成复值卷积,所谓复值卷积就是在内部使用实数运算模拟复数运算,首先需要将信号数据一分为二,设置前半部分表示实部,后半部分表示虚部。定义一个复数滤波器权重矩阵 $Z = A + jB$ 和一个复数向量 $\vec{v} = x + jy$ 来表示 I/Q 信号。通过滤波器对复数向量进行卷积就能得到:

$$Z * \vec{v} = (A^* x - B^* y) + j(B^* x + A^* y) \quad (14)$$

这一过程的推导如图 3(d)所示,经过卷积,得到的实部和虚部为:

$$Real(Z * \vec{v}) = (A^* x - B^* y) \quad (15)$$

$$Imag(Z * \vec{v}) = (A^* y + B^* x) \quad (16)$$

最后,将实部虚部进行拼接,生成最终向量。使用复值运算比实值运算更能帮助神经网络提取信号的特征信息。

2.3 提出的数据增强方法

如图 4(a)所示,传统的数据增强方法只对原始信号产生一定的干扰,而不会提供额外的发射器特征信息,过多的干扰甚至妨碍正常的网络训练。为了解决上述问题,本文对数据特征分布进行了分析,认为增强后的数据与原始数据在特征分布方面的差异越大,表示的特征空间就会越接近原本的特征空间,如图 4(b)所示。因此,本文提出了两种数据增强方法:连续小波变换和 Welch 功率谱,它们对信号进行时频变换,以获得与原始数据显著不同的样本。

1) 功率谱替代传统的数据增强

一般认为,发射机信息主要存在于本振偏移和相位噪声中。对 I/Q 信号进行 Welch 功率谱计算得到频域信息,突出了信号的发射端特征。对原始 I/Q 信号进行 Welch 功率谱变换,在提供新信息的同时不会破坏发射机特性,使得将其作为数据增强的方法完全可行。第 i 段的信号功率谱为:

$$\hat{P}^i(\omega) = \frac{1}{MU} + \sum_{n=0}^{M-1} x^i(n)w(n)e^{-j\omega n} \quad |^2, U = \frac{1}{M} \sum_{n=0}^{M-1} w^2(n) \quad (17)$$

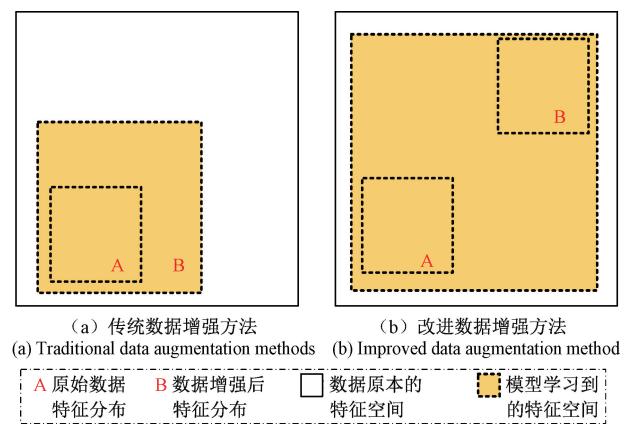


图 4 增强后数据与原始数据对比

Fig. 4 Comparison of the enhanced data with the original data

式中:信号样本 $x(n)$ 被分割成 L 段,每段长度为 M , $x^i(n) = x[n + (i-1)k]$, U 为归一化因子; $w(n)$ 为非矩形窗函数,信号的功率谱则定义为:

$$\hat{P}(\omega) = \frac{1}{L} \sum_{i=1}^L \hat{P}^i(\omega) \quad (18)$$

2) 小波谱替代传统的数据增强

使用 CWT 作为一种数据增强的方法,可以在一定程度上克服信道中噪声对辐射源信号的影响,这是因为它是提取信号频率的不同分量,而且是有针对性的对信号的有用频率进行提取^[30]。对于辐射源信号 $x(n)$,对其进行 CWT 的公式为:

$$x(n)_{CWT}(x, y) = \frac{1}{\sqrt{x}} \int x(n) \psi\left(\frac{n-y}{x}\right) dt \quad (19)$$

其中, x 为小波基的缩放系数,可以用来改变信号的提取频率; y 为小波基的时间平移系数; $\psi(n)$ 为小波基函数,本文采用的 ADS-B 数据集的调制方式是脉冲位置调制,WiFi 数据集的调制方式是正交频分复用技术(orthogonal frequency division multiplexing,OFDM),因此小波基函数使用 haar,其表达式为:

$$\psi(n) = \begin{cases} 1, & 0 \leq n \leq 1 \\ 0, & \text{其他} \end{cases} \quad (20)$$

选择看似复杂的数据增强方法的原因是为了获得与原始样本显著不同的增强数据,不仅改变了原始数据的特征概率分布,而且改变了数据的维数,从向量对向量的比较过渡到向量对图像的比较。通过将一维 I/Q 信号转换为二维小波谱图,并使用对比损失来计算它们的相似性并训练网络,它本质上成为一种多模态网络,而不仅仅是数据增强。

2.4 改进的损失函数

监督对比损失可以分为 3 个部分:原始样本和增强样本之间的对比损失、原始样本的监督损失、增强样本的监督损失。传统的损失函数是在预训练阶段不使用标签,仅

在微调时使用标签,而小样本学习缺乏高质量的数据,仅在微调期间使用标签来训练网络是不够的,本文提出将原始样本和增强样本聚类在一起,然后使用对比损失来拉近正原始样本和正增强样本之间的距离。并且本文提出的 TF-SupCon 中的两个编码器不共享权值,因此使用监督损失和对比损失来训练两个编码器。

上一小节中提到了数据增强后的数据经过两个编码器,生成了特征向量 h_i 和 h_j ,在经过全连接层得到 z_1 和 z_2 ,它们会和各自的标签送入到交叉熵损失函数中得到 L_{CE1} 和 L_{CE2} ,交叉熵损失函数值定义标签一致性,预测值的概率分布与真实值的概率分布越一致,交叉熵损失越小,交叉熵损失函数为:

$$L_{CE}(z, Labels) = -\log_2 \left(\frac{\exp^{z[Labels]}}{\sum_{j=1}^N \exp^{z[j]}} \right) = -z[Labels] + \log_2 \left(\sum_{j=1}^N \exp^{z[j]} \right) \quad (21)$$

h_j 会继续被送入到多层感知机中得到 h_k ,再与 h_i 相乘得到 k, k 再与 h_i 计算监督对比损失。对比损失函数值定义样本一致性,假如 $Batch_Size = N$ 则输入的数据为 $\{\{x_i, y_i\}, \dots, \{x_N, y_N\}\}$, 分别经过两种数据增强生成两个数据 \tilde{x}_{2i-1} 和 \tilde{x}_{2i} , 数据集为 $\{\{\tilde{x}_i, \tilde{y}_i\}, \dots, \{\tilde{x}_{2N}, \tilde{y}_{2N}\}\}$, 其中标签 $\tilde{y}_{2i-1} = \tilde{y}_{2i} = y_i$, 监督对比损失公式为:

$$L_{SCL} = \sum_{i=1}^{2N} \frac{-1}{2N_{\tilde{y}_i} - 1} \sum_{j=1}^{2N} R_{i \neq j} \times R_{\tilde{y}_i = \tilde{y}_j} \times \log_2 \left(\frac{\exp \left(\frac{z_i \cdot z_j}{\tau} \right)}{\sum_{k=1}^{2N} R_{i \neq k} \times \exp \left(\frac{z_i \cdot z_k}{\tau} \right)} \right) \quad (22)$$

其中, $N_{\tilde{y}_i}$ 是同批数据中相同标签的样本;当 $i = j$ 时, $R_{i \neq j}$ 返回 0; z_i 为特征提取网络的输出, $z_i \cdot z_j$ 代表内积; τ 为温度系数,取 0.5, k 与 h_i 计算监督对比损失得到的结果为 L_{SCL} 。

交叉熵损失会引起的模型泛化性差和对噪声标签的鲁棒性差等问题,监督对比损失对小样本识别分类任务很友好,所以,本文先将原始样本和增强样本聚类在一起,然后使用对比损失来拉近正原始样本和正增强样本之间的距离。本文采用的损失函数为:

$$Loss = 1 \times L_{ce1} + 1 \times L_{ce2} + q \times L_{scl} \quad (23)$$

其中, L_{ce1} 代表原始数据交叉熵损失, L_{ce2} 代表数据增强数据的交叉熵损失, q 为权重系数,在小样本学习中,改变原始样本和增强样本之间的对比损失比例可以显著提高分类效果,如第 3.5 节实验中对加权和损失系数 q 如何影响分类结果进行了讨论。实验结果表明, q 取 1 时效果最好。

2.5 设计的预训练与微调过程

微调(Fine-tuning)指的是在已有的预训练模型基础上,进一步训练或调整模型的过程。目的是使模型在特定任务或数据集上表现得更好。本文模型在经过小样本训

练集训练之后,会保存最优模型,冻结模型参数不变,继续使用少量训练集对模型分类网络进行微调,微调框架如图 5 所示。

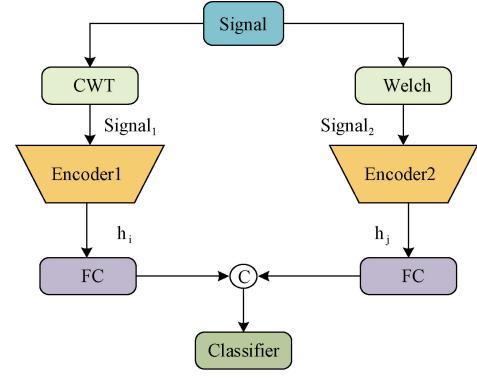


图 5 模型微调框图

Fig. 5 Block diagram of model fine-tuning

3 实验及结果分析

3.1 实验参数设置

本文使用 ADS-B 公开数据和文献[26]中公开的 WiFi 数据集。其中,前者是主要用于收集和分析这些广播的飞行数据,广泛应用于航空交通管理、飞行预测、异常检测和数据科学等领域,本文选取 10 个航空器的通信数据构建真实 SEI 数据集;后者是从符合 IEEE 802.11a 标准帧的 16 台 USRP X310 无线电收集的 WiFi 数据集。数据集均按照 6:2:2 的比例划分训练集、验证集和测试集,划分后的训练集中每个类别的样本数量都为 3 080 个。接着按照 1%、5%、10%、15%、20% 的比例分别划分不同规模的小样本训练集。本文所有网络模型均采用 PyTorch 框架搭建,实验硬件采用 Intel CORE i7-6700K CPU,64 GB 内存,搭载 NVIDIA GeForce RTX 2080Ti 显卡。30% 的训练样本被划分为验证数据集,搭建 TF-SupCon 网络结构模型,其网络超参数为:迭代次数(Epoch)设置为 300 次,批尺寸(Batch_size)最终设置为 64,优化器(Optimizer)的类型为 LARS;微调时,Batch_size 为 256,对于 ADS-B 数据集来说,Epoch 设置为 35;对于 WiFi 数据集来说,Epoch 设置为 120。

3.2 不同网络模型对比实验及分析

在 ADS-B、WiFi 数据集下,为了探究本文方法在小样本下效果明显优于现有方法,故选取了引言部分提到的 6 种方法和本文提出的一组仅采用 FFT 进行数据增强的对照试验方法进行比较(包括:CVNN^[16]、DRCN^[22]、SSRCNN^[23]、TripleGAN^[24]、SimMIM^[25]、MAT^[26]、F-SupCon)。其中,基于 SimMIM 的方法使用全部数据对自动编码器进行预训练,然后使用有标签数据对其进行微调,可当做半监督的算法进行比较。在不改变基线模型核心算法的前提下,使用与本文方法相同的数据集、优化器、

学习率等条件进行比较,保证公平性。

本文提出的 TF-SupCon 方法在 ADS-B 和 WiFi 数据集下的平均准确率由图 6 所示,总体来说,在各个数据比率条件下,橘色柱状是最高的,代表本文提出方法的平均准确率都优于其他基线模型,F-SupCon 模型也是本文提出的对照模型,它在数据增强部分仅采用了频域的快速傅里叶变换数据增强方法,其效果仅次于本文模型。如表 1 所示,特别是在参与训练的训练样本与所有训练样本数量的比例设定为 1% 时,只有本文提出的方法识别准确率高于 50%,且大幅领先其他算法;另外,在 WiFi 数据集下,当训练数据比例为 5% 时,本文提出的方法能达到 90% 以上,而其他基线模型的准确率只能达到 20%~40% 之间。这些实验结果都能说明,本文模型尽管在数据量极小的条件

下,仍然能学习到更丰富的特征,这得力于本文设计的时频数据增强方法、优化的损失函数等。

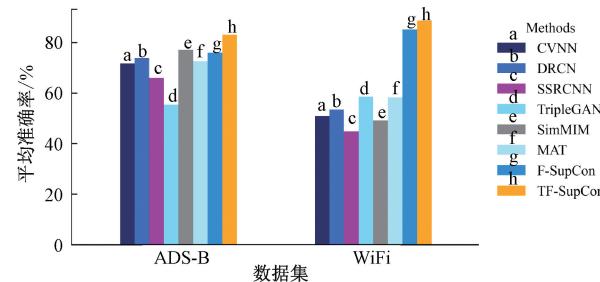


图 6 不同网络模型在各个数据比例下平均准确率对比

Fig. 6 Comparison of the average accuracy rates of different network models at various data ratios

表 1 不同网络模型在 ADS-B 和 WiFi 数据集下准确率对比

Table 1 Comparison of accuracy rates of different network models on the ADS-B and WiFi datasets

方法	ADS-B						WiFi					
	1%	5%	10%	15%	20%	Average	1%	5%	10%	15%	20%	Average
CVNN ^[16]	26.40	67.30	82.30	90.50	92.60	71.82	13.62	29.03	41.06	75.35	95.67	50.95
DRCN ^[22]	26.50	70.90	88.80	90.80	92.80	73.96	13.49	29.46	56.10	81.30	87.18	53.51
SSRCNN ^[23]	16.40	40.40	90.30	90.90	92.00	66.00	6.22	12.32	60.85	63.28	81.51	44.84
TripleGAN ^[24]	30.60	50.00	55.30	67.20	74.20	55.46	13.76	30.45	64.81	88.84	94.96	58.56
SimMIM ^[25]	30.70	81.30	90.10	90.50	92.90	77.10	19.40	38.68	45.46	65.41	77.30	49.25
MAT ^[26]	33.10	71.90	73.70	90.90	93.40	72.60	12.43	21.99	59.50	98.17	99.80	58.38
F-SupCon	37.20	74.40	85.10	90.00	93.20	75.98	38.78	91.25	97.58	98.99	99.23	85.17
TF-SupCon	54.80	87.30	88.20	91.80	93.60	83.14	50.91	94.07	99.18	99.61	99.85	88.72

3.3 消融对比实验及分析

为了分析 TF-SupCon 模型不同组成部分对实验结果的重要性,本文设计了消融实验,消融的细节信息如表 2 所示。在 ADS-B 和 WiFi 数据集下,不论是损失函数方面还是数据增强方面,对最终的识别准确率的影响都很大,消融任何因素,都会使准确率大幅降低;通过进一步分析可知,当没有交叉熵

损失时,在两个数据集和各个数据量比例下,模型的准确率仅在 20%~44% 的范围内,这说明这一对交叉熵损失对于模型来说至关重要,因为交叉熵损失函数值可以定义标签的一致性,也就是说交叉熵损失函数可以保证模型的训练与学习更贴近与真实情况,同时也说明了在 SEI 任务中,本文的模型对标签比较敏感,这也是大多数有监督学习的通病。

表 2 在 ADS-B 和 WiFi 数据集下消融实验

Table 2 Ablation experiments under the ADS-B and WiFi datasets

Components	CWT	Welch	CE	SCL	ADS-B		WiFi	
					5%	20%	5%	20%
w/o CE	√	√		√	23.40	28.40	35.58	44.01
w/o SCL	√	√	√		81.00	92.50	93.66	97.31
w/o Welch	√		√	√	59.30	87.50	75.73	96.56
w/o CWT		√	√	√	75.40	91.70	56.90	89.46
TF-SupCon	√	√	√	√	87.30	93.60	94.07	99.44

3.4 数据增强对比实验

数据增强的操作组合对于对比学习模型学习良好的特征表示至关重要,为了系统地研究数据增强组合方式的影响,本文将前文提到的 7 种适用于 SEI 数据的数据增强

方法进行组合和比较,为了使实验结果更有说服力以及更有泛化性,在两个数据集都进行了验证,绘制了数据增强热力图,如图 7~8 所示,图中的数值代表准确率(单位为%)。

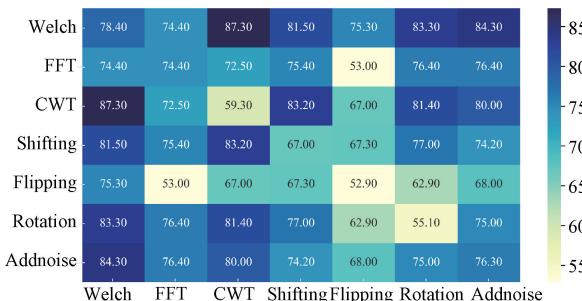


图 7 在 5% 的 ADS-B 数据集下数据增强准确率热力图

Fig. 7 Heat map of data enhancement accuracy under the 5% ADS-B dataset

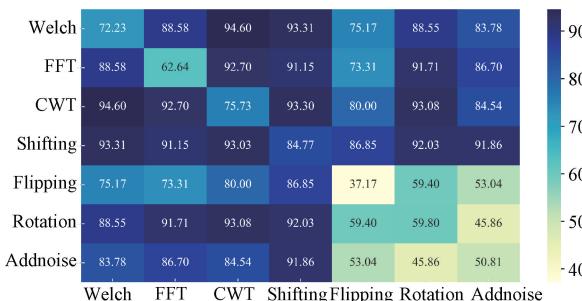


图 8 在 5% 的 WiFi 数据集下数据增强准确率热力图

Fig. 8 Heat map of data enhancement accuracy under the 5% WiFi dataset

为了理解单个数据增强的效果和增强组合的重要性,本文研究了单独或成对应用数据增强时框架的性能。在单个或组合数据增强下,每种数据增强方法仅应用于一个编码器。对于对角线上的数值是对应于单个转换,而非对角线的数值对应于两个转换的组合,两个数据增强的顺序对实验结果没有影响,所以上图实验结果是关于对角线对称的。

在热力图中,色块颜色越深代表所对应的数据增强组合方式准确率越高,首先,由实验结果对比分析可知,本文提出的 CWT 和 Welch 这种时频组合的数据增强方式在两个数据集中效果都是最好的。这是因为本文的方法把时间序列信号转化为对应的时域和频域,使得模型获得了两个不同域的视角,从而很大程度上刺激了模型对于特定辐射源之间隐藏特征的获取和学习,而加噪、旋转、翻转和平移,只会对原始信号产生一定的干扰,而不会提供额外的辐射源特征信息,并且过多的干扰甚至可能妨碍正常的网络训练;其次,在都是时频数据增强组合方式的前提下,本文提出的 CWT-Welch 的组合方式优于 CWT-FFT 的组合方式,这是因为信号中存在噪声,这会使得信号频谱中噪声的高频分量会被 FFT 放大,从而淹没有用特征;而 Welch 功率谱是将信号分段,对各段求平均,可以有效较少噪声的干扰,从而使模型在提取特征之前就能获得较纯净的频域信息,配合 CWT 时域数据增强,可以让模型有效的获得时域和频域不同的视角,从而克服了由于数据量不足

的时候,深度学习方法对于 SEI 任务识别准确率不高的问题。

3.5 超参数对比实验

不同的网络超参数对实验结果影响很大,为了得到最优的超参数,本文设计了超参数对比实验,实验结果如下。

图 9 是本文模型在 ADS-B 数据集下,1%、5%、10%、15% 和 20% 的数据比例在 0~35 个 Epoch 之间的准确率,显然,除了 1% 的数据比例外,对于数据比例的其他值,随着微调 Epoch 的增加,网络模型的识别准确率逐渐提高,并且在 Epoch 为 35 的时候达到最高点并且趋于稳定;而 Epoch 从 35 增加到 40 时,只有数据量为 1% 的情况下准确率还在增加最终稳定,因此,在小样本特定辐射源识别任务中,当数据量不足时,可以适当提高 Epoch,有助于提高识别率。

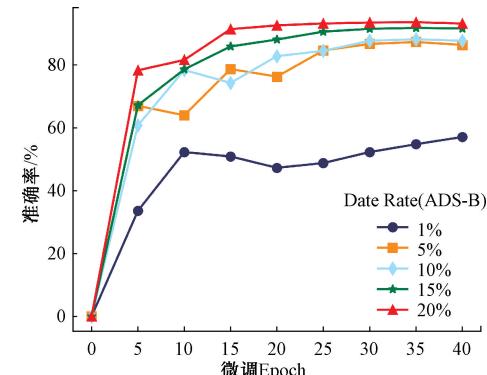


图 9 TF-SupCon 网络微调 Epochs 参数折线图

Fig. 9 Line graph of fine-tuning Epochs parameters in the TF-SupCon network

图 10 是本文模型在 ADS-B 数据集下,Batch Size 取 64、128、256 和 512 时,在不同数据比例下的准确率。从折线图中可以直观地发现,红色的折线也就是 Batch Size 为 256 时,准确率最高;还能发现,当数据量过小时,无论 Batch Size 取何值,对实验结果都无影响。

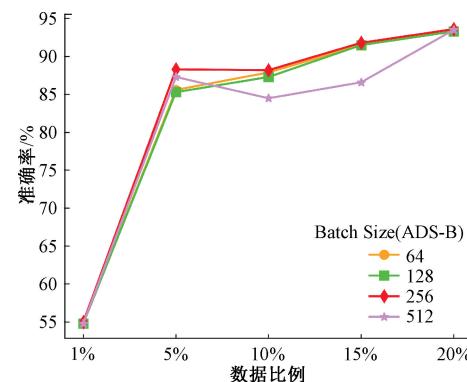


图 10 TF-SupCon 网络 Batch Size 参数折线图

Fig. 10 Line graph of the Batch Size parameter of the TF-SupCon network

图 11 是本文模型在 ADS-B 数据集下,加权和损失函数系数为 0.5,1,1.5 时,在不同数据比例下的准确率。对

于系数 q 的所有值,随着样本比例的增加,网络的识别精度逐渐提高。具体来说,当 $q = 1$ 时,TF-SupCon 在几乎所有数据比率下都实现了最佳识别性能。

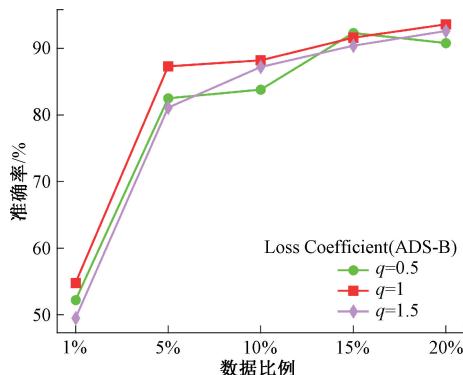


图 11 加权和损失函数系数对准确率的影响

Fig. 11 The influence of weighted sum loss function coefficients on the accuracy rate

4 结 论

目前,由于深度学习方法依赖于大规模数据进行训练,在小样本情况下 SEI 识别准确率不高的问题,本文提出了一种基于时频数据增强和对比学习的特定辐射源识别方法,该方法通过对数据进行 CWT-Welch 这种时频组合的数据增强方式,通过精心设计的两个特征提取网络以及优化的加权和损失函数,并结合对比学习微调技术,实现特定辐射源识别。通过实验验证,该方法在不同数据量集和小样本情况下,都具有更高的准确率和泛化性,且具有很高的实际应用价值。

然而在实验过程中,对于加权和损失函数中权重系数的选择问题, $q = 1$ 的设定目前主要依赖于经验性实验调参,且尚未采用自动化方法进行优化。在未来工作中我们计划尝试引入如贝叶斯优化、网格搜索或其他自动化优化方法来优化该加权系数。

参考文献

- 石涵宇, 司伟建, 夏新凡. 低信噪比下典型雷达信号调制类型识别[J]. 制导与引信, 2023, 44(4): 9-16.
- SHI H Y, SI W J, XIA X F. Identification of typical radar signal modulation types under low signal-to-noise ratio[J]. Guidance and Fuses, 2023, 44(4): 9-16.
- POLAK A C, GOECKEL D L. Identification of wireless devices of users who actively fake their RF fingerprints with artificial data distortion[J]. IEEE Transactions on Wireless Communications, 2015, 14(11): 5889-5899.
- PENG L, HU A, ZHANG J, et al. Design of a hybrid RF fingerprint extraction and device classification scheme[J]. IEEE Internet of Things Journal, 2018, 6(1): 349-360.
- 眭萍, 郭英, 李红光, 等. 半监督条件下的贝叶斯估计辐射源指纹特征识别[J]. 华中科技大学学报(自然科学版), 2018, 46(8): 71-76.
- SUI P, GUO Y, LI H G, et al. Fingerprint feature recognition of radiation sources based on Bayesian estimation under semi-supervised conditions [J]. Journal of Huazhong University of Science and Technology(Natural Science Edition), 2018, 46(8): 71-76.
- 李奇真, 刘佳旭, 梁先明, 等. 基于深度学习的跨域辐射源个体识别综述[J]. 电讯技术, 2024, 64(7): 1163-1174.
- LI Q ZH, LIU J X, LIANG X M, et al. Review of individual identification of cross-domain radiation sources based on deep learning [J]. Telecommunication Technology, 2024, 64(7): 1163-1174.
- GUO S, AKHTAR S, MELLA A. A method for radar model identification using time-domain transient signals[J]. IEEE Transactions on Aerospace and Electronic Systems, 2021, 57(5): 3132-3149.
- 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 algorithm of specific radiation sources[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 116-123.
- 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 ZH, JIA J CH, KANG J, et al. A Review of Radio Frequency Fingerprint Identification Technology Methods [J]. Radio Communication Technology, 2021, 47(3): 249-258.
- 陈沛铂. 特定辐射源智能识别技术研究[D]. 长沙: 国防科技大学, 2020.
- CHEN P B. Research on intelligent recognition technology of specific radiation sources[D]. Changsha: National University of Defense Technology, 2020.
- 王检, 张邦宁, 魏国峰, 等. 基于 Welch 功率谱和卷积神经网络的通信辐射源个体识别[J]. 电讯技术, 2021, 61(10): 1197-1204.
- WANG J, ZHANG B N, WEI G F, et al. Individual identification of communication radiation sources based on welch power spectrum and convolutional neural network[J]. Telecommunication Technology, 2021, 61(10): 1197-1204.
- 普运伟, 郭江, 刘涛涛, 等. 基于模糊函数等高线与

- 栈式降噪自编码器的雷达辐射源信号识别[J]. 仪器仪表学报, 2021, 42(1): 207-216.
- PU Y W, GUO J, LIU T T, et al. Radar radiation source signal recognition based on fuzzy function contour lines and stack-based denoising autoencoder[J]. Chinese Journal of Scientific Instrument, 2021, 42(1): 207-216.
- [12] ZHOU X, HU A, LI G, et al. A robust radio-frequency fingerprint extraction scheme for practical device recognition [J]. IEEE Internet of Things Journal, 2021, 8(14): 11276-11289.
- [13] DING L, WANG S, WANG F, et al. Specific emitter identification via convolutional neural networks [J]. IEEE Communications Letters, 2018, 22 (12): 2591-2594.
- [14] 周楷, 黄赛, 曾昱祺, 等. 基于稳态循环谱特征的通信辐射源识别方法[J]. 北京邮电大学学报, 2021, 44(3): 100-105.
- ZHOU K, HUANG S, ZENG Y Q, et al. Identification method of communication radiation sources based on steady-state cyclic spectral characteristics[J]. Journal of Beijing University of Posts and Telecommunications, 2021, 44(3): 100-105.
- [15] 韩洁, 张涛, 王欢欢, 等. 基于3D-Hibert能量谱和多尺度分形特征的通信辐射源个体识别[J]. 通信学报, 2017, 38(4): 99-109.
- HAN J, ZHANG T, WANG H H, et al. Individual identification of communication radiation sources based on 3D-Hibert energy spectrum and multi-scale fractal characteristics[J]. Journal of Communications, 2017, 38(4): 99-109.
- [16] WANG Y, GUI G, 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] QI G J, LUO J. Small data challenges in big data era: A survey of recent progress on unsupervised and semi-supervised methods[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 44 (4): 2168-2187.
- [18] YAO Y, YU L, CHEN Y. Specific emitter identification based on square integral bispectrum features[C]. 2020 IEEE 20th International Conference on Communication Technology(ICCT). IEEE, 2020: 1311-1314.
- [19] WANG Y, GUI G, 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.
- [20] 刘康晟, 凌青, 闫文君, 等. 基于WSW-KAN网络的弱标注辐射源识别算法[J]. 雷达学报, 2025, 14: 1-17.
- LIU K SH, LING Q, YAN W J, et al. Weak labeling-specific emitter identification algorithm based on the WSW-KAN network[J]. Journal of Radars, 2025, 14: 1-17.
- [21] 张立民, 谭凯文, 闫文君, 等. 基于持续学习和联合特征提取的特定辐射源识别[J]. 电子与信息学报, 2023, 45(1): 308-316.
- ZHANG L M, TAN K W, YAN W J, et al. Identification of specific radiation sources based on continuous learning and joint feature extraction[J]. Journal of Electronics & Information Technology, 2023, 45(1): 308-316.
- [22] WANG Y, GUI G, GACANIN H, et al. Transfer learning for semi-supervised automatic modulation classification in ZF-MIMO systems[J]. IEEE Journal on Emerging and Selected Topics in Circuits and Systems, 2020, 10(2): 231-239.
- [23] DONG Y, JIANG X, 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.
- [24] GONG J, XU X, QIN Y, et al. A generative adversarial network based framework for specific emitter characterization and identification [C]. 2019 11th International Conference on Wireless Communications and Signal Processing(WCSP). IEEE, 2019: 1-6.
- [25] HUANG K, LIU H, HU P. Deep learning of radio frequency fingerprints from limited samples by masked autoencoding [J]. IEEE Wireless Communications Letters, 2022: 1-1, DOI:10.1109/LWC.2022.3184674.
- [26] FU X, PENG Y, LIU Y, et al. Semi-supervised specific emitter identification method using metric-adversarial training [J]. IEEE Internet of Things Journal, 2023, 10(12): 10778-10789.
- [27] 袁晔, 汤春阳, 张博轩, 等. 融合时频特征的通信辐射源个体识别方法[J]. 电子测量技术, 2025, 48(1): 129-136.
- YUAN Y, TANG CH Y, ZHANG B X, et al. Individual identification method of communication radiation sources integrating time-frequency characteristics [J]. Electronic Measurement Technology, 2025, 48(1): 129-136.
- [28] CHEN T, KORNBLITH S, NOROUZI M, et al. A

- simple framework for contrastive learning of visual representations [C]. International Conference on Machine Learning. PMLR, 2020: 1597-1607.
- [29] 任洪兵, 彭宇明, 黄海波. 基于监督对比学习和混合注意力残差网络的隔膜泵单向阀故障诊断[J]. 机电工程, 2024, 41(4): 594-603.
REN H B, PENG Y B, HUANG H B. Fault diagnosis of diaphragm pump check valve based on supervised contrastive learning and hybrid attention residual network [J]. Mechanical and Electrical Engineering, 2024, 41(4): 594-603.
- [30] TANG C, LIAN J, ZHENG L, et al. Specific emitter identification method for limited samples via time-wavelet spectrum consistency [J]. Sensors, 2025,

25(3): 648.

作者简介

黄逸飞,硕士研究生,主要研究方向为特定辐射源识别,复杂网络分析。

E-mail:1042724208@qq.com

闫光辉(通信作者),教授,博士生导师,博士,主要研究方向为数据库理论与系统,智能信息处理,数据挖掘,复杂网络分析。

E-mail:yanghacademic@163.com

郑礼,讲师,博士研究生,主要研究方向为无线通信、频谱感知及复杂网络分析。

E-mail:zhengli3227@163.com

汤春阳,硕士,主要研究方向为人工智能、软件无线电方向。