

基于 CNN-FAN 的辐射源个体开集识别

温金莹, 谢跃雷, 刘祥国

(桂林电子科技大学信息与通信学院, 桂林 541004)

摘要: 针对开放电磁环境下的未知辐射源识别问题, 提出了一种基于卷积神经网络-傅里叶分析网络 (Convolutional neural network-Fourier analysis network, CNN-FAN) 模型的开集识别 (Open-set recognition, OSR) 方法。该方法首先通过引入傅里叶分析网络 (Fourier analysis network, FAN) 网络层, 利用傅里叶级数的特性有效提取信号的频率分量, 与卷积神经网络结合构成 CNN-FAN 网络模型, 然后采用 OpenMax 代替 Softmax 层构成开集识别模型, 最后采用中心损失函数组合交叉熵损失函数联合优化模型性能, 减少辐射源个体特征距离类间差距, 提高个体分类效果, 使用 OpenMax 异常值检测算法进行已知类和未知类之间的区分。在开源 WiSig 数据集上对所提方法在不同开放度下进行性能验证和实验分析, 实验结果表明, 所提方法在开放度为 0.057 时识别率达到 95%, 开放度为 0.184 时的开集识别率仍有 84%, 优于其他开集识别方法。

关键词: 辐射源个体识别; 开集识别; 深度学习; 卷积神经网络; 傅里叶分析网络

中图分类号: TN911.7; TP183

文献标志码: A

引用格式: 温金莹, 谢跃雷, 刘祥国. 基于 CNN-FAN 的辐射源个体开集识别[J]. 数据采集与处理, 2026, 41(4): 1041-1057. WEN Jinying, XIE Yuelei, LIU Xiangguo. Open-set specific emitter identification based on CNN-FAN [J]. Journal of Data Acquisition and Processing, 2026, 41(4): 1041-1057.

引言

随着无线通信技术的快速发展, 辐射源个体识别 (Specific emitter identification, SEI) 成为无线网络安全、电子对抗和频谱管理等领域的核心技术^[1-3]之一。所有的电子器件都会有不同程度的缺陷, 这些缺陷会对信号形成无意识调制, 也被称为射频指纹, 即使使用相同型号、同一批次的电子器件间的射频指纹也互不相同, 因此根据这一特点可以实现辐射源的个体识别^[4]。传统辐射源识别研究多基于闭集假设, 即假设测试数据中的辐射源个体均在训练集中出现过。然而, 实际应用中, 电磁环境复杂多变, 存在大量未知的辐射源个体信号, 传统的闭集识别方法因无法有效拒绝未知样本而导致误判率升高, 严重制约了系统在开放环境下的实用价值。因此, 辐射源个体开集识别 (Open-set recognition, OSR) 成为近年来的研究热点^[5-6]。

目前的辐射源个体开集识别方法大多采用基于阈值的分类机制^[7], 在决策分类识别器中使用经验设置的阈值, 将输入样本拒绝或分类为某些已知类, 此过程中阈值起着关键作用。Hanna 等^[8]采用一个和多个二进制分类器、多分类器和信号重建的方法对未授权的发射机进行开集识别检测, 实验对 10 个授权、50 个未授权的 WiFi 发射器进行验证时, 结果显示针对同一天的测试集, 未授权的 WiFi 的检测精度可以达到 98%, 不在同一天的测试集上则可达到 80% 精度。Xie 等^[9]提出了一个超球体表示法, 以实

现设备之间在其射频指纹(Radio frequency fingerprinting, RFF)的余弦距离度量上的最大距离,由此产生的RFF可直接用于区分已知或未知设备,甚至用于离群点检测和新设备发现。Wang等^[10]提出通过希尔伯特-施密特独立准则(Hilbert-Schmidt independence criterion, HSIC)融合监督与无监督信息,实现新旧类别的有效区分。刘人玮等^[11]针对通信辐射源个体开集识别问题,将接收到的信号输入至卷积原型网络,经ResNet50特征提取层计算特征点,利用自适应距离分类规则为每个类别学习距离阈值,并通过距离阈值完成对已知目标的分类和未知目标的检测。结果表明,该方法在开集识别场景下比传统卷积神经网络(Convolutional neural network, CNN)预测概率更有优势:数据集含5个已知辐射源个体、2个未知辐射源个体,单信噪比下每类1 000个训练样本、500个测试样本,其归一化准确率较传统CNN提升约20%。杨柳等^[12]提出一种基于计算特征子空间投影比值的开集多重信号分类(Open-multiple signal classification, Open-MUSIC)算法,通过神经网络获得已知类特征表示,以特征矩阵在矩阵的两个正交子空间的投影比值为指标,判决是否为已知辐射源信号样本,对9个无人机个体识别信号数据集的OSR正确率达到91.11%。

为了使支持向量机、稀疏表示、K-均值聚类这些方法适应辐射源个体OSR方案,研究员们做了许多努力。赵妮^[13]提出基于一类支持向量机(One-class support vector machine, OCSVM)的开集识别模型,将雷达辐射源信号测试样本输入闭集训练模型中得到Softmax概率输出,根据概率计算信心分数使用OCSVM判别是否为“异常”样本,是则记为未知类别,不是则输出其类别。Yang等^[14]提出结合深度支持向量数据描述(Support vector data description, SVDD)算法训练模型获取单分类能力,再通过构建高维空间中的超球面,将目标样本紧密包裹,非目标样本被排除在超球面外,实现开集识别中“识别已知目标、排除未知非目标”的核心需求。严科^[15]通过搭建异常检测和K-means聚类模型实现辐射源信号已知类还是未知类的识别,实验对实地采集的广播式自动相关监视(Automatic dependent surveillance-broadcast, ADS-B)数据做分类,闭集识别率达到95%左右,对未知个体判别能力达到93%。尽管以上研究取得了许多重要的突破,然而开集识别的方法还需进一步地与辐射源识别的场景融合,辐射源的开集识别还有待进一步研究。

针对开放环境下的辐射源个体开集识别,本文首先在传统神经网络的辐射源个体识别技术的基础上,引入傅里叶分析网络(Fourier analysis network, FAN)网络层,结合CNN构建CNN-FAN网络。然后利用OpenMax将CNN-FAN网络进一步改进为开集网络模型,通过对CNN-FAN网络倒数第2层的激活向量进行极值理论建模,能够有效区分已知类别与未知样本的概率分布,显著降低对未知样本的误判风险。为进一步优化辐射源个体特征空间的判别性,采用交叉熵损失和中心损失的联合监督来训练CNN-FAN开集网络进行区分性特征学习。该机制通过动态更新类中心向量,并最小化深度特征与其对应类中心的距离,有效增强了类间可分性,改善了开集环境下的未知样本检测能力,能够在保证已知个体识别准确率的前提下有效识别未知辐射源个体。

1 CNN-FAN网络

1.1 FAN层结构模型

为了有效理解数据中的周期性规律,Dong等^[16]通过引入傅里叶级数的思想,将周期性信息直接嵌入网络的结构中,构成了一种新型网络架构FAN。FAN是自定义特征增强层,通过极坐标编码 $\cos(\rho)$ 、 $\sin(\rho)$ 和非线性激活,让模型更高效地学习辐射源信号的周期性特征,使模型更自然地捕捉和理解数据中的周期性模式。傅里叶分析是一个数学框架,它将函数分解成它们的组成频率,揭示复杂函数中潜在的周期结构。傅里叶级数是其分析的核心,它将周期函数表示为正弦和余弦项的无限和式。数学上,对于函数 $f(x)$,它的傅里叶级数展开式可以表示为^[16]

$$f(x) = a_0 + \sum_{n=1}^{\infty} \left(a_n \cos\left(\frac{2\pi nx}{T}\right) + b_n \sin\left(\frac{2\pi nx}{T}\right) \right) \quad (1)$$

式中: T 为函数的周期; 系数 a_n 和 b_n 由函数在一个周期内的积分决定^[16], 即

$$a_n = \frac{1}{T} \int_0^T f(x) \cos\left(\frac{2\pi nx}{T}\right) dx \quad (2)$$

$$b_n = \frac{1}{T} \int_0^T f(x) \sin\left(\frac{2\pi nx}{T}\right) dx \quad (3)$$

傅里叶级数能够表示各种各样的函数, 包括通过周期扩展的非周期函数, 从而能够提取频率分量, 利用傅里叶级数的这一特性, FAN旨在将周期性特征直接嵌入到网络架构中, 增强各种任务的泛化能力和性能, 特别是在需要识别模式和规律的场景中。

首先构建一个简单的神经网络, 用傅里叶级数的公式建模, 然后在此基础上设计FAN模型。考虑一个涉及输入输出对 $\{x_i, y_i\}$ 的任务, 其目标是确定一个函数 $f(x): \mathbf{R}^{d_x} \rightarrow \mathbf{R}^{d_y}$, 该函数近似于所有 x_i 的关系, 使得 $y_i \approx f(x_i)$, 其中 d_x 和 d_y 分别表示 x 和 y 的维度。建立一个简单的神经网络 $f_s(x')$, 表示函数的傅里叶级数展开, 如式(1)所示的 $F\{f(x')\}$, 为构建一个简单的神经网络 $f_s(x')$ 表示函数的傅里叶级数展开, 将 $f_s(x')$ 表示为^[16]

$$\begin{aligned} f_s(x') &= a_0 + \sum_{n=1}^N \left(a_n \cos\left(\frac{2\pi nx'}{T}\right) + b_n \sin\left(\frac{2\pi nx'}{T}\right) \right) \stackrel{(I)}{=} a_0 + \sum_{n=1}^N \left(w_n^c \cos(w_n^{\text{in}} x') + w_n^s \sin(w_n^{\text{in}} x') \right) \stackrel{(II)}{=} \\ &B + [w_1^c, w_2^c, \dots, w_N^c] \cos([w_1^{\text{in}} \| w_2^{\text{in}} \| \dots \| w_N^{\text{in}}] x') + [w_1^s, w_2^s, \dots, w_N^s] \sin([w_1^{\text{in}} \| w_2^{\text{in}} \| \dots \| w_N^{\text{in}}] x') = \\ &B + W_c \cos(W_{\text{in}} x') + W_s \sin(W_{\text{in}} x') \stackrel{(III)}{=} B + W_{\text{out}} [\cos(W_{\text{in}} x') \| \sin(W_{\text{in}} x')] \end{aligned} \quad (4)$$

设计FAN有两个原则:

(1) FAN表示傅里叶系数的能力应与其深度正相关, 通过利用FAN的深度增强了其周期性建模的表现力;

(2) 任何隐藏层的输出都可以通过后续层使用傅里叶级数来建模周期性, 确保FAN中间层的特征可用于执行周期性建模。

假设将 $f_s(x)$ 解耦为^[16]

$$f_s(x') = f_{\text{out}} \circ f_{\text{in}} \circ x' \quad (5)$$

其中

$$f_{\text{in}}(x') = [\cos(W_{\text{in}} x') \| \sin(W_{\text{in}} x')] \quad (6)$$

$$f_{\text{out}}(x') = B + W_{\text{out}} x' \quad (7)$$

为了满足这两个原则, FAN的中间层输入需要同时使用 f_{in} 和 f_{out} , 而不是依次应用它们。

最终, FAN基于此设计, 其FAN层 $\phi(x')$ 定义如下^[16]

$$\phi(x') = [\cos(W_p x') \| \sin(W_p x') \| \sigma(B_{\bar{p}} + W_{\bar{p}} x')] \quad (8)$$

式中: $W_p \in \mathbf{R}^{d_x \times d_p}$, $W_{\bar{p}} \in \mathbf{R}^{d_x \times d_{\bar{p}}}$, $B_{\bar{p}} \in \mathbf{R}^{d_{\bar{p}}}$ 是可学习参数, 输出层 $\phi(x') \in \mathbf{R}^{2d_p + d_{\bar{p}}}$ 。 d_p 控制周期特征(正弦和余弦分量)的维度, 对应矩阵 W_p 的第1维度, d_p 是该网络中最关键的超参数, 用于平衡周期特征与非周期特征的比例, 直接影响网络对周期性建模能力, 需要根据具体任务来调整; $d_{\bar{p}}$ 是非周期特征部分的维度, 对应矩阵 $W_{\bar{p}}$ 的第1维度, 用于处理被激活函数处理过的非周期特征, $d_{\bar{p}}$ 通过保留非周期特征维度, 保证FAN的周期性建模, 维持了对非周期模式的拟合能力, 还保留了多层感知器(Multilayer perceptron, MLP)的通用建模能力; σ 表示激活函数。这可以进一步增强其对周期性建模的表达能力, 完整的

FAN通过堆叠FAN层构成深层网络,如图1所示。




图1 FAN层模型结构

Fig.1 Structure of the FAN layer model

1.2 CNN-FAN模型结构

卷积神经网络一般由卷积层、激活层、池化层、全连接层和 Softmax 层构成,能够从原始信号中学习到有效的特征表示,避免了人工特征提取的局限性。CNN^[17]的全连接层一般采用 MLP 模型,然而,传统 MLP 在模型复杂性与任务适应性上存在一些局限:(1)MLP 依赖固定神经元激活函数,难以动态适配不同数据分布,易因参数冗余导致过拟合;(2)其全连接结构在长序列或高维数据处理时计算复杂度呈指数增长,且缺乏对特征间稀疏关联的建模能力;(3)MLP 的可解释性不足,难以揭示输入特征与输出决策间的显式关联。这些问题限制了 CNN 在复杂场景中的应用效能,使得利用 CNN 处理辐射源信号时,对频域信息的挖掘不够深入。辐射源信号包含丰富的时域和频域信息,频域特征对于区分不同辐射源个体往往具有关键作用。CNN 模型主要侧重于时域特征的提取,虽然也能间接学习到一些频域信息,但缺乏对频域特征的深度挖掘,导致在复杂电磁环境下的识别性能受到限制。

为了缓解 MLP 对含周期性的辐射源信号无法显式利用先验且易丢失细微特征的问题,可以充分挖掘辐射源信号的频域特征,引入 FAN 层模型,先将信号分解为不同频率的分量,再借网络结构学习处理这些分量,提取更具代表性的频域特征,这样可以解决传统 MLP 对信号特征敏感度过低的问题。将 FAN 与 CNN 相结合构建 CNN-FAN 网络模型,如图 2 所示,CNN-FAN 模型在 CNN 模型的基础上将卷积后输出的相关特征提取层替换为改进后的 FAN 层,利用 FAN 对频域信息的强大建模能力,可增强 CNN 对辐射源信号频域特征的学习能力,进行全局特征转换与增强,最后通过一层全连接层对个体做分类。




图2 CNN-FAN模型结构

Fig.2 CNN-FAN model structure

为体现 CNN-FAN 的识别性能,对 CNN、FAN、CNN-FAN 在不同信噪比(Signal-to-noise ratio, SNR)加性高斯白噪声环境下进行了对比实验,对原始辐射源个体的 I/Q 两路信号加上一组信噪比为 $-10:2:30$ dB 的高斯白噪声,模拟噪声环境,再将加噪的信号使用这 3 个网络进行预测,如图 3 所示,在添加噪声后 3 种模型的准确率都会有所下降,总体上 CNN-FAN 的识别率高于其余两种模型,从而体现了 FAN 的性能优势,与传统的 CNN 相比,改进后的全连接层即替换成 FAN 后, CNN-FAN 的性能更优,说明了 FAN 层的周期性建模能力对辐射源个体信号的特征提取有一定的优势。

2 本文算法

2.1 OpenMax 开集识别

为解决辐射源开放集识别问题,采用 OpenMax^[18-19]

分类器来替换卷积神经网络最后的 Softmax 层。OpenMax 是一种对 Softmax 进行改进的算法,旨在解决开集识别问题,即识别出训练集中未出现的未知类别样本。在传统的 Softmax 算法中,模型假设所有测试样本都来自训练集中的已知类别,通过计算样本属于各个已知类别的概率来进行分类。然而,在实际应用中,当遇到未知类别样本时,Softmax 算法往往会将其错误地分类为某个已知类别,导致识别错误。

OpenMax 算法是一种简洁且轻量级的开放集识别算法,其核心思想在于引入了对未知类别的处理能力。它不再仅仅依赖于 Softmax 的概率分布来划分样本到已知类别,而是引入了一种更为灵活的机制,即 OpenMax 层采用了极值分布来描述已知类别的统计属性。这种分布能够捕捉已知类别数据中的极端情况,从而更准确地描述它们的边界。基于这种分布,OpenMax 能够估算出测试样本属于已知类别和未知类别的概率。与 Softmax 相比,OpenMax 层最显著的特点在于它增加了一个额外的输出。这个输出不再是一个简单的类别标签,而是一个概率值,表示测试样本不属于任何已知类别的可能性。这个额外输出的引入,使得 OpenMax 能够更全面地评估测试样本的归属情况,不仅仅局限于已知的类别范围。图 4 的 OpenMax 是对 Softmax 的改进,在原有 N 个已知类别基础上,增加了“ $N+1$ ”个的未知类别分支。

OpenMax 识别原理如下:

首先,在模型训练阶段,对于训练集中每个样本,通过神经网络的倒数第 2 层(全连接层)提取激活向量(Activation vector, AV),仅保留被正确分类的样本的 AV。对每个类别的所有正确分类的 AV 求均值,得到各类的均值激活向量(Mean activation vector, MAV)。例如,类别 i 的 MAV 为

$$L_{MAV_i} = \frac{1}{n_i} L_{AV_j^i} \quad (9)$$

式中 n_i 为类别 i 的正确分类样本数。

然后构建距离集并拟合 Weibull 分布,计算每个类别内所有 AV 到其 MAV 的欧式距离,得到距离集

$$D_i = [d_1, d_2, \dots, d_{n_i}] \quad (10)$$




图3 不同信噪比下3种模型的预测结果

Fig.3 Prediction results of three models under different SNRs




图4 OpenMax 和 Softmax

Fig.4 OpenMax and Softmax

对每个 D_i 的尾部极大值进行 Weibull 分布拟合, 得到累积分布函数 (Cumulative distribution function, CDF)

$$\text{CDF}(d; \lambda, k) = 1 - \exp\left(-\left(\frac{d}{\lambda}\right)^k\right) \quad (11)$$

式中 λ (尺度参数) 和 k (形状参数) 通过极大似然估计拟合得到。

在测试样本的阶段: 输入一个测试样本, 得到其激活向量 L_{AV} , 计算该激活向量到所有已知类别 L_{MAV} 的欧式距离 $d_1, d_2, \dots, d_N$, 将这 N 个距离分别代入各类拟合好的 CDF 函数中, 得到 N 个概率

$$p_i = \text{CDF}_i(d_i) \quad i = 1, 2, \dots, N \quad (12)$$

这 N 个概率分别代表此测试样本 L_{AV} 到 L_{MAV} 的距离出现在各类距离集中的概率, 表示测试样本属于类别 i 的概率。修正权值为 $1 - p_i$, 表示不属于类别 i 的概率。对原始 Softmax 得分进行修正, 得到调整后的得分

$$s'_i = s_i \times (1 - p_i) \quad (13)$$

未知类别的概率为所有已知类别得分消减值之和

$$s_{\text{unknown}} = \sum_{i=1}^N (s_i - s'_i) = \sum_{i=1}^N s_i \times p_i \quad (14)$$

然后得分向量由修正后的已知类别得分和未知类别得分组成

$$L_{\text{OpenMax}_i} = \begin{cases} s_i \times (1 - p_i) & i \text{ 为已知类} \\ \sum_{i=1}^N s_i \times p_i & i \text{ 为未知类} \end{cases} \quad (15)$$

最终生成 $N+1$ 维的 L_{OpenMax} 得分向量 $[s'_1, s'_2, \dots, s_{\text{unknown}}]$, 根据 L_{OpenMax} 得分向量, 选择最高得分的类别, 若为 unknown 则判定为未知类。

重复以上步骤, 就可以获取新的激活向量。此向量充分考虑了数据归属于未知类或不确定类别的概率情况, 经 Softmax 层归一化处理后生成相应的概率分布。对于一个已知类别为 N 的网络, 输入特征倘若在 $N+1$ 维度上概率值达到最大, 则该数据极有可能源自未知个体, 进而会被打上为未知标签。通过这样的流程, OpenMax 分类器便可以实现开放集的识别。

2.2 联合损失函数

在深度学习中, 传统的交叉熵 (Cross-entropy, CE) 损失主要关注不同类别之间的可分性, 通过最大化正确分类的概率来训练模型。然而, 仅使用交叉熵损失无法确保同一类别的样本在特征空间中相对集中, 这可能导致在处理复杂的辐射源信号时, 模型对同类辐射源的识别能力下降。

交叉熵损失函数表达式为

$$L_{\text{CE}} = -\frac{1}{m} \sum_{i=1}^m [y_i \ln \hat{y}_i + (1 - y_i) \ln (1 - \hat{y}_i)] \quad (16)$$

式中: m 表示样本的个数; y_i 和 $\hat{y}_i$ 分别表示模型第 i 个样本输出的真实分类值和预测分类值。

为了使同类样本之间更加紧凑, 不同样本之间更加分散, 本文在神经网络的交叉熵损失函数中加入中心损失。中心损失是一种用于增强深度神经网络特征分布的损失函数, 其核心目标是约束类内紧凑性, 即让同一类别的样本在特征空间中更加紧密地聚集在一起, 在训练过程中学习每个类的深度特征的中心, 并最小化深度特征与其对应类中心的距离。利用中心损失这一特性, 采用交叉熵损失和中心损失的联合监督下训练神经网络, 并引入一个超参数来平衡两个损失函数。直观上, 交叉熵损失迫使不同类的深层特征保持分离, 中心丢失有效地将同一类的深层特征拉到它们的中心。在联合监督下, 不仅扩大了类间特征差异, 而且减小了类内特征差异。因此, 深度学习的特征的区分能力可以被高

度增强。另外对比损失^[20]和三元组损失^[21]也被提出来增强深度学习的特征区分能力,但是当从训练集构成样本对或样本三元组时,对比损失和三元组损失都遭受急剧的数据膨胀,而中心损失与交叉熵损失并且不需要复杂的训练样本重组,更易于实现,且此方法更直接地针对类内聚集的学习目标,是一种非常有益的特征分类方法。

中心损失的定义基于每个类别的特征中心,对于每个类别 k ,定义其特征中心 c_k ,对于属于类别 k 的样本 i ,其特征向量为 x_i ,中心损失的计算公式为

$$L_C = \frac{1}{2m} \sum_{i=1}^m \|x_i - c_{y_i}\|_2^2 \quad (17)$$

式中: m 是样本数量, y_i 是样本 i 的真实类别标签, c_{y_i} 表示第 y_i 个类别的深层特征的中心,该参数表征了类内变化。这个公式的含义是让每个样本的特征向量尽量靠近其所属类别的特征中心,从而实现类内紧凑性的约束。

L_C 相对于 x_i 的梯度和 c_{y_i} 的更新方程计算为

$$\frac{\partial L_C}{\partial x_i} = x_i - c_{y_i} \quad (18)$$

$$\Delta c_j = \frac{\sum_{i=1}^m \delta(y_i=j) \times (c_j - x_i)}{1 + \sum_{i=1}^m \delta(y_i=j)} \quad (19)$$

式中:如果 $y_i=j$ 则 $\delta(y_i=j)=1$,反之则 $\delta(y_i=j)=0$ 。

如果仅使用交叉熵损失函数来训练分类,会造成类内距离相对较大,或者仅使用中心损失,深层特征和特征中心会衰减为0,所以只使用其中任何一个损失函数都不能有效地实现区分性特征学习。因此,将它们联合起来共同监督网络训练,既能区分类间又能使类内紧凑,故本文采用交叉熵损失和中心损失的联合监督来训练神经网络进行区分性特征学习,即

$$L = L_{CE} + \lambda L_C = -\frac{1}{m} \sum_{i=1}^m [y_i \ln \hat{y}_i + (1 - y_i) \ln (1 - \hat{y}_i)] + \frac{\lambda}{2m} \sum_{i=1}^m \|x_i - c_{y_i}\|_2^2 \quad (20)$$

式中,标量 λ 是一个超参数,用于控制中心损失在总损失中的权重。通过调整 λ 的大小,可以平衡类内紧凑性和类间分离性的优化程度。在辐射源个体识别中,合理调整 λ 能够使模型更好地学习到辐射源信号的特征,提高对同类辐射源信号的聚类能力和对不同类辐射源信号的区分能力。如果 λ 设置为0,则传统的交叉熵损失可以被认为这种联合监督的特殊情况, λ 越大,则特征聚集效果越好,但会在一定程度上影响分类正确率,为保证分类前提下有更好的聚集效果方便用于开集识别,设置 λ 为1^[22]。

为进一步评估交叉熵损失加入中心损失后在噪声环境下的识别性能,对两种识别方法在不同信噪比加性高斯白噪声环境下进行实验,对测试集数据I/Q信号加上一组信噪比为 $-10:2:30$ dB的高斯白噪声来模拟噪声环境,将加了噪声的信号代入网络进行开集识别来评估本文算法在噪声环境下的识别性能,预测结果如图5所示。很显然,加入中心损失后的识别准确率更高。

2.3 基于CNN-FAN模型的辐射源开集识别算法

在CNN-FAN模型基础上做开集识别,所提的Open-




图5 不同信噪比下两种方法对模型预测结果图
Fig.5 Prediction results of two methods for the model under different SNRs

Max 和联合损失函数的辐射源个体开集识别算法结构如图 6 所示,流程图及算法如下所述。




图6 所提OSR算法框图

Fig.6 Block diagram of the proposed OSR algorithm

算法1 基于CNN-FAN模型的辐射源OSR方法

训练阶段:

输入:提取模型倒数第2层的输出作为激活向量 L_{AV} , $L_{AV}^{train} = [L_{AV_1}^{train}, L_{AV_2}^{train}, \dots, L_{AV_N}^{train}]$

输出: L_{MAV_i} 和 Weibull 模型

- (1)遍历所有类别:对 i 从1到 N (包括所有 N 个类别)执行以下操作;
- (2)计算平均激活向量 $L_{MAV_i} = 1 / \left(n_i \sum_{j=1}^{n_i} L_{AV_j} \right)$, n_i 是类别 i 的正确分类样本数;
- (3)拟合 Weibull 分布,得到距离集 $D_i = \{d_1, d_2, \dots, d_{n_i}\}$,累积分布函数 CDF。

测试阶段:

输入: $L_{AV}^{test} = [L_{AV_1}^{test}, L_{AV_2}^{test}, \dots, L_{AV_N}^{test}]$, N 个 Weibull 模型和 L_{MAV_i} , 原始 Softmax 得分

输出:识别结果类别:1, 2, ..., n , $n+1$

- (1)计算 L_{AV}^{test} 到已知类 L_{MAV_i} 的 $D_i = \{d_1, d_2, \dots, d_N\}$
- (2)将 N 个距离代入各类拟合的 CDF 函数,得到 N 个 $p_i = L_{CDF_i}(d_i)$, $i = 1, 2, \dots, N$
- (3) p_i 为测试样本属于类别 i 的概率, $1 - p_i$ 为不属于类别 i 的概率,修正原始得分 Softmax:
 $s_i \rightarrow s'_i = s_i \times (1 - p_i)$

- (4)计算未知类别的概率为所有已知类别得分消减值之和: $S_{unknown} = \sum_{i=1}^N (s_i - s'_i) = \sum_{i=1}^N s_i \times p_i$

- (5)修正得分向量: $L_{Openmax_i}$

- (6) $N+1$ 维的 OpenMax 得分向量 $[s'_1, s'_2, \dots, s_{unknown}]$, unknown 被判为未知类。

3 实验结果与分析

3.1 数据来源

本文所做实验采用开源数据集 WiSig 数据^[23], 包含从 174 个现成的 WiFi 发射器和 41 个通用软件无线电外设 (Universal software radio peripheral, USRP) 接收器捕获的 1 000 万个数据包数据, 原文作者验证了此数据集可用来解决射频指纹识别的一些开放问题。本文将采用其中使用同一接收机采集的来自 8 个不同的发射机经信道均衡后的个体数据, 每个个体包含 800 段有效信号, 每一段有效信号为长度为 256 的 IQ 数据。图 7 展示了其中 3 个个体 IQ 信号波形。




图7 3个不同个体IQ信号波形

Fig.7 IQ signal waveforms of three different individuals

3.2 数据集制作

首先将每个个体的I路信号和Q路信号做能量归一化,将长度为256的两路IQ信号拼接成 256×2 大小的二维信号作为网络的输入数据。每个个体数据按4:1随机划分为训练集和测试集,由于这8个个体每个个体有800段有效信号,故每个个体随机选取其中640段信号作为训练集,另外160段信号作为测试集。通过训练集与测试集中标签类别的数量关系来定义开集任务的开放程度,开放度^[24]定义为

$$O=1-\sqrt{\frac{2\times |N_{\text{TR}}|}{|N_{\text{TR}}|+|N_{\text{TE}}|}}$$

(21)

式中: N_{TR} 为训练集中的类别数, N_{TE} 为测试集中的类别数。两者相等时开放度为0,表示闭集识别。

3.3 环境配置

本实验的神经网络模型运行在一台型号为Intel(R) Xeon(R) Platinum 8352V的CPU、内存64 GB、显卡为NVIDIA GeForce RTX4090的Windows 11系统的电脑上,实验平台使用基于CUDA 12.2、cuDNN 8、Python3.10环境的深度学习框架Pytorch 2.1.1。

实验中,采用标注数据集进行模型训练,相关训练参数设定:Epochs=20、Batch_size=64、Adam 优化器、学习率设置为0.001,经超参优化后选取最优模型实施测试集验证。

3.4 模型设置

本文主要对信号原始IQ数据做分类识别,具体网络组成和主要参数如表1所示。
表1中,Conv(5,(3,1),(1,1))表示通道数为5,卷积核尺寸为 3×1 ,步长为 1×1 的二维卷积核;

表1 模型结构

Table 1 Model structure

CNN	FAN	CNN-FAN
Input(256,2)	Input(256,2)	Input(256,2)
[Conv(5,(3,1),(1,1)) ReLU MaxPool(2,1)] $\times 2$	Flatten FAN(512,64) Linear(64,8)	[Conv(5,(3,1),(1,1)) ReLU MaxPool(2,1)] $\times 2$
Flatten		Flatten
Linear(320,64)		FAN(320,64)
Linear(64,8)		Linear(64,8)

ReLU表示ReLU激活函数;MaxPool(2,1)表示尺寸为 2×1 的最大池化层;Flatten表示卷积后展平为一维向量,展平后用于全连接层的分类;Linear表示线性全连接层;FAN则为图2所示FAN层模型结构。将模型结构对比可知,构建的CNN-FAN模型是在CNN模型的基础上将卷积后输出的相关特征提取层替换为改进后的FAN层,最后通过一层全连接层对个体做分类,FAN层的输入维度是根据具体任务来调整的,本文用的CNN-FAN网络参数如表1所示。

3.5 实验结果

3.5.1 阈值选取

实验使用表1中训练好的CNN-FAN模型,在训练阶段使用8个已知辐射源个体,测试阶段使用的测试数据集为训练数据集添加两个未知辐射源个体,根据式(20)计算可知此时的开放度为0.057。使用OpenMax分别对只使用交叉熵损失和联合交叉熵损失和中心损失的CNN-FAN网络模型进行开集识别,在不同阈值下的开集识别正确率如图8所示。

当测试集样本属于已知类别的概率大于阈值时,将其分类为相应的已知类别,否则将其判定为未知类别,阈值的取值范围为 $[0,1]$ 。从图8可以看出,当阈值最小设为0时将测试集全部样本判为已知类,测试集中包含8个已知类和两个未知类,故此时正确率约为80%,当阈值最大设为1时将测试集全部样本判为未知类,测试集中包含8个已知类和两个未知类,故此时正确率约为20%,当阈值为0.7时的两种方法识别正确率均达到最大,故本文将OpenMax阈值设置为0.7。

只使用交叉熵损失函数的OpenMax开集识别率有85%左右,联合了交叉熵损失与中心损失的开集识别率可达到94.87%。

3.5.2 联合损失效果可视化

为了直观体现加了中心损失后对特征的聚集效果,对训练好后的模型提取倒数第2层的输出作为个体特征,其特征经 t -分布领域嵌入算法(t -distributed stochastic neighbor embedding, t -SNE)^[25]。 t -SNE是一种非线性降维算法,它可以将高维数据映射到低维空间,同时保持数据间的相对距离不变,通常用于可视化高维数据,从而可以通过图形的方式展示数据的特征,个体特征可视化后的映射点如图9所示。其中图9(a)为只使用交叉熵损失函数的网络分类情况,图9(b)为联合交叉熵损失函数与中心损失共同监督训练的特征分布情况,二者比较,使用交叉熵损失和中心损失监督训练输出的特征映射图效果更好,有效区分不同类别,使相同的类别更加聚集,可见在加入了中心损失后特征具有明显的聚集效果。

测试阶段加入两个未知个体,同样提取倒数第2层的输出作为个体特征,其特征经 t -SNE可视化,此时特征映射图如图10所示。图中棕色部分为加入的未知个体数据,其余8种颜色为训练中出现过的已知个体数据,图10(a)为只使用交叉熵损失函数的网络分类情况,图10(b)为联合交叉熵损失函数与中心损失共同监督训练的特征分布情况,在加入了中心损失后特征具有明显的聚集效果,且在加入未知个体数据后,不仅已知个体划分清晰,对于未知的两个个体数据也有一定的聚集效果,更有利于开集判别。




图8 两种识别方法在开放度为0.057不同阈值下的OSR正确率

Fig.8 OSR accuracy rates of the two recognition methods at different thresholds at the 0.057 openness




图9 训练后网络倒数第2层特征映射图

Fig.9 Feature map of the penultimate layer of the network after training




图10 测试时网络倒数第2层特征映射图

Fig.10 Feature map of the penultimate layer of the network during testing

3.5.3 不同开放度下识别效果

上述实验仅在测试集包含8个已知个体和两个未知个体的情况下进行,为了验证本文方法在不同开放度下的识别效果,固定训练集中包含的辐射源个体类别数为8,测试集在包含8个已知个体的前提下分别加入1、2、3、4、5、6、7、8个未知的辐射源个体,对应的开放度分别为0.039、0.057、0.082、0.106、0.127、0.147、0.166、0.184,本文所提方法在不同开放度下的特征映射图如图11所示。

图11中棕色部分为未知个体特征映射点,其余8种颜色为已知的8个个体特征映射点。图11(a~h)分别对应测试集在包含8个已知个体的前提下加入1、2、3、4、5、6、7、8个未知的辐射源个体。根据不同开放度下的特征映射图可以看出,随着未知个体数量增加,特征映射图越来越混杂,但总体来看训练集中训练过的8个已知个体仍然具有可观的个体分类和特征聚集效果,且未知个体也能明显看出聚集为几个类别。由此可见本文所使用的方法在不同的开放度下均可实现已知个体的分类识别和未知个体的区分,在相应开放度下具体的开集识别正确率如图12红色曲线所示。




图 11 不同开放度下特征映射图

Fig.11 Feature mapping diagrams under different degrees of openness

3.5.4 消融实验

对本文所用OpenMax结合联合损失函数的开集识别方法做消融实验,在相应的开放度下对比只使用Softmax、只使用OpenMax、移除FAN层的OpenMax以及本文方法4种方法的识别正确率,结果如图12所示。

在开放度为0时即为闭集识别,本文所提方法与只使用交叉熵损失的OpenMax方法和Softmax分类性能相当,说明本文算法在增加开集识别能力时,并未影响网络原先的闭集识别性能。随着开放




图 12 Softmax 与 OpenMax 算法准确率随开放度变化图
Fig.12 Accuracy of softmax and openMax algorithms versus openness

度的增加,开放空间风险变大,开集识别的准确率也逐渐下降。因为基于Softmax的闭集识别算法不具备开集识别能力,所以测试集中新增的辐射源个体信号样本全部识别错误,识别性能急剧下降。本文所提方法在不同开放度下均能做到一定程度的开集识别率,这说明联合损失函数使得开集识别算法识别率更高,在开放度0.184时,识别准确率能达到86.42%,明显优于仅使用交叉熵损失的OpenMax方法。在此基础上,本文方法移除FAN层后,即只使用CNN网络进行特征提取,再结合OpenMax进行开集识别,识别率一开始相当,随后逐渐下降,移除FAN层后,已知类和未知类边界模糊,导致识别率下降,因为FAN层对卷积层提取的原始特征提取出了更适合分类的部分,说明FAN层的特征提取能力有助于提升开集识别的准确率。

3.5.5 对比其他开集方法

为进一步说明本文所提方法对开集识别的优越性,将其与表2所示的开集识别方法做对比,采用开源数据集 WiSig 数据,使用8个个体数据训练网络,添加未训练的个体作为未知个体进行测试阶段的开集识别,0~7类为已知类,8~15类为未知类,检验的评价指标为识别准确率,开放度由式(20)计算。对比参数如表2所示,在不同的开放度下的识别结果如图13所示。

表2 对比方法
Table 2 Comparative methods

对比维度	特征提取模型	开集识别机制
本文方法	CNN(1D)-FAN	OpenMax 计算得分+阈值判断+交叉熵损失+中心损失
超球面表示 ^[9]	CNN(1D)-FAN	基于马氏距离的类中心匹配+自适应阈值+置信度过滤
谱聚类-HSIC ^[10]	CNN(1D)+双向 LSTM	谱嵌入学习特征分布+HSIC 损失
OCSVM ^[13]	CNN(1D)	对齐已知/未知分类
K-means ^[15]	CNN(1D)	闭集分类+异常检测
OpenMax-SKResNet ^[26]	ResNet+Selective kernel	新奇检测算法进行二分类判断已知和未知+K-means对新类聚类
生成对抗网络(Generative adversarial network, GAN)-OpenMax ^[27]	辅助分类器生成对抗网络 (Auxiliary classifier generative adversarial network, ACGAN)+伪样本训练	OpenMax 计算得分+阈值判断

识别准确率

$$ACC_{all} = \frac{\text{已知类预测正确的样本数} + \text{未知类预测正确的样本数}}{\text{总样本数}} \quad (22)$$

从图12可以看出,在开放度较低时,5种开集识别方法差距不大,随着开放度的增加,本文方法与6种对比方法识别率均有所降低,在开放度为0.125时,本文所提方法、OCSVM方法、OpenMax-SKResNet方法、GAN-OpenMax方法、谱聚类-HSIC、K-means方法和超球面表示方法的识别率分别为0.926、0.826、0.793、0.788、0.783、0.770和0.544,很显然本文所提方法的准确率较高,开集识别效果较好。基于OCSVM的开集识别方法通




图13 不同算法开集识别准确率随开放度变化图
Fig.13 Open-Set recognition accuracy of different algorithms versus openness

过对网络输出的 Softmax 置信度设置阈值来区分未知个体,识别效果较优于聚类方法; OpenMax-SKResNet方法由于SKResNet是CNN引入注意力机制的残差网络,核心设计更适合空间特征(图像的局部纹理),但对时序信号(I/Q序列)的特征捕捉存在局限,所以对未知类的信号适应性较差;GAN-OpenMax方法使用模型生成“伪未知样本”模拟未知类,其本质是已知类的“变异”,随着真实未知类增多,其特征与已知类的差异可能远超出伪未知样本的覆盖范围,导致分类器无法有效识别;基于聚类K-means的开集识别方法通过对网络提取特征直接做聚类判别已知未知,在开放度较高时因个体数量多,个体特征之间干扰大,准确率下降,基于开放性选择核残差网络的开集识别方法由于模型建模有限,随着未知类的增多使特征增多,与已知类特征重叠,导致误判,准确率下降;基于谱聚类和HSIC的开集识别方法通过最小化特征与核矩阵的依赖性来学习分布,未知类别少时的识别准确率较高,当未知类别过多时,固定维度的核矩阵无法捕捉所有类别的复杂分布;基于特征距离度量(超球面表示)的开集识别方法比较依赖特征的几何结构,随着未知个体的增多,同样是未知类和已知类可能存在特征重叠便不能有效区分,识别效果最差。以上几种开集识别方法的识别准确率还是低于本文提出的加了中心损失的OpenMax方法。由此可见,本文提出的在CNN-FAN模型基础上联合中心损失使用OpenMax进行未知辐射源个体识别方法在解决开集识别问题上具有一定的优势。

4 结束语

本文提出了一种基于CNN-FAN的辐射源个体开集识别方法,该方法利用CNN-FAN网络更有效地提取辐射源频率域指纹特征,利用OpenMax和联合损失构成开集识别模型,最小化了特征与其对应类中心的距离,在不影响闭集识别准确率的前提下实现高准确率开集识别。实验中使用同一接收机采集的8个不同的发射机个体数据训练CNN-FAN模型,在测试集中加入了两个未知辐射源个体数据,验证了所提开集识别方法的有效性;然后在测试集中分别加入1~8个未知个体数据,验证本文方法在不同的开放度下的识别性能。最后对比了其他4种开集方法,验证了本文算法在不同开放度下识别率的优越性,在加入8个未知个体时,即开放度为0.184,识别准确率仍有84%,说明本文所提方法具有较好的开集识别性能。实验中所用数据是经过信道均衡后的数据,无线信道对辐射源个体开集识别的影响有待进一步研究,在实际应用中,低信噪比和多径衰落问题可能会同时存在,采用多模态学习可以进一步提高鲁棒性,利用多模态信息,比如添加信号的调制方式的识别,模型能从多角度处理信号,提高对干扰的抵抗力。开集识别中还会面临不断增加的未知类别,如何使模型能够学习新类别,且不会遗忘旧类别,可以进行增量学习,使模型能够在已有知识的基础上扩展,这是未来的研究方向。

参考文献:

- [1] 陈翔,汪连栋,许雄,等.基于Raw I/Q和深度学习的射频指纹识别方法综述[J].雷达学报,2023,12(1): 214-234.
CHEN Xiang, WANG Liandong, XU Xiong, et al. Review on radio frequency fingerprint identification based on Raw I/Q data and deep learning [J]. Journal of Radars, 2023, 12 (1): 214-234.
- [2] 韦建宇,俞璐.通信辐射源个体识别中的特征提取方法综述[J].通信技术,2022,55(6): 681-687.
WEI Jianyu, YU Lu. Review of feature extraction algorithms for communication emitter individual identification[J]. Communications Technology, 2022, 55(6): 681-687.
- [3] SOLTANIEH N, NOROUZI Y, YANG Y, et al. A review of radio frequency fingerprinting techniques[J]. IEEE Journal of Radio Frequency Identification, 2020, 4(3): 222-233.
- [4] 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 individual emitter identification using directed graph connectivity[J]. Journal of Data Acquisition and Processing, 2025, 40(5): 1250-1260.
- [5] WU C, CHEN S, SUN G, et al. Open set RF fingerprint identification for wireless communication devices[J]. IEEE Wireless

- Communications Letters, 2025, 14(3): 776-780.
- [6] 张本辉,刘松涛.未知辐射源识别技术研究进展[J].中国电子科学研究院学报,2023,18(9):864-872.
ZHANG Benhui, LIU Songtao. Research progress on unknown emitter recognition technology[J]. Journal of China Academy of Electronics and Information Technology, 2023, 18(9): 864-872.
- [7] 王春升,王永民,许华,等.面向开集场景的辐射源个体识别[J].西安交通大学学报,2022,56(10):130-140.
WANG Chunsheng, WANG Yongmin, XU Hua, et al. Individual emitter identification oriented to open-set scenarios[J]. Journal of Xi'an Jiaotong University, 2022, 56(10): 130-140.
- [8] HANNA S, KARUNARATNE S, CABRIC D. Open set wireless transmitter authorization: Deep learning approaches and dataset considerations[J]. IEEE Transactions on Cognitive Communications and Networking, 2021, 7(1): 59-72.
- [9] XIE R, XU W, CHEN Y, et al. A generalizable model-and-data driven approach for open-set RFF authentication[J]. IEEE Transactions on Information Forensics and Security, 2021, 16: 4435-4450.
- [10] WANG Z, SALEHI B, GRITSENKO A, et al. Open-world class discovery with kernel networks[C]//Proceedings of 2020 IEEE International Conference on Data Mining (ICDM). Sorrento, Italy: IEEE, 2020: 631-640.
- [11] 刘人玮,李天昀,章昕亮,等.基于卷积原型网络的通信辐射源个体开集识别方法[J].信息工程大学学报,2023,24(2): 140-149.
LIU Renwei, LI Tianyun, ZHANG Xinliang, et al. Open-set individual communication emitter identification based on convolutional prototype network[J]. Journal of Information Engineering University, 2023, 24(2): 140-149.
- [12] 杨柳,利强,邵怀宗. Open-MUSIC: 基于度量学习与特征子空间投影的电磁目标开集识别算法[J].电子学报,2022,50(6): 1310-1318.
YANG Liu, LI Qiang, SHAO Huaizong. Open-MUSIC: Open-set electromagnetic target recognition via metric learning and feature subspace projection [J]. Acta Electronica Sinica, 2022, 50(6): 1310-1318.
- [13] 赵妮.基于深度学习的雷达辐射源智能识别[D].成都:电子科技大学,2022.
ZHAO Ni. Intelligent radar emitter recognition based on deep learning[D]. Chengdu: University of Electronic Science and Technology of China, 2022.
- [14] YANG Z, JING M, GUO Y, et al. Circuit breaker target sound signal detection method based on VAD and SVDD algorithms [C]//Proceedings of 2023 IEEE 4th China International Youth Conference on Electrical Engineering (CIYCEE). Chengdu, China: IEEE, 2023: 1-5.
- [15] 严科.基于半监督深度学习的辐射源个体识别[D].北京:中国电子科技集团公司电子科学研究院,2021.
YAN Ke. Individual emitter identification based on semi-supervised deep learning[D]. Beijing: China Academy of Electronic and Information Technology, 2021.
- [16] DONG Y, LI G, TAO Y, et al. FAN: Fourier analysis networks[EB/OL]. (2024-10-03) [2025-03-27]. <https://arxiv.org/abs/2410.02675>.
- [17] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [18] ZHOU Z, JIAO W, HU X, et al. Open-set event recognition model using 1-D RL-CNN with OpenMax algorithm for distributed optical fiber vibration sensing system[J]. IEEE Sensors Journal, 2023, 23(12): 12817-12827.
- [19] PERERA P, MORARIU V, JAIN R, et al. Generative-discriminative feature representations for open-set recognition[C]//Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA, USA: IEEE, 2020: 11311-11320.
- [20] 万昊,梁菁.基于多重对比损失的雷达传感器网络HRRP无监督目标特征提取方法[J].雷达学报,2024,13: 1-12.
WAN Hao, LIANG Jing. Unsupervised HRRP feature extraction of radar sensor network with multi-contrast loss[J]. Journal of Radars, 2024, 13: 1-12.
- [21] LIAO R, LI Z, BHATTACHARYYA S, et al. Aerial image classification with label splitting and optimized triplet loss learning[C]//Proceedings of 2021 International Conference on Visual Communications and Image Processing (VCIP). Munich, Germany: IEEE, 2021: 1-6.
- [22] WEN Y, ZHANG K, LI Z, et al. A discriminative feature learning approach for deep face recognition[C]//Proceedings of European Conference on Computer Vision. Cham, Switzerland: Springer, 2016.

- [23] HANNA S, ARUNARATNE S, CABRIC D. WiSig: A large-scale WiFi signal dataset for receiver and channel agnostic RF fingerprinting [J]. *IEEE Access*, 2022, 10: 22808-22818.
- [24] CHEN Y, XU X, QIN X. An open-set modulation recognition scheme with deep representation learning[J]. *IEEE Communications Letters*, 2023, 27(3): 581-585.
- [25] ZHANG H, WANG X, GAO Y, et al. Data visualization and fault detection using bi-kernel t-distributed stochastic neighbor embedding in semiconductor etching processes[J]. *IEEE Transactions on Semiconductor Manufacturing*, 2022, 35(3): 522-531.
- [26] HAN X, CHEN S, CHEN M, et al. Radar specific emitter identification based on open-selective kernel residual network[J]. *Digital Signal Processing*, 2023, 134: 103901.
- [27] GUO L, LIU C, LIU Y, et al. Toward open-set specific emitter identification using auxiliary classifier generative adversarial network and OpenMax[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2024, 10(6): 2019-2028.

作者简介:

温金莹(2001-),女,硕士研究生,研究方向:辐射源个体识别, E-mai: mochi_wen@163.com。



谢跃雷(1975-),通信作者,男,教授,研究方向:通信信号处理、信号处理的ASIC设计实现、FPGA数字系统设计, E-mail: ylxie@guet.edu.cn。



刘祥国(1999-),男,工程师,研究方向:辐射源个体识别。

(编辑:陈珺)

Open-Set Specific Emitter Identification Based on CNN-FAN

WEN Jinying, XIE Yuelei*, LIU Xiangguo

(School of Information and Communication Engineering, Guilin University of Electronic Technology, Guilin 541004, China)

Abstract: In order to solve the problem of identifying unknown emitters in an open electromagnetic environment, we propose an open-set identification method based on the convolutional neural network-Fourier analysis network (CNN-FAN) model. The proposed method initially introduces the network layer of Fourier analysis networks (FAN). The Fourier series properties are utilized to effectively extract the frequency components of the signal, followed by its integration with a convolutional neural network to formulate the CNN-FAN network model. Subsequently, the Softmax layer is substituted with an open-set identification model, facilitated by the utilization of OpenMax. Finally, a joint optimization strategy combining center loss and cross-entropy loss is adopted to optimize model performance. This optimization reduces the feature distance of individual radiation sources and narrows inter-class gaps, which improves the classification performance and enables OpenMax to distinguish between known and unknown emitter categories. The proposed method is validated and subjected to experimental analysis on the open-source WiSig dataset under varying degrees of openness. Experimental results demonstrate that the proposed method attains a recognition rate of 95% at an openness level of 0.057 and an open-set recognition rate of 84% at an openness level of 0.184, thereby outperforming other open-set recognition methods. In addition, the proposed framework provides a systematic solution for open-set radio frequency fingerprint identification by jointly considering discriminative feature learning and unknown-class rejection. The CNN module captures local temporal characteristics from the input radio frequency signals, while the FAN layer further enhances the representation capability by modeling periodic and frequency-domain variations. This complementary feature extraction mechanism enables the network to obtain more robust and separable emitter-specific representations. Moreover, by incorporating OpenMax into the decision stage, the model is no longer restricted to closed-set classification and can assign samples from unseen emitters to unknown categories according to their activation distribution. The combination of feature compactness optimization and open-set probability calibration improves both known-emitter identification and unknown-emitter rejection. These results indicate that the proposed CNN-FAN-based open-set identification method has strong applicability in realistic electromagnetic environments where unknown emitters may appear during deployment.

Highlights

1. An open-set emitter identification method based on CNN-FAN is proposed.
2. FAN is introduced to enhance frequency-component feature extraction from radio frequency signals.
3. OpenMax is employed to distinguish known emitters from unknown emitters.
4. Center loss and cross-entropy loss are jointly used to improve feature separability.
5. Experiments on the WiSig dataset show competitive performance under different openness levels.

Key words: individual radiation source identification; open-set recognition; deep learning; convolutional neural network (CNN); Fourier analysis network (FAN)

Foundation items: National Natural Science Foundation of China (No. 62461015); Guangxi Natural Science Foundation(No. 2023GXNSFAA026060).

Received: 2025-07-09; **Revised:** 2026-06-29

***Corresponding author, E-mail:** ylxie@guet.edu.cn.