

面向开集场景的辐射源个体识别

王春升, 王永民, 许华, 张悦, 朱丽莉
(空军工程大学信息与导航学院, 710077, 西安)

摘要: 为解决现有开集场景下辐射源个体识别算法鲁棒性不强、识别性能较低的问题, 结合原型网络提出了一种开集场景下适用于一维信号的辐射源个体识别模型。对采集的辐射源 I/Q 信号进行功率归一化、切片和加噪等预处理操作; 设计用于识别 I/Q 信号的一维卷积神经网络, 并在网络中加入具有注意力机制的压缩激励模块, 以此提高网络中有效特征通道的权重; 将该网络结构和原型学习思想相结合, 利用预处理的数据集进行训练和测试。在训练过程中, 利用距离交叉熵损失函数为每个类别学习一个原型, 并将信号特征到原型的距离作为分类依据, 同时利用原型损失函数以提高信号类内紧密度的方式增大类间距离, 进一步增强分类能力; 在测试过程中, 利用自适应距离分类规则为每个类别学习一个自适应的距离阈值, 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。对 5 种 ZigBee 设备采集的信号进行实验, 结果表明: 在信噪比为 $-10 \sim 10$ dB 之间, 所提模型的识别准确率比通常所用的基于极值理论的模型高 8% 左右。

关键词: 辐射源个体识别; 开集场景; 原型网络; 卷积神经网络

中图分类号: TN975 **文献标志码:** A

DOI: 10.7652/xjtuxb202210013 **文章编号:** 0253-987X(2022)10-0130-11

Specific Emitter Identification Under Open Set Scenes

WANG Chunsheng, WANG Yongmin, XU Hua, ZHANG Yue, ZHU Lili
(Information and Navigation College, Air Force Engineering University, Xi'an 710077, China)

Abstract: This paper proposes a specific emitter identification model suitable for one-dimensional signals under open set scenes based on prototype network. The model is used to solve the problems of weak robustness and low recognition of existing algorithms for specific emitter identification under open set scenes. Firstly, the I/Q signals collected are preprocessed by power normalization, slicing and noise addition. Then, a one-dimensional convolutional neural network for recognition of I/Q signals is designed, and a squeeze-and-excitation block with attentional mechanism is added to the network to improve the weights of feature channels with high efficiency. Finally, the preprocessed data set is used to train and test the network based on the idea of prototype learning. During the training process, the distance cross entropy loss function is used for prototype learning for each category, taking the distance between the signal features and the prototype as the classification basis. At the same time, the prototype loss function is used to increase the inter-class distance by compacting the intra-class signals, which further enhances the classification ability. During the testing process, the network can learn an adaptive distance threshold for each category by using the adaptive distance classification rule. The distance threshold is used

收稿日期: 2022-04-09。 作者简介: 王春升(1994—), 男, 硕士生; 王永民(通信作者), 男, 副教授, 硕士生导师。 基金项目: 国家自然科学基金资助项目(61906156); 空军工程大学研究生创新实践基金资助项目(CXJ2021075)。

网络出版时间: 2022-06-22

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20220621.1726.004.html>

for the classification of known classes and the detection of unknown ones. Experiments are carried out on the signals collected from five ZigBee devices. Simulation results show that the recognition rate of proposed model is about 8% higher than the common models based on extreme value theory between a signal-to-noise ratio from -10 dB to 10 dB.

Keywords: specific emitter identification; open set scenes; prototype network; convolutional neural network

随着信息技术的迅猛发展以及通信辐射源种类数量的日益增多,无线网络安全和电子侦察面临着严峻挑战。传统的 MAC 地址和秘钥认证方法容易被伪造和破解,依靠信号分析方法去追踪和识别信号已无法满足复杂电磁环境下的侦察需求,特定辐射源识别(specific emitter identification, SEI)^[1]通过提取辐射源信号中固有的指纹特征,再配合传统的秘钥等认证方法可以加强对非法设备的识别和身份认证,提高通信系统安全性能。另外,在电子侦察领域中,通过识别个体特征可以有效获取非合作目标信息、追踪信号位置空间、分析战场电磁态势并获取价值情报。

根据通信辐射源的工作状态,可以将信号指纹特征分为暂态特征和稳态特征。暂态特征的差异明显且容易分辨,但提取暂态特征对设备的精密性和采集条件要求高,且易受噪声干扰^[2]。相较于暂态特征,稳态特征获取容易,基于稳态特征提取射频指纹的方法有广泛的研究和适用范围,如通过高阶累积量^[3]、矩形积分双谱^[4]、变分模态分解^[5]等特征变化方法进行特征提取,并通过支持向量机(support vector machine, SVM)、聚类等分类算法进行分类。但是,这些人工设计的特征提取和分类方法复杂度较高、泛化性不强、识别率低。

随着深度学习技术的快速发展^[6],很多学者将其应用于辐射源个体识别或信号识别领域。例如,利用不同的卷积神经网络(convolutional neural network, CNN)对信号的 Hilbert 谱图像^[7]、差分星座轨迹图(differential constellation trace figure, DCTF)^[8-10]、时频谱图^[11-12]进行识别,这些方法都较传统方法有了大的性能提升。为了减少在信号变换中特征的丢失和模型复杂度,很多学者利用一维 CNN 和长短期记忆网络(long short-term memory network, LSTM)直接对基带 I/Q 序列数据进行特征提取和分类^[13-14]。进一步地, CNN 和 LSTM 融合的混合网络识别方法^[15]、基于复数神经网络的识别方法^[16]也相继被提出,这些方法利用深度学习的强大特征提取能力、自学习能力和相应的数据处理方法,使得分类性能得到了很大提升。

以往研究的通信辐射源个体识别方法大都是基于闭集环境,但实际的应用场景往往都是处于开集环境。目前,已有部分学者开始研究在开集场景下的辐射源个体识别。文献[17-18]利用基于极值理论的 OpenMax^[19]对雷达的高分辨率距离像以及辐射源个体进行识别,相较于传统的开集识别模型有较好的性能优势。此外,将 triplet loss、center loss 等多种度量学习方法和深度学习结合的识别方法^[20]以及基于半监督和对抗自编码器的辐射源个体开集识别方法^[21-22]都取得了较好的效果。近年来,结合原型学习思想和深度神经网络的原型网络被用于小样本条件下的图像识别^[23]、类增量学习^[24]和开集识别^[25],这些方法都取得了相较于传统 CNN 更好的识别性能。

目前,针对通信辐射源个体的开集识别研究较少,且识别性能和鲁棒性还有待提升。文献[10]基于原型学习^[24]提出残差原型网络结构,并针对信号的差分星座轨迹图进行识别,在闭集环境下取得了良好的识别性能。在此基础上,本文提出了一种开集场景下适用于一维信号的辐射源个体识别模型,该网络模型采用原型学习思想,在一维卷积神经网络中加入压缩激励(squeeze-and-excitation, SE)模块^[6],利用基于原型的距离交叉熵损失(distance cross entropy, DCE)函数为每一个类别学习一个原型,通过类原型之间的距离完成分类。在此基础上,加入原型损失(prototype loss, PL)函数,在提高信号类内紧密度的同时扩增内间距离,进一步提高了模型分类能力。基于 PL 的作用原理,采用基于自适应距离的分类规则完成对已知目标的分类和未知目标的检测,从而完成了开集识别。对 5 种 ZigBee 设备采集的 I/Q 原始数据进行实验,结果表明,本文提出的模型相较于其他经典方法具有更高的识别性能。

1 开集识别和原型学习

1.1 开集识别

对于一个特定的识别问题,常用的识别方法是闭集识别,即测试集的样本类别和用于训练的样本

类别相同。假定样本的类别数量为 N , 闭集识别所解决的问题就是完成测试集中 N 个类别的分类。但是, 实际的应用场景中往往都是处于开集的环境, 需要测试的样本中可能包含了训练集中没有出现的新类别, 利用闭集识别方法所训练的模型在进行识别时会将来自未知类的测试样本识别为已知类别, 从而严重影响识别精度。

开集识别为解决该问题提供了新的思路, 即在

对已知的 N 类样本进行分类识别的基础上完成对未知类目标的检测或拒绝。闭集识别和开集识别的分类模型如图 1 所示。在闭集识别中, 所学习到的整个特征空间将会被分配给所有已知类, 未知类目标只能被判定为某一个相似的已知类; 在开集识别中, 已知类别的特征空间是有限的, 分类边界在对已知类别进行分类的同时可识别出未知类别, 并将所有未知类别的样本划分为一类。



图1 闭集识别和开集识别模型

Fig. 1 Recognition models for closed set and open set

1.2 原型学习

原型学习通过特定的学习方法为每个类别计算出一个或多个原型表示 a_{ij} , 其中 $i \in \{1, 2, \dots, N\}$ 表示样本中共有 N 个类别, $j \in \{1, 2, \dots, M\}$ 表示每个类中有 M 个原型^[24]。在分类识别任务中, 可以利用神经网络强大的特征提取能力来提取数据特征, 并构建每一个类原型, 神经网络作为特征提取器可表示为 $f(x; \theta)$, x 和 θ 分别表示网络的原始输入和参数^[10]。以往的 CNN 模型在分类的时候使用 softmax 函数对全连接层的输出进行归一化, 以最大概率值对输入样本 x 进行判定和分类。分类依据为

$$\begin{cases} x \in \arg \max_y p(y | x) \\ p(y | x) = \frac{\exp(\delta_y)}{\sum_{i=1}^N \exp(\delta_i)} \end{cases} \quad (1)$$

式中: $y \in \{1, 2, \dots, N\}$; $p(y | x)$ 表示样本 x 属于类别 y 的概率; δ_i 表示第 i 类对应的网络输出值。利用原型学习进行分类时, 网络可为每个类学习一个原型。对于任意样本, 可以将它划入到距离最近的原型所属的类别。该过程可以表示为

$$x \in \arg \max_i g_i(x) \quad (2)$$

式中 $g_i(x)$ 是类别 i 的分类函数, 表示为

$$g_i(x) = -\|f(x; \theta) - a_i\|_2^2 \quad (3)$$

其中 $f(x; \theta)$ 和原型 a_i 可以联合学习。在学习过程中, 不断将某一类原型推向该类的样本特征, 而其他

类的原型远离该类样本特征。原型学习将分类问题转化为在特征向空间中的最近邻问题, 结合神经网络的特征提取优势, 可以有效缓解过拟合, 提高泛化性能和识别性能。

2 辐射源个体识别模型

2.1 模型框架

开集场景下基于原型网络的辐射源个体识别模型是利用一维卷积神经网络为基础结构, 结合原型学习方法和 SE 模块对预处理的 I/Q 信号进行识别, 并利用自适应距离分类规则完成分类预测。

开集场景下基于原型网络的辐射源个体识别模型如图 2 所示, 主要分为 3 个模块。第 1 个模块为数据处理模块, 接收端接收信号后, 首先对其进行高采样率采样, 然后按照样本长度对数据进行功率归一化、切片和加噪等操作, 最后按预设比例划分训练集和测试集。第 2 个模块为特征提取和参数更新模块。将处理好的 I/Q 数据送入一维 CNN, 对于该网络模型, 给定输入 x , 通过神经网络特征提取器 $f(x; \theta)$ 获得它的抽象特征表示。在训练阶段, 通过最小化损失函数和神经网络的反向传播算法同时更新网络参数和原型, 更高效地训练整个网络。第 3 个模块为分类模块, 在训练阶段, 将训练样本提取到的抽象特征与所有原型进行匹配, 根据欧氏距离将其分类到最近原型所属的类别。在测试阶段, 将测试样本提取到的抽象特征与所有已训练好的原型进

行匹配,根据自适应距离分类规则将测试样本分类 为已知类别的某一类或未知类别。




图 2 开集场景下基于原型网络的辐射源个体识别模型

Fig. 2 Specific emitter identification model based on prototype network for open set scenes

2.2 网络结构设计

开集识别网络结构如图 3 所示。本文直接对序列数据进行处理,复杂度较低,故设计的网络结构以较为简单的一维卷积神经网络为基础。网络层数共有 4 层,每一层的卷积核数分别为 32、64、128、256。在每一个卷积层后添加内核为 2 的最大池化层来降低模型的复杂度和过拟合程度,通过 4 层的网络使得最后的输出样本维度降到一个较低的值,以便充分提取数据的深层特征。




图 3 开集识别网络结构

Fig. 3 Network structure of open set recognition

每个卷积层的卷积核大小为 1×9 ,使用较大的卷积核能够充分提取序列数据中的时序信息。在每

一次卷积和池化操作后加入 SE 模块,通过调整各通道的权重进一步提高识别准确率。在最后一个卷积层中加入 Dropout 层,以缓解模型在训练中出现的过拟合现象。在卷积操作中对每一个样本数据的边缘补 0,保证充分提取该样本的特征,并确保卷积后得到的样本长度不变。

在卷积层后,采用 PReLU 激活函数。PReLU 激活函数在负值时的斜率是在 $0 \sim 1$ 之间可学习的。在神经网络中,初始化权重和权重更新时,都有可能出现权重为负值的情况,使用 PReLU 激活函数,保证了在激活函数输入特征为负值的时候其输出值不为全 0,能够更全面地保留网络提取的特征,提升识别性能。在所有卷积操作完成后,采用自适应平均池化,输出大小维度为 1×1 。最后经过全连接层,输出 2 维特征,输出特征通过 DCE 损失和 PL 损失计算特征到原型的欧氏距离,同时更新网络参数和原型 a_i 。

网络中加入的 SE 模块采用了注意力机制,其核心思想是通过不断学习来自动获取在卷积过程中每个特征通道的重要程度,依据重要程度来调整各通道的权重,在权重的作用下可提高有效通道特征的影响,抑制作用较小的通道特征,进而提高网络的识别性能。一维 SE 模型如图 4 所示,输入数据 $X = (u_1, u_2, \dots, u_{C'})$,经过卷积操作后提取的特征为 $U = (u_1, u_2, \dots, u_C)$,其中 C 和 C' 代表通道维度, L 和 L' 代表每一个通道的特征维度。为了适应一维数据处理,将 SE 模块中的二维结构改为一维结构。该模块总共分为 3 个步骤。第 1 步,进行 Squeeze 操作。保留通道数不变,将时间序列数据中的 $C \times L$

维特征经过一维自适应平均池化,变成 $C \times 1$ 维特征,使其具有全局感受野。该过程可表示为

$$z_c = F_{sq}(u_c) = \frac{1}{L} \sum_{i=1}^L u_c(i) \quad (4)$$




图4 一维 SE 模型

Fig. 4 One-dimensional SE model

第2步,进行 Excitation 操作。该操作经过两个全连接层,第一个全连接层表示为 $W_1 \in \mathbf{R}^{C \times C}$ 。它将特征压缩为 C/r 通道,其中 r 是通道的压缩比例,可以极大地减少参数量和计算量,文中的 r 为 16。之后,经过一个 ReLU 激活函数。第二个全连接层表示为 $W_2 \in \mathbf{R}^{C \times \frac{C}{r}}$,将特征还原为 C 通道。最后,使用一个 Sigmoid 激活函数。经过全连接层和非线性激活层,可以得到一个 0-1 之间的归一化权重 $s = (s_1, s_2, \dots, s_C)$ 。该过程表示为

$$s = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2 \delta(W_1 z)) \quad (5)$$

式中: δ 代表 ReLU 函数; σ 代表 Sigmoid 函数; $F_{ex}(\cdot, W)$ 代表 Excitation 操作。

第3步,进行特征重标定操作,将归一化的权重逐通道加权到每个通道的特征上。完成在通道维度上对原始特征的重标定,输出特征为 $\tilde{X} = (\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_C)$,将其作为下一级的输入数据。该过程表示为

$$\tilde{x}_c = F_{scale}(u_c, s_c) = s_c u_c \quad (6)$$

式中 $F_{scale}(\cdot, \cdot)$ 代表特征重标定操作。

2.3 自适应距离分类规则

在闭集场景下,对已知类目标的分类可以基于式(2)、(3)完成。在开集场景下,对已知目标的分类和未知类目标的检测可以在原型网络的基础上使用基于距离的拒绝规则。

在式(3)中, $g_i(x)$ 代表样本 x 属于类别 i 的匹配程度,即样本 x 到类别 i 的距离。在测试时,如果样本 x 到类别 i 的最近距离大于阈值 ω ,即

$$\min \|f(x; \theta) - a_i\|_2^2 > \omega \quad (7)$$

式中: $F_{sq}(\cdot)$ 代表 Squeeze 操作; $u_c \in \mathbf{R}^L$ 代表操作前的特征分布; z_c 代表 z 的第 c 个分量, $z \in \mathbf{R}^C$ 代表 $F_{sq}(\cdot)$ 操作后的特征分布; $u_c(i)$ 代表 U 中第 c 个通道的第 i 个分量。


则代表该样本 x 与已知类别 i 的原型 a_i 匹配程度很低,可判定该样本为未知类别^[25]。式中 $f(x; \theta)$ 代表样本 x 的深度特征。基于 $g_i(x)$ 的定义,则有

$$\max g_i(x) < -\omega \quad (8)$$


式(8)代表样本 x 属于类别 i 的最大匹配程度小于某一个阈值,等价于式(7)。

然而,在基于距离的拒绝规则中,阈值 ω 难以设定。选取不同网络结构、网络深度,不同信噪比下的识别信号或者不同的 λ 进行训练拟合时,都会导致每一个类出现不同的样本分布,而不同的样本分布会导致每一个类原型之间的距离不同,且每一个类的样本到该类别所属原型的距离分布也不同。因此,使用固定的阈值 ω 会使得拒绝检测不具有鲁棒性,且阈值 ω 也难以确定。

图5是不同信噪比和不同类别样本下的特征分布对比。可以看出,经过训练后,不同信噪比下已知类的样本以及类原型分布不同。图中, $d_1 \neq d'_1, d_2 \neq d'_2$, 因此用来判定样本属于某一类原型的距离阈值 ω 就不同,这就给 ω 的设定带来了困难。



(a) 10 dB 下的样本特征分布



(b) 0 dB 下的样本特征分布

图 5 不同信噪比和不同类别样本下的特征分布对比

Fig. 5 Comparison of feature distribution under different SNR and different categories

基于此,本文提出了基于自适应距离的分类规则。在该规则中,距离阈值 ω 是可学习的,在训练期间,根据每一个类别样本的分布情况,可以自动调整 ω ,得到一个更具鲁棒性的 ω 。具体算法如下:在训练期间,根据标签信息得到每一个预测正确的样本 x ,通过 CNN 网络提取到特征 $f(x; \theta)$,计算特征 $f(x; \theta)$ 到样本 x 对应原型的距离。训练完成后,得到所有类的原型以及正确预测样本 x 所提取的特征 $f(x; \theta)$ 到对应原型的距离分布 D ,表示为

$$D = \{d_{xi} \mid x = 1, 2, \dots, T; i = 1, 2, \dots, N\} \quad (9)$$

式中: T 代表训练集中每个类别的样本数量; N 代表类别数量; d_{xi} 代表样本 x 到对应原型 a_i 的距离。在测试时,由于测试样本中未知样本的空间分布情况未知,它可能在不同的网络模型或数据集下出现不同的位置分布。对于每一个测试样本,首先计算该测试样本到每一个原型 a_i 的距离,找到最近距离所对应的类别 i ,计算式为

$$i = \arg \max_i (-\|f(x) - a_i\|) \quad (10)$$

之后,根据所找到的类别 i 以及该类样本特征到类原型 a_i 的距离分布,得到最大距离分布值 $d_i = \max d_{xi}$ 。将该距离分布值 d_i 作为类别 i 的距离阈值 ω_i 。如果测试样本到最近原型的距离小于该类原型的阈值 ω_i ,则判定为该类别,否则判定为未知类样本。判别式表示为

$$\begin{cases} x \in i, & \min \|f(x; \theta) - a_i\|_2 \leq \omega_i \\ x \in N+1, & \min \|f(x; \theta) - a_i\|_2 > \omega_i \end{cases} \quad (11)$$

2.4 损失函数定义和优化方法

2.4.1 DCE 损失

在原型网络结构中,用距离来衡量样本和原型

之间的相似性^[23]。因此,样本 (x, y) 与原型 a_i 之间的距离可以衡量其属于原型的概率,其中, x 为样本, y 为样本对应的标签。基于文献[24]和[10]的分析,可以将 DCE 损失定义为

$$l((x, y); \theta, A) = -\frac{1}{K} \sum_{k=1}^K \sum_{n=1}^N q(y) \log p(y \mid x) \quad (12)$$

式中: $A = \{a_i \mid i = 1, 2, \dots, N\}$ 代表类原型集合; $q(y)$ 是样本标签的分布; $p(y \mid x)$ 表示样本 x 属于类别 y 的概率; K 为一个批次的样本数量。

2.4.2 PL 损失

为了进一步提高网络的识别性能,同时完成开集识别任务,可以在训练期间通过 PL 损失函数^[24]缩小类内样本特征间的距离,继而以提高类内紧密度的方式增加类间距离。同时,通过该损失函数的约束,在缩小已知类样本特征空间的基础上扩大了未知类的空间分布,更有利于对未知类目标的检测和拒绝。PL 损失定义为

$$PL((x, y); \theta, A) = \|f(x) - a_y\|_2^2 \quad (13)$$

式中 a_y 为 y 类所属原型。最小化 $PL((x, y); \theta, A)$ 可以缩小各类样本特征到所属原型的距离。

2.4.3 联合损失

根据以上分析,可以将 DCE 损失和 PL 损失相结合来训练模型。联合损失可以定义为

$$L((x, y); \theta, A) = l((x, y); \theta, A) + \lambda PL((x, y); \theta, A) \quad (14)$$

式中 λ 是控制 PL 损失权重的超参数。通过结合 DCE 损失和 PL 损失,可进一步提高网络的分类准确率和鲁棒性。另外,PL 损失作为正则化项和对已知类样本空间的约束函数,既有助于完成开集识别任务,也可以防止模型的过拟合,增加泛化性能。通过式(14)分析得到, λ 太小则类内分布空间不够紧密,难以达到更优的识别性能。 λ 太大也会过度提高样本空间的紧密度,增加过拟合程度,降低闭集和开集识别的分类性能。

2.4.4 优化方法

采用自适应梯度下降(Adma)进行优化,优化目标为最小化联合损失 $L((x, y); \theta, A)$,每批训练样本数为 64,学习率初始值为 0.000 5。迭代数选择为 40,每迭代 10 次后学习率降低 50%。

2.5 训练和测试方法

在训练时,首先根据特征维度和类别数目对每一类别构造原型,并对原型进行初始化。输入样本经过网络提取特征后,计算与各个类原型的距离,根

据距离再计算出 DCE 损失和 PL 损失。最后,联合 DCE 和 PL 损失进行端到端训练和网络优化,同时更新网络参数和原型 a_i 。

在测试时,将输入信号的抽象特征与所有类别的原型进行比较,根据自适应距离分类规则将测试样本分类为已知类别的某一类或未知类别。

3 实验与结果分析

3.1 实验平台和数据预处理

3.1.1 实验平台

本文实验基于 Python 下的 Pytorch 深度学习框架,所使用的硬件平台中 CPU 为 AMD Ryzen 7 5800H, GPU 为 NVIDIA GeForce RTX3070。

3.1.2 数据预处理

实验所用数据集来自 5 种 ZigBee 设备的实采信号^[8],采样率为 10^7 s^{-1} 。信号调制方式为 OQPSK (offset quadrature phase-shift keying),遵循 IEEE 802.15.4 标准,信号接收设备为 Ettus Research N210 USRP。每一类设备有 5 段信号,每段信号分为 9 个小的帧段,每个帧段约为 40 000 个样本。将所有采集到的信号进行预处理,首先对信号进行功率归一化,消除在实际采集数据时因信号功率不同带来的影响,然后对信号进行切片处理、加高斯噪声。

在闭集实验中,随机选取每一类设备的 4 段信号为训练集,第 5 段信号为测试集。在开集实验中,选取其中的 3 类设备,每一类设备选取 4 段信号作为训练集,而测试集选取 5 类设备的第 5 段信号。

3.2 不同参数下的识别性能对比

3.2.1 不同样本长度下的性能对比

采用控制变量法选取最优识别性能下的参数。图 6 显示了在闭集环境下,信噪比在 $-10 \sim 6 \text{ dB}$ 之间变化时不同样本长度下的识别准确率。可以看出,对于序列信号:当样本长度较小时,网络难以提取到样本所包含的指纹特征,识别精度较低;当样本长度逐渐变大时,样本所包含的指纹特征更丰富,识别精度逐渐提高。但是,当样本长度过大时,识别精度会下降。原因是随着样本长度的增大,用于识别的指纹特征已经达到饱和,识别精度变化就不明显。另外,随着样本长度的增大,用于训练和测试的样本减少,测试精度就会受到较大影响。在高信噪比的情况下,模型能够较容易识别不同类信号,识别精度在不同样本长度下的变化不明显;在低信噪比的情况下,识别精度对参数的变化较敏感,所以在不同样本长度下的变化较大。综合实验结果来看,选取样

本长度为 800 个采样点进行后续实验。





图 6 不同样本长度下的识别准确率对比


Fig. 6 Comparison of recognition rate with different sample lengths

3.2.2 不同 λ 下的性能对比

选取样本长度为 800,对比在闭集和开集环境下信噪比在 $-10 \sim 6 \text{ dB}$ 之间变化时不同 λ 对应的测试精度。闭集和开集环境下的识别准确率如图 7 所示。可以看出,实验结果验证了 PL 损失的理论分析。 λ 决定了每一个类别的聚集程度,进而影响了类别之间的距离分布,使得不同 λ 下的识别性能也不同。通过实验得出,当 λ 为 0.05 左右时,识别性能最好。 λ 取值从 0 开始增大时,每一类特征的类内紧密度会逐渐增高,继而扩增了类间距离,既提高了对已知样本分类能力,也增强了对未知目标的检测和拒绝能力。随着 λ 的进一步增大,识别性能趋于稳定。当 λ 过大时,PL 损失对样本空间的约束就越大,就会将训练集的每一类样本空间过度缩小到类原型的附近,加重了过拟合现象。当输入测试样本时,测试集的样本空间分布会大于训练收敛后的样本空间分布,在通过类原型之间的距离进行判别时就会影响识别性能。同样地,在低信噪比下变化更明显,因此选择合适的 λ 对识别性能至关重要。另外,PL 损失对开集识别的作用更明显,其作用原理也更适合对未知类目标的检测。



(a) 对闭集识别准确率的影响



(b) 对开集识别准确率的影响

图 7 λ 对识别率的影响对比Fig. 7 Comparison of recognition rate at different λ

图 8 为开集识别下不同 λ 所对应的全连接层 2 维输入特征分布。可以看出,在 DCE 损失的作用下,可以完成对已知类的分类和对未知目标的检测,但从样本的分布来看,准确率和稳定性还不够高。在加入 PL 损失后,通过提高类内紧密度的方式扩大未知空间的分布,同时使得已知类样本和未知类样本在特征空间更加分离,继而提高了开集识别准确率和鲁棒性。



(a) $\lambda=0$ 时的训练特征分布 (b) $\lambda=0$ 时的测试特征分布(c) $\lambda=0.05$ 时的训练特征分布 (d) $\lambda=0.05$ 时的测试特征分布

图 8 不同损失函数下的特征分布

Fig. 8 Feature distribution under different loss functions

3.3 不同模型的识别性能对比

3.3.1 闭集环境下的识别性能对比

参照之前的实验结果,选取信号样本长度为 800, λ 为 0.05,信噪比变化范围为 $-10 \sim 10$ dB,将

本文提出的原型网络模型 PN-SE 与未加入 SE 模块的原型网络 PN 和未加入原型学习的一维卷积神经网络 CNN-SE 进行识别性能对比。为了进一步说明本文模型相较于其它模型的性能优势,同时将本文模型与 DCTF-CNN^[8]、PACGAN^[9]、LSTM-CNN^[15]这 3 种不同网络模型进行对比,以上几种模型都是针对 ZigBee 设备进行识别的。在对比实验中,使用本文数据集,按照相应的数据处理方式进行处理。

闭集环境下不同模型的识别准确率对比如图 9 所示。可以看出:引入原型学习思想,采用联合损失函数后可以在同等网络结构下增强模型的识别性能。在加入 SE 模块后,通过引入注意力机制改变了通道权重,可以提高原型网络的识别准确率。在较低信噪比下,本文提出的模型有较大的性能优势。当信噪比大于 0 dB 时,本文模型识别精度可达到 95% 以上;当信噪比大于 6 dB 时,本文模型识别精度可达到 99% 以上。另外,通过实验和分析得到,将信号转化成 DCTF 图像会丢失掉一些细微特征,导致在低信噪比下识别准确率不佳。




图 9 闭集环境下不同模型的识别准确率对比

Fig. 9 Comparison of recognition rate with different models in close set scenes

3.3.2 开集环境的识别性能对比

为了说明本文模型 PN-SE-Open 在开集识别中的优越性能,首先将本文模型与未加入 SE 模块的 PN-Open 模型进行对比,然后将本文模型与基于 OpenMax^[7-18]的开集识别模型进行对比,最后再对比本文模型在开集环境和闭集环境下的性能差别,闭集环境下的识别曲线为 PN-SE-Close。所有模型均采用本文所用数据集,对比结果如图 10 所示。




图10 不同模型的识别准确率对比

Fig. 10 Comparison of recognition rate with different models

可以看出,本文模型在开集场景下相较于其他模型具有更好的识别性能,当信噪比为 0 dB 以上时,可达到 95% 的识别准确率。在加入 SE 模块后,尤其是在低信噪比下,开集识别的性能有较大提升。另外,当信噪比为 -6 dB 以上时,开集识别准确率和闭集识别准确率相当,这也充分说明了本文模型在不同识别场景下均可以达到良好的识别性能。

在 -6、0、6 dB 下,开集识别的混淆矩阵如图 11 所示。可以看出,第 1 类和第 2 类设备容易混淆,第 3 类较为独立。即使在较低信噪比下,第 4 类和第 5 类设备的信号作为未知类目标也能够很好的被检测和拒绝。

4 结 论

本文在原型网络模型下,通过自适应距离分类规则实现了 ZigBee 设备个体的开集识别。在一维卷积神经网络中加入 SE 模块,通过调整通道权重加强分类能力;结合 DCE 损失和 PL 损失对网络的参数和原型进行联合训练,同时更新网络参数和原

设备1	0.83	0.17	0.00	0.00
设备2	0.03	0.97	0.00	0.00
设备3	0.00	0.00	0.99	0.01
未知设备	0.00	0.00	0.00	1.00
	设备1	设备2	设备3	未知设备

(b) 0 dB 下的混淆矩阵

设备1	0.95	0.05	0.00	0.00
设备2	0.00	0.99	0.00	0.01
设备3	0.00	0.00	1.00	0.00
未知设备	0.00	0.00	0.00	1.00
	设备1	设备2	设备3	未知设备

(c) 6 dB 下的混淆矩阵

图 11 开集识别下的混淆矩阵

Fig. 11 Confusion matrix under open set

设备1	0.55	0.43	0.00	0.02
设备2	0.13	0.87	0.00	0.01
设备3	0.00	0.00	1.00	0.00
未知设备	0.09	0.00	0.00	0.91
	设备1	设备2	设备3	未知设备

(a) -6 dB 下的混淆矩阵

型,有效地提高了网络的识别性能;通过引入 PL 损失,以提高类内紧密度的方式扩大了类间距离,进一步增强了模型的分类能力;通过自适应距离分类规则,完成了开集场景下的辐射源个体识别,免去了人工阈值的设定。通过实验对比可知,本文提出的网络模型在闭集环境和开集环境下都具有更高的识别精度和泛化性。后续研究应着重改进分类规则,提高基于原型的距离分类规则的鲁棒性,同时应加强对未知类样本空间的建模和分析。

参考文献:

- [1] TALBOT K I, DULEY P R, HYATT M H. Specific emitter identification and verification [J]. Technology Review, 2003: 113-133.
- [2] BIHL T J, BAUER K W, TEMPLE M A. Feature selection for RF fingerprinting with multiple discriminant analysis and using ZigBee device emissions [J].

- IEEE Transactions on Information Forensics and Security, 2016, 11(8): 1862-1874.
- [3] YANG Yinsong, GUO Ying, LI Hongguang, et al. Fingerprint feature recognition of frequency hopping based on high order cumulant estimation [C]//2018 IEEE 3rd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC). Piscataway, NJ, USA; IEEE, 2018: 2175-2179.
- [4] XU Shuhua, HUANG Benxiong, XU Lina, et al. Radio transmitter classification using a new method of stray features analysis combined with PCA [C]//2007 IEEE Military Communications Conference. Piscataway, NJ, USA; IEEE, 2007: 1-5.
- [5] 刘明骞, 颜志文, 张俊林. 空中目标辐射源的个体识别方法 [J]. 系统工程与电子技术, 2019, 41(11): 2408-2415.
- LIU Mingqian, YAN Zhiwen, ZHANG Junlin. Specific emitter identification method for aerial target [J]. Systems Engineering and Electronics, 2019, 41(11): 2408-2415.
- [6] HU Jie, SHEN Li, ALBANIE S, et al. Squeeze-and-excitation networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [7] PAN Yiwei, YANG Sihan, PENG Hua, et al. Specific emitter identification based on deep residual networks [J]. IEEE Access, 2019, 7: 54425-54434.
- [8] PENG Linning, ZHANG Junqing, LIU Ming, et al. Deep learning based RF fingerprint identification using differential constellation trace figure [J]. IEEE Transactions on Vehicular Technology, 2020, 69(1): 1091-1095.
- [9] 牛伟宇, 许华, 刘英辉, 等. 基于PACGAN与差分星座轨迹图的辐射源个体识别 [J]. 信号处理, 2021, 37(8): 1559-1567.
- NIU Weiyu, XU Hua, LIU Yinghui, et al. Individual identification method based on PACGAN and differential constellation trace figure [J]. Signal Processing, 2021, 37(8): 1559-1567.
- [10] 王春升, 王永民, 许华, 等. 基于残差原型网络的辐射源个体识别 [J/OL]. 系统工程与电子技术 [2022-06-06]. <http://kns.cnki.net/kcms/detail/11.2422.TN.20220419.1641.002.html>.
- WANG Chunsheng, WANG Yongmin, XU Hua, et al. Specific emitter identification based on residual prototype network [J/OL]. Systems Engineering and Electronics [2022-06-06]. <http://kns.cnki.net/kcms/detail/11.2422.TN.20220419.1641.002.html>.
- [11] 刘明骞, 李建英, 李兵兵, 等. 认知无线电 Underlay 模式下 MQAM 信号的调制识别 [J]. 西安交通大学学报, 2018, 52(2): 52-57.
- LIU Mingqian, LI Jianying, LI Bingbing, et al. Modulation identification of MQAM signals in Underlay cognitive radios [J]. Journal of Xi'an Jiaotong University, 2018, 52(2): 52-57.
- [12] 李彬, 徐怡杭, 罗杰. 采用残差神经网络的无人机遥控信号识别监测算法 [J]. 西安交通大学学报, 2021, 55(12): 146-154.
- LI Bin, XU Yihang, LUO Jie. A recognition and monitoring algorithm for drone remote control signals using residual neural network [J]. Journal of Xi'an Jiaotong University, 2021, 55(12): 146-154.
- [13] QING Guangwei, WANG Huifang, ZHANG Tingping. Radio frequency fingerprinting identification for Zigbee via lightweight CNN [J]. Physical Communication, 2021, 44: 101250.
- [14] ZHOU Xinyu, HU Aiqun, LI Guyue, et al. A robust radio-frequency fingerprint extraction scheme for practical device recognition [J]. IEEE Internet of Things Journal, 2021, 8(14): 11276-11289.
- [15] LIU Yinghui, XU Hua, QI Zisen, et al. Specific emitter identification against unreliable features interference based on time-series classification network structure [J]. IEEE Access, 2020, 8: 200194-200208.
- [16] WANG Yu, GUI Guan, 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] CHEN Wei, WANG Yanhua, SONG Jia, et al. Open set HRRP recognition based on convolutional neural network [J]. The Journal of Engineering, 2019, 2019(21): 7701-7704.
- [18] 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.
- [19] BENDALE A, BOULT T E. Towards open set deep networks [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA; IEEE, 2016: 1563-1572.
- [20] 林万杰. 基于深度学习的未知辐射源个体识别的研究 [D]. 成都: 电子科技大学, 2021.
- [21] 林子榆, 王翔, 孙丽婷, 等. 基于深度自编码器的辐射源个体开集识别 [J/OL]. 太赫兹科学与电子信息

- 学报 [2022-06-06]. <http://kns.cnki.net/kcms/detail/51.1746.TN.20211222.1033.002.html>.
- LIN Ziyu, WANG Xiang, SUN Liting, et al. Open set recognition of specific emitter identification based on deep auto-encoder [J/OL]. Journal of Terahertz Science and Electronic Information Technology [2022-06-06]. <http://kns.cnki.net/kcms/detail/51.1746.TN.20211222.1033.002.html>.
- [22] DRAGANOV A, BROWN C, MATTEI E, et al. Open set recognition through unsupervised and class-distance learning [C]//Proceedings of the 2nd ACM Workshop on Wireless Security and Machine Learning. New York, NY, USA: ACM, 2020: 7-12.
- [23] JI Zhong, CHAI Xingliang, YU Yunlong, et al. Improved prototypical networks for few-shot learning [J]. Pattern Recognition Letters, 2020, 140: 81-87.
- [24] YANG Hongming, ZHANG Xuyao, YIN Fei, et al. Robust classification with convolutional prototype learning [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 3474-3482.
- [25] YANG Hongming, ZHANG Xuyao, YIN Fei, et al. Convolutional prototype network for open set recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(5): 2358-2370.
- (编辑 陶晴 刘杨)