

基于深度学习与聚类的开集个体识别技术^{*}

朱争超^{1,2} 乔强¹ 郎俊杰¹ 杨鸿杰^{1,2}

(1. 中国电子科技集团公司第五十四研究所 石家庄 050051; 2. 河北省电磁频谱认知与管控重点实验室 石家庄 050051)

摘要: 针对开集场景下闭集网络无法有效识别未知类的问题,本研究提出了一种基于深度学习与无监督聚类相结合的辐射源开集个体识别(SEI)方法。通过对原始数据进行精细化的预处理以提取蕴含指纹特征的常规特征波形,将常规特征波形进行闭集网络训练,基于概率度量手段对待识别类样本进行已知/未知判决,对识别成未知类的样本提取残差网络全连接层特征进行无监督降维、聚类处理,通过聚类结果明确未知个体数量。实验结果表明,相对于传统闭集网络识别,本研究所提方法能够在已知类准确识别的前提下,实现对已知/未知类的有效区分,识别正确率均在97%以上,并能准确识别10个未知电台数目,实验结果验证了方法的有效性。

关键词: 个体识别;深度学习;无监督聚类;开集

中图分类号: TN92; TP183 文献标识码: A 国家标准学科分类代码: 510.4010

An open set SEI method based on deep learning and clustering

Wei Zhengchao^{1,2} Qiao Qiang¹ Lang Junjie¹ Yang Hongjie^{1,2}

(1. The 54th Research Institute of CETC, Shijiazhuang 050051, China; 2. Hebei Province Key Laboratory of Electromagnetic Spectrum Cognition and Control, Shijiazhuang 050051, China)

Abstract: For the problem that closed set networks cannot effectively identify unknown classes in open set scenarios, an open set specific emitter identification (SEI) method based on the combination of deep learning and unsupervised clustering was proposed. The original data is refined to extract the conventional features containing fingerprint features, and the conventional feature waveform is trained in the closed set network, based on probability measures, the known and unknown decisions are carried out on the identification class samples, and unsupervised dimension reduction and clustering are carried out on the features of the full connection layer of the residual network extracted from the samples identified as unknown classes. The number of unknown individuals was clarified the clustering results. The experimental results show that compared with traditional closed set recognition, the proposed method can realize the effective classification between known classes and unknown classes, under the known classes accurate recognition, the recognition accuracy is more than 97%, and ten unknown radios can be accurately clarified, experimental results verify the effectiveness of the method.

Keywords: SEI; deep learning; unsupervised clustering; open set

0 引言

辐射源个体识别技术,基于不同模拟器件(如调制器、混频器、滤波器、放大器等)的指纹特征差异,在信号层面提取特征进行辐射源个体区分。目前,个体识别技术主要分为两类:1)基于专家知识的指纹特征提取+机器学习分类器分类^[1-3];2)基于深度学习网络进行特征提取、分类^[4-10]。

随着新辐射源个体不断出现,个体识别常面临开集识别场景。目前,国内外学者针对开集个体识别研究成果主

要集中在已知/未知二分类方面。文献[11]提出了一种基于零样本学习的开集识别方法,通过注意力机制神经网络对特征进行挖掘,并基于语义特征空间分布进行已知/未知类识别;文献[12]提出了一种自编码器结合SVM分类器的开集识别方法,通过堆栈自编码器实现降噪、特征提取,并利用SVM进行开集分类;文献[13]提出了基于集体决策和融合语义信息的开集个体识别方法,方法缺少更新机制,难以工程化应用;文献[14]从领域自适应角度基于生成模型和判别模型进行了对抗识别,所提未知类处理方法不

够精细;文献[15]提出了基于 openMax 开集识别方法,通过对网络模型激活向量进行处理,基于已知类统计特性来推断未知类是否存在;文献[16]提出了一种开集和增量学习结合的个体识别技术,设计了元识别模型,通过深度网络与组合距离测度构建了已知/未知类边界模型。

为了有效解决通信辐射源开集个体识别难题,本文提出了一种深度学习和无监督聚类相结合的开集个体识别框架(deep-learning and clustering open-set SEI framework, DC-OSEIF),DC-OSEIF 主要包括 4 个处理单元。设计预处理单元对原始 IQ(in-phase and quadrature-phase)数据进行规范和常规特征波形提取,该处理聚焦指纹特征并对网络多通道输入源进行规范;设计残差网络对输入波形特征进行特征挖掘,通过 Softmax 层进行个体分类;设计开集判决单元以区分待识别数据中的未知类,已知类通过 softmax 分类直接采信网络输出的个体标签,未知类通过概率判决后标识成未知个体;针对未知个体数据,设计未知数量澄清单元,利用无监督降维、聚类处理技术,对未知个体数量进行识别。

为了验证方法有效性,实验使用 20 个某型超短波电台,对采集原始数据进行射频直采、样本标注、特征提取、网络训练,并利用模型进行开集识别测试,实验结果表明本文所提 DC-OSEIF 能够在准确识别已知类的基础上,实现已知类/未知类的有效判别,分类准确率在 97% 以上,并能正确澄清未知个体数量。

1 开集个体识别技术

本文所提 DC-OSEIF 结构如图 1 所示,共包括 4 个处理单元:1)样本预处理单元;2)闭集网络训练单元;3)开集判决单元;4)未知数量澄清单元。

1.1 样本预处理单元

原始数据虽然保留了信号全部特征,但也包含未体现指纹特征的冗余数据段,为了聚焦指纹特征差异,同时对网络输入波形进行规范,在网络训练前需对原始数据进行精细化预处理。

预处理设计分为两部分:样本规范化处理、常规特征波形提取。

1) 样本规范化处理设计

包括样本清洗、变频滤波、归一化、重采样、前沿对齐、符号定时同步。样本清洗有助于排除信号质量差的样本,确保指纹特征提取的信噪比需求;滤波有助于降低噪声对指纹特征提取的影响;归一化的目的是使信号在幅值上进行规范,以适应网络在数值范围、训练收敛等方面的约束;数据重采样目的是保证采样尺度的统一;前沿对齐可与定时同步配合使用,其目的是精细化的对齐信号前沿,规范输入信号的起始位置,防止数据因前后较大抖动对后续网络特征提取带来负面影响;符号定时同步的目的是为了提取星座图轨迹或眼图轨迹。

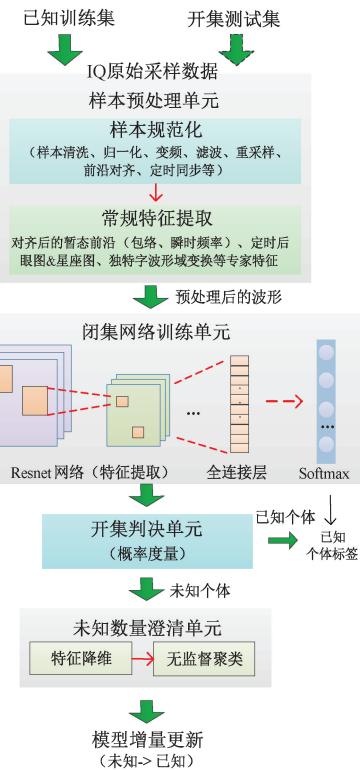


图 1 DC-OSEIF 结构图

Fig. 1 DC-OSEIF structure

2) 常规特征波形提取设计

在样本规范化的基础上提取常规特征波形,该特征虽未直接体现指纹差异,但波形趋势中却蕴含指纹特征,常规特征波形包括但不限于:对齐后的暂态前沿(暂态包络如图 2 所示、暂态相位)、定时后的眼图转移轨迹、定时后的星座图转移轨迹、独特字的域变换波形等。

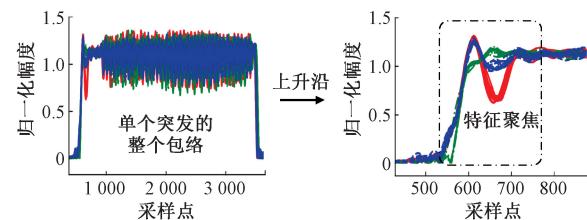


图 2 预处理聚焦的暂态前沿包络畸变特征

Fig. 2 Transient front envelope distortion characteristics of preprocessing focusing

模拟器件指纹特征在上升沿表现比较明显,通过设计前沿对齐规则将前沿差异较大的部分波形提取出来,而非将全部 IQ 波形都作为网络输入,这样可减少无关位置因素的影响,实现细微特征聚焦,从而更有利于网络发现和学习细微特征。此外,由于通信信号常携带信息,为了去除信息变化对指纹特征提取的影响,可将承载信息的数据段处理成单个符号的眼图或星座图,同时保留转移轨迹,图 3(a)为某型电台 1 个突发信号的基带波形(承载信

息),通过对信号进行定时同步、转移轨迹分类、轨迹平均,得到预处理后的眼图转移轨迹,图 3(b)为两个个体眼图转移轨迹对比图,可发现其存在细微差异,该差异主要由不同调制器的个体差异所致,可利用网络进行深度挖掘、特征提取。

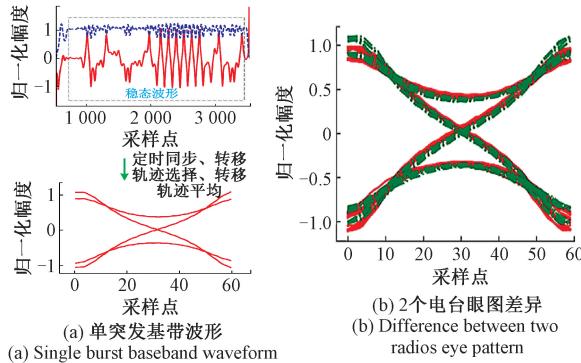


图 3 眼图轨迹特征

Fig. 3 Eye trace characteristic

总之,精细化预处理起到了样本增强、尺度统一、聚焦指纹特征的作用,为后续网络训练提供规范化的多通道输入数据。

1.2 闭集网络训练单元

本文设计的神经网络输入为预处理后的多通道特征波形,而非原始 IQ 采样数据,这种做法可提升网络训练时的泛化能力。

本文闭集网络训练采用残差网络结构,考虑原因有二:残差网络强大的时空特征提取能力、多通道处理能力。可以利用卷积层捕捉隐藏在信号里的局部细微特征,并将多个通道提取的特征进行融合,特别适用于处理一维信号、二维图像的细微特征提取。

残差单元结构图为 building block 经典单元结构(如图 4),在 CNN(convolutional neural networks)基础上引入了 shortcut 连接,通过跳过一层或更多层,将输入 x 复制一份到更深层次的网络,可有效避免梯度丢失、信息丢失,可有效解决训练“退化”问题,防止训练过拟合现象发生。

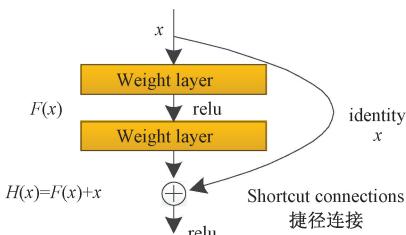


图 4 Building block 结构

Fig. 4 Building block structure

设计残差网络为 Resnet-80,网络结构共计 4 个残差卷积块,分别表示为 Conv2_x,Conv3_x,Conv4_x,Conv5_x,详细结构如表 1 所示。

表 1 Resnet 网络结构

Table 1 Resnet structure

层名称	80 layers Resnet
Conv1	3×3 conv, stride:2, padding:3
Pool	3×3 max pool, stride:2, padding:1
Conv2_x	$\begin{bmatrix} 1 \times 1 \text{ conv, 64 filters} \\ 3 \times 3 \text{ conv, 64 filters} \\ 1 \times 1 \text{ conv, 256 filters} \end{bmatrix} \times 3$
Conv3_x	$\begin{bmatrix} 1 \times 1 \text{ conv, 64 filters} \\ 3 \times 3 \text{ conv, 64 filters} \\ 1 \times 1 \text{ conv, 256 filters} \end{bmatrix} \times 4$
Conv4_x	$\begin{bmatrix} 1 \times 1 \text{ conv, 64 filters} \\ 3 \times 3 \text{ conv, 64 filters} \\ 1 \times 1 \text{ conv, 256 filters} \end{bmatrix} \times 16$
Conv5_x	$\begin{bmatrix} 1 \times 1 \text{ conv, 64 filters} \\ 3 \times 3 \text{ conv, 64 filters} \\ 1 \times 1 \text{ conv, 256 filters} \end{bmatrix} \times 3$
Other layers	average pool, fc, softmax

残差网络闭集处理流程如图 5 所示,残差网络通过多通道卷积层对输入的预处理特征数据进行卷积、池化处理,每个卷积层采用 ReLU 函数作为激活函数,卷积核大小通过控制网络参数进行调节控制,设计其后紧跟全连接层、softmax 进行分类,网络提取的深度特征体现在全连接层,该特征可解释性不强,但却客观反映了不同个体指纹特征差异所在。

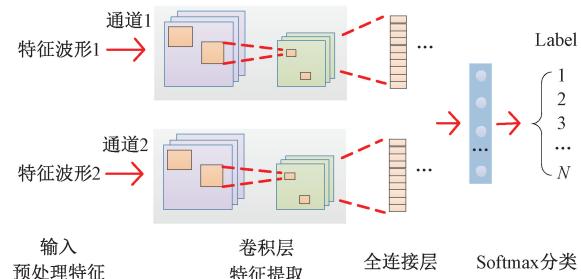


图 5 残差网络闭集处理(双通道)

Fig. 5 ResNet closed set processing(dual-channel)

1.3 已知/未知判决单元

已知/未知判决的根本依据是基于不同个体指纹特征分布的差异,残差网络提取的深度特征体现在全连接层,该层后拼接 softmax 激活函数。Softmax 将分类原始值转化为概率分布的数值,假设将待识别样本识别成闭集已知类中的每一类的概率表示成 p_i ,如式(1)所示。

$$\begin{cases} p_i = \frac{e^{x_i}}{\sum_{i=1}^N e^{x_i}} \\ p_1 + p_2 + \dots + p_N = 1 \end{cases} \quad (1)$$

式中: x 为不同类别的分类输入, $i=0, 1, 2, \dots, N$, N 为已知类别数。

已知未知判决规则(如式(2)所示)为:

规则 1)若待分类样本 softmax 输出的 p_i 值均小于设定概率阈值, 则认定待分类样本不符合已知类的概率分布, 待识别样本和所有已知样本均不相似, 此时可将待分类样本判定为未知类;

规则 2)若待分类样本 softmax 输出的 p_i 值存在大于设定概率阈值的情况, 则认定待分类样本和已知类第 i 个标签个体相似度高, 则判定待分类样本为已知类。

$$\begin{cases} type = 0, \max(p_i) \geq thd \\ type = 1, \max(p_i) < thd \end{cases} \quad (2)$$

式中: $type=0$ 代表已知个体, $type=1$ 代表未知个体, p_i 为 softmax 输出的识别成已知类中的每一类的概率值, $i=0, 1, 2, \dots, N$, N 为类别数, thd 代表概率阈值。

Thd 值设定需要依据信道环境、传输系统类型、工程经验综合设定, 为了有效平衡虚警和漏警, 典型值可设置为 0.8, 该方法基于阈值门限通过分布概率进行度量, 工程实现相对简单。

通过已知/未知判决单元判决为已知个体时, 标签直接采信 softmax 层的输出结果, 判决为未知个体时, 则需要进行未知数量的澄清。

1.4 特征降维、无监督聚类

网络提取的特征为高维度特征, 为实现未知数量澄清, 则需要对该特征进行聚类处理, 若直接聚类会导致维度灾难、模型过拟合, 在聚类之前需要进行降维处理。无监督降维方法包括线性降维法、非线性降维法, 其中工程中比较常用的是 TSNE (t-distributed stochastic neighbor embedding) 降维法。TSNE 于 2008 年提出用于探索高维度数据的降维方法, 可由 T 分布和随机近邻嵌入标识, 通过将数据间的相似性转化为概率, 可将数据降低至 2-3 维可视化, 该方法改变了流行学习中距离不变的思想, 将高维映射到低维度的同时, 尽量保证分布概率不变, 可用于进行高维度特征降维处理。若不同个体的细微特征差异比较明显(具备特征簇的可区分性), 则通过二维特征可视化可直观看出未知个体数量, 可基于无监督聚类技术实现数量判定。通过工程化的摸索及不同聚类方法的性能对比, 基于密度的空间聚类方法 DBSCAN (density-based spatial clustering of applications with noise) 性能突出, 该算法核心思想为: 对于给定的数据集, 首先找到核心对象, 在给定的半径内至少包含设定数量的点, 然后从核心对象出发, 通过密度可达性关系, 将紧密相连的核心对象归为一族, 不属于任何簇的点被视为噪音点。

图 6 为未知个体数量澄清流程图, 针对判定为未知个体的全连接层高维度特征进行无监督降维、聚类处理, 可用于未知个体数量澄清。

本文所提技术框架具备以下 3 个特点:

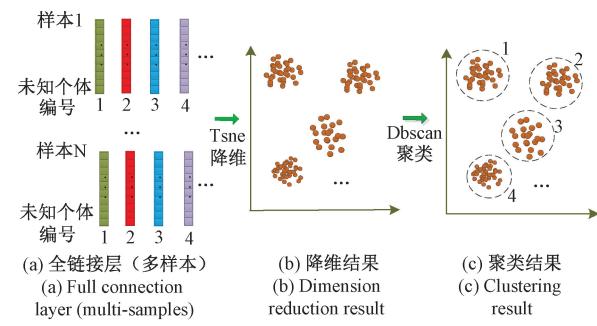


图 6 未知个体数量澄清流程

Fig. 6 Number of unknown individuals identified

1) 网络输入为精细化预处理后的特征波形, 并非原始 IQ 数据, 此处理聚焦了指纹特征, 并提升了网络泛化能力。

2) 利用多通道闭集网络 softmax 层的识别概率结果设定分类阈值, 将待识别类判决问题转换为概率度量问题, 方法简单、工程易实现。

3) 开集场景下模型必须具备可扩展性, 需具备区分未知个体数量的能力, 本文针对网络深度特征进行降维、聚类处理, 能有效澄清未知个体数目, 具备未知变已知的增量更新能力。

2 实验与结果

为了评估本文所提的基于深度学习和聚类的开集个体识别方法的可行性和有效性, 选取 20 个某型超短波电台为实验对象, 将其中一半数量电台设成已知类, 另一半电台设成未知类, 数据采集场景为射频直采, 网络运行环境为 Windows10 系统下的 Pytorch 框架, 训练和测试所用的服务器 GPU 为 NVIDIA RTX3070。本文设置 3 个实验任务, 1) 利用 DC-OSEIF 对已知类进行个体识别; 2) 利用 DC-OSEIF 对已知/未知电台混叠场景进行个体分类; 3) 利用 DC-OSEIF 澄清实验中的未知电台个体数量。

2.1 实验过程

实验电台情况如表 2 所示, 每个电台用于训练的样本数量 $N \geq 10000$ 条。

表 2 试验电台情况

Table 2 Experimental radios condition

个体类型	数量	频段/MHz	信号类型	信号模式
已知	10	30~90	定频	战斗网
未知	10	30~90	定频	战斗网

对于采集的 10 个已知电台数据, 进行样本标注、特征提取、网络训练。网络设计为双通道输入, 通道 1 为 1×240 (样点)暂态前沿对齐波形, 通道 2 为 1×240 (样点)眼图转移轨迹波形; 残差网络设计为 Resnet80, 网络结构 [3, 4, 16, 3], 训练 Batchsize 为 64, 初始学习率为 1×10^{-5} , 训

训练轮数 Epoch 为 100。

利用预处理单元对 20 个电台的前沿畸变特征波形进行提取, 图 7 为前沿对齐后的 3 个电台信号的上升沿波形示意图, 可以看到暂态部分的幅度畸变特征差异比较明显, 该差异反应功放、滤波器的器件个体差异, 将其作为残差网络一个通道的输入。

利用预处理单元对 20 个电台的眼图转移轨迹特征波形进行提取(如图 8 所示), 将 4 条眼图转移轨迹拼接成一维向量作为残差网络第 2 个通道的输入。

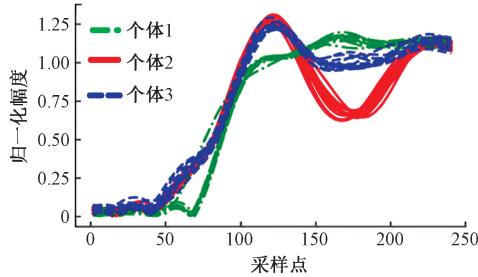


图 7 暂态前沿对齐波形

Fig. 7 Transient front alignment waveform

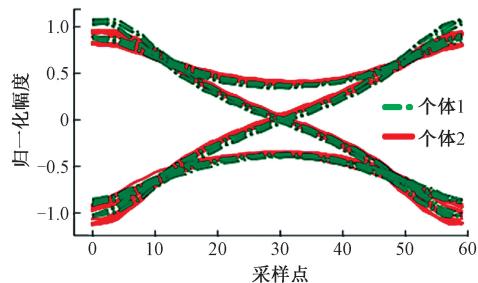


图 8 眼图轨迹特征波形

Fig. 8 Eye trace characteristic waveform

将上述两个特征波形输入到残差网络进行训练, 80% 样本用于训练, 20% 样本用于模型测试。网络训练过程的平均损失在 30 轮左右趋于平稳, 利用样本进行模型测试, 保存闭集网络模型, 并利用模型进行已知类、未知类识别性能测试。

2.2 实验结果分析(已知类个体识别)

在已知类个体识别实验中, 识别结果的混淆矩阵如图 9 所示, 纵坐标为个体真实标签, 横坐标为利用 DC-OSEIF 输出的个体预测标签, 其中电台 1 和 2、6 和 7 混叠较多, 电台个体特征相似。从已知个体识别整体结果来看, 已知类分离效果良好, 所提 DC-OSEIF 对已知类的个体识别正确率达到 97% 以上, 可以有效识别已知类个体标签。

2.3 实验结果分析(已知/未知分类)

在已知/未知分类实验中, 利用残差网络训练的 softmax 层识别概率作为度量基准, 设定概率度量阈值为 0.82, 对混叠有已知未知类的待识别电台进行识别正确率统计, 结果如表 3, 从判决结果可以看出, DC-OSEIF 对已知

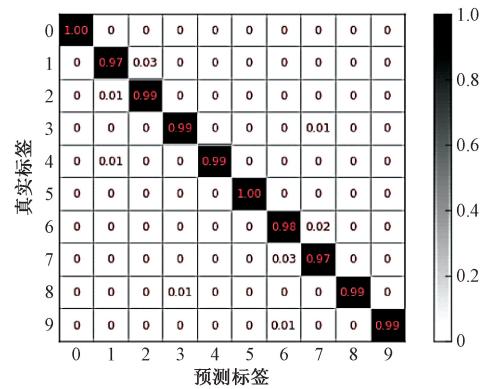


图 9 10 个已知电台混淆矩阵

Fig. 9 Ten known radios confusion matrices

类、未知类识别结果均在 98% 左右, 所提方法能有效提取已知类、未知类的特征分布差异, 可以实现已知类、未知类的有效分类。

表 3 已知、未知分类结果(经过预处理单元)

Table 3 Known and unknown classification results

状态	(with preprocessed unit)		%
	识别	待识别	
已知类	98.63	1.37	
未知类	98.94	1.06	

本文相对于直接利用原始数据(未经样本预处理单元处理)进行网络训练后的识别结果(如表 4), 其性能提升约 1.84%, 主要原因是本文预处理单元对输入数据进行了规范化处理, 聚焦了指纹特征的差异。

表 4 已知、未知分类结果(直接输入 IQ 数据)

Table 4 Known and unknown classification results

状态	(Enter IQ data directly)		%
	识别	待识别	
已知类	97.32	2.68	
未知类	96.57	3.43	

2.4 实验结果分析(未知个体数量澄清)

在未知个体数量澄清实验中, 取出残差网络提取的全连接层特征, 按照表 5 进行降维、聚类算法参数设定。

表 5 降维、聚类参数设定

Table 5 Dimension reduction clustering parameter setting

类型	具体参数
降维	TSNE, n components = 2
聚类	DBScan, eps: 5, min_samples: 10

利用 TSNE 将被判定为未知的样本对应的网络全连接层特征进行降维(效果如图 10 所示), 可以看出未知个体

特征呈分簇现象,不同个体特征聚敛程度不同,但均呈现分堆现象,降维效果表明采用 DC-OSEIF 框架提取的个体指纹特征聚敛性较高,个体差异被网络学习到并进行了有效表征。

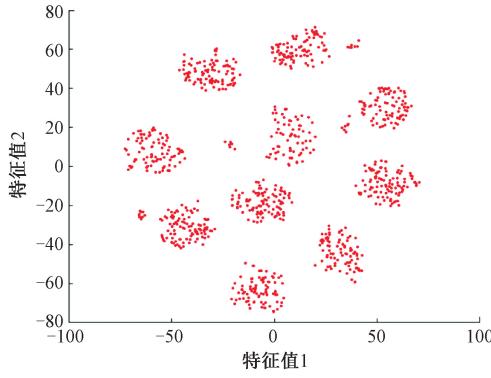


图 10 未知个体特征降维图

Fig. 10 Unknown individual feature dimension reduction

利用 DBSCAN 对降维后的二维特征进行无监督聚类(效果如图 11),每种点型代表一个个体,从聚类结果可以看出,除了一些噪点未聚成簇之外,待识别的未知个体特征共聚成 10 簇,每簇代表一个未知个体,和实验设定的未知个体数量一致。

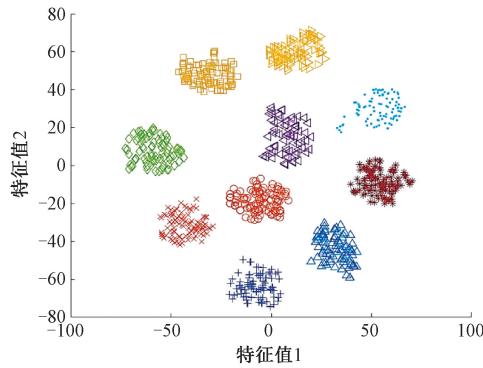


图 11 未知个体特征聚类图

Fig. 11 Unknown individual feature clustering

从降维、聚类效果可以看出,DC-OSEIF 框架可有效澄清未知个体数量,并可对特征进行可视化展示,方便后续未知个体标注、模型增量更新。

3 结 论

本文提出了一种基于深度学习与聚类相结合的开集个体识别技术,首先针对采集的 20 个电台原始数据进行预处理,提取常规特征波形,基于实验任务将 20 个电台划分已知类、未知类,然后利用残差网络对指纹特征进行深度学习、特征提取,利用训练好的网络模型对已知类进行个体识别、对已知类/未知类进行分类,并利用降维、聚类技术澄清未知个体数量。实验结果表明,相对于传统闭集网络识别,本文所提 DC-OSEIF 能够在已知类准确识别的前提下,实

现对已知/未知类的有效区分,识别正确率均在 97% 以上,并能准确识别 10 个未知电台数目。所提方法对从事 SEI 的研究人员具备一定的参考价值。

本文只研究了高斯信道下的开集个体识别性能,采集数据信噪比较高($SNR \geq 20$ dB),对衰落信道、跨接收机、低信噪比等场景下的算法性能有待进一步测试。

参考文献

- [1] 刘博. 辐射源个体识别技术的发展现状及应用建议[J]. 电子信息对抗技术, 2019, 34(4): 40-43.
- [2] LIU B. Development status and application suggestions of specific emitter identification technology[J]. Electronic Information Warfare Technology, 2019, 34(4): 40-43.
- [3] 彭林宁, 胡爱群, 朱长明, 等. 基于星座轨迹图的射频指纹提取方法[J]. 信息安全学报, 2016, 1(1): 50-58.
- [4] PENG L N, HU AI Q, ZHU CH M, et al. Radio frequency fingerprint extraction method based on constellation trajectory diagram[J]. Journal of Cyber Security, 2016, 1(1): 50-58.
- [5] 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.
- [6] XU M, LI B H, WANG K, et al. Research on specific emitter identification method[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 116-123.
- [7] 刘剑锋. 基于深度学习的通信辐射源个体识别关键技术研究[D]. 郑州: 战略支援部队信息工程大学, 2021.
- [8] LIU J F. Research on key technologies of specific emitter identification based on deep learning [D]. Zhengzhou: Strategic Support Army Information Engineering University, 2021.
- [9] 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.
- [10] LIU F H, ZHANG ZH ZH, ZHANG T, et al. Research on adversarial attack in specific emitter identification[J]. Electronic Measurement Technology, 2023, 46(16): 16-23.
- [11] 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.
- [12] TANG ZH, QIAO X Q, ZHANG T, et al. Specific emitter identification method based on deep residual shrinkage network [J]. Electronic Measurement Technology, 2022, 45(9): 168-174.
- [13] WU Q, FERES C, KUZMENKO D, et al. Deep learning based RF fingerprinting: A massive experimental study[J]. IEEE Internet of Things Magazine, 2020, 3(1): 50-57.
- [14] 吴子涛. 基于深度学习的辐射源个体识别技术研究[D]. 北京: 北京交通大学, 2023.

- WU Z T. Research on emitter identification based on deep learning[D]. Beijing: Beijing Jiaotong University, 2023.
- [9] 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.
- LIN W J. Research on unknown emitter identification based on deep learning [D]. Chengdu: University of Electronic Science and Technology of China, 2021.
- [10] 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 K. Specific emitter identification based on semi-supervised deep learning[D]. Beijing: China Academy of Electronics and Information Technology, 2021.
- [11] 孙程远, 杜奕航, 张涛, 等. 基于零样本学习的未知辐射源个体识别研究[J]. 电子测量技术, 2023, 46(22): 41-48.
- SUN CH Y, DU Y H, ZHANG T, et al. Specific emitter identification based on zero sample learning[J]. Electronic Measurement Technology, 2023, 46(22): 41-48.
- [12] 刘志文, 陈旗, 满欣. 基于 SDAE_SVDD 的通信辐射源个体开集识别方法[J]. 电子信息对抗技术, 2023(4): 26-31.
- LIU ZH W, CHEN Q, MAN X. Communication emitter identification based on SDAE_SVDD [J]. Electronic Information Warfare Technology, 2023(4): 26-31.
- [13] 耿传兴. 闭集与开集识别场景中若干问题研究[D]. 南京: 南京航空航天大学, 2020.
- GE CH X. Research on some problems in closed set and open set recognition scenarios [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2020.
- [14] 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(9): 864-872.
- ZHANG B H, LIU S T. Research progress of unknown emitter identification [J]. Journal of China Academy of Electronics and Information Technology, 2023(9): 864-872.
- [15] YANG G W, ZHOU SH J, WAN M H. Open-set recognition model based on negative-class sample feature enhancement learning algorithm [J]. Mathematics, 2022, 10(24): 4725.
- [16] 张子豪. 基于开集和增量学习的辐射源个体识别研究[D]. 天津: 天津大学, 2020.
- ZHANG Z H. Research on specific emitter identification based on open set and incremental learning[D]. Tianjin: Tianjin University, 2020.

作者简介

未争超, 硕士研究生, 工程师, 主要研究方向为信号处理、机器学习相关方向。

E-mail: 450479133@qq.com

杨鸿杰(通信作者), 硕士研究生, 主要研究方向为机器学习相关方向。

E-mail: 326662956@qq.com