

文章编号: 2095-4980(2022)12-1285-07

基于深度自编码器的辐射源个体开集识别

林子榆, 王翔*, 孙丽婷, 柯达, 柳征

(国防科技大学 电子科学学院, 湖南 长沙 410073)

摘要: 为实现对城市用频设备的精确管控, 针对特定辐射源开集识别问题, 构建了一套基于深度学习的辐射源个体开集识别处理流程, 核心在于指纹特征有效区间筛选与基于深度自编码器的开集识别模型。一方面, 通过使用 Grad-CAM 实现对深度网络激活可视化, 筛选出信号对网络激活贡献较高的部分, 在不损失过多指纹信息的情况下进行信号区间筛选; 另一方面, 建立基于半监督对抗自编码器的辐射源个体开集识别模型, 实现对电磁环境中出现的未知辐射源个体的有效识别。实验表明此开集识别模型能够在不损失闭集识别率的条件下实现高精度的开集识别。

关键词: 辐射源识别; 开集识别; 深度学习; 自编码器; Grad-CAM 算法

中图分类号: TN957.52

文献标志码: A

doi: 10.11805/TKYDA2021180

Open set recognition of specific emitter identification based on deep auto-encoder

LIN Ziyu, WANG Xiang*, SUN Liting, KE Da, LIU Zheng

(College of Electronic Science and Technology, National University of Defense Technology, Changsha Hunan 410073, China)

Abstract: A processing process of open-set specific emitter identification is built in order to achieve accurate control of urban frequency equipment. The core lies in the effective interval filtering of fingerprint features and the open set recognition model based on the deep self-encoder. By visualizing deep network activation using Class Activation Mapping(Grad-CAM), the section of signal contributing more to neural network activation can be determined, and then interval filtering for the signal can be performed without losing too much fingerprint information. On the other hand, an open-set specific emitter identification model is established based on semi-supervised adversarial autoencoders, achieving effective monitoring and identification of unknown emitters that may occur in the spectrum. Experiments show that Grad-CAM can filter out the most advantageous part of the extracted signal fingerprint, and the proposed model can achieve high-precision open set recognition without degrading the closed set recognition rate.

Keywords: specific emitter identification; open set recognition; deep learning; deep self-encoder; Grad-CAM

现代城市内电磁频谱环境复杂多变, 有各种合法用频设备, 如手机基站、无线路由器、蓝牙设备、物联网、广播发射台、民航飞机等; 也有各种可能对人身和财产安全造成威胁的非法辐射源, 如黑飞无人机、伪基站、考场作弊发射器、非法电台、银行卡盗刷设备等。对于这些设备, 传统的电磁频谱监测手段已无法满足。

在城市频谱监管中, 对电磁环境构建多层次多类别的画像, 可以实现对城市用频设备的精确管控。现有电磁频谱监测手段主要对空间内全体辐射源的工作时间、空间、频率、极化、调制方式、调制参数、功率及敌我属性等特性进行监控, 构建的画像细粒度较低, 难以实现对辐射源个体的有效辨识。因此, 需要建立用频设备的细微特征提取方法, 构建更深层次电磁目标画像, 实现城市频谱的“精准”监控。

特定辐射源识别(Specific Emitter Identification, SEI)是一种通过从信号中提取外部特征来实现对无线电发射

收稿日期: 2020-03-04; 修回日期: 2020-05-10

基金项目: 湖南省创新群体研究资助项目(2019JJ10004)

*通信作者: 王翔 email:christopherwx@163.com

机进行精确分类识别的技术,可以对辐射源个体进行精确区分,从而提升电磁环境画像的细粒度。应用SEI技术,能够在接收用频设备信号的情况下,实现信号所属辐射源的身份识别,完成对电磁环境中非法辐射源或违法用频设备的检测。

随着人工智能的兴起及广泛应用,根据是否使用深度学习相关技术,目前SEI分为传统特征提取和深度学习两类方法。传统特定辐射源识别主要包含特征提取和分类识别2个过程,按照对发射机工作状态的关注点的不同,特征提取可分为暂态特征提取^[1]和稳态特征提取^[2]。在特征提取时,应用谱相关理论^[3]、小波分析^[4]、分形维数^[5]、模态分解^[6]等数学分析工具。在提取特征之后,选择分类器,如最大似然分类器^[7]、支持向量机^[8]、集成学习^[9]等进行分类识别。传统基于特征提取的SEI方法面临如下问题:一是人工预定义的特征在SEI系统中的有效性和泛用性有待进一步评估,处理流程相对比较复杂,对先验知识要求较高;二是缺乏有效统一的指纹特征分析模型,依赖研究者主观经验,存在盲目性。为了弥补传统方法的不足,众多学者将深度学习引入到SEI问题中^[10-11]。利用输入数据进行自主学习,根据设定的目标函数,实现辐射源特征自动挖掘与提取。

但目前的基于深度学习的SEI方法也存在着如下问题:一是网络输入问题。是直接输入原始信号数据还是预先定义的特征,存在一定的争论。从智能化的角度看,输入原始信号数据,使用神经网络进行特征自动提取,是应用深度学习技术的目的。但目前的方法存在缺乏可解释性、过拟合、泛化差等各种缺点,且由于SEI非合作、过采样的特点,输入信号原始数据通常为一段点数很长的突发信号,导致需要使用参数量很大的网络;二是基于深度学习的方法大都遵循着闭集假设,即所有数据集中辐射源个体都是已知的,没有未知的辐射源个体。但现实条件下,随着用频设备的不断增加,SEI必定是一个开集问题,即在测试阶段会出现训练阶段从未出现的辐射源个体,此时如果继续使用闭集SEI系统,将会出现严重错误。

为了解决上述不足,本文创新地提出以下观点:第一,引入类别热力图(CAM)^[12]进行网络的可解释表达,进而剔除指纹特征信息较少的信号数据段,降低网络输入维度,减小网络规模,提高学习效率与精确度;第二,为解决基于深度学习的SEI方法面临的开集识别问题,提出基于深度自编码器^[13]和极值理论^[14]的SEI开集识别模型,可以区分测试数据中的未知辐射源个体。

1 辐射源个体开集识别流程

根据经典的开集识别分类方式^[15],本文将所有辐射源个体按照是否可以获得用于训练的数据,及是否具有先验信息,分为已知已知类(Known Known Classes, KKC)、已知未知类(Known Unknown Classes, KUC)、未知已知类(Unknown Known Classes, UKC)、未知未知类(Unknown Unknown Classes, UUC)4类。目前的开集识别方法主要目的是实现KKCs与UUCs的区分。应用到SEI个体识别中,一类即一个辐射源个体。KKCs指的是该辐射源个体在训练阶段能得到其标签数据;UUCs指的是该个体在训练阶段完全无法得到任何的数据及先验信息,但该个体在模型的测试阶段可能会出现。在闭集识别中,仅对KKCs进行分类,没有考虑到UUCs的存在,即KKCs占据了整个特征分类空间。这样的情况下,若继续使用闭集识别模型进行特征空间的划分,UUCs会被分类为KKCs。

辐射源个体的开集识别难点在于同型号辐射源的个体特征差异非常小,即类间距离很小。相比计算机视觉领域,SEI在闭集分类中的各个KKCs本就难以区分,加之考虑到环境因素的影响,对分类器的鲁棒性提出了更高的要求。

辐射源个体闭集识别已具备一套完整的处理流程。无论是传统特征提取的方法,还是深度学习的方法,在处理的整体结构上基本一致,均包含3个过程:预处理、指纹特征提取和分类识别。本文在这3个基本处理过程的基础上,结合开集识别思想,提出辐射源个体开集识别流程。

训练阶段,系统流程如图1所示。

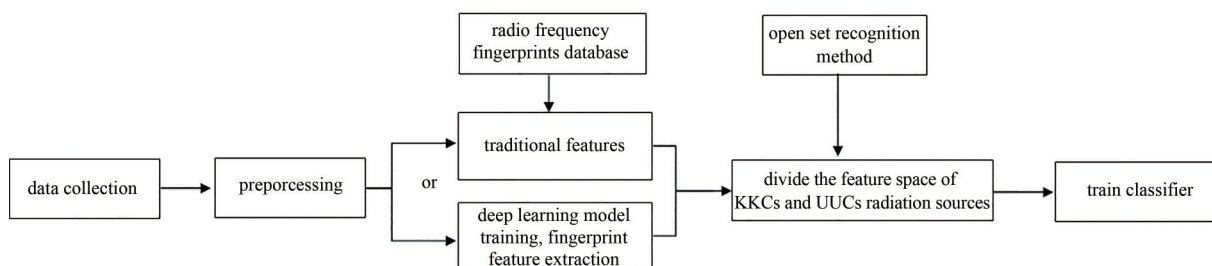


Fig.1 Training process of open-set specific emitter identification

图1 辐射源个体开集识别系统训练流程

在对各个辐射源个体进行数据采集后，会对接收到的信号时间序列进行检测、滤波、截取、变频等预处理，克服各种因素的影响，如：对多普勒频移，可以通过频率的精确估计和变频进行处理。

测试阶段的系统流程如图 2 所示。




Fig.2 Testing process of open-set specific emitter identification system
图 2 辐射源特体开集识别系统测试流程

2 辐射源个体开集识别模型

本文结合辐射源个体识别任务的特点，在经典自编码器的基础上提出了一种有效指纹区间筛选方法，能够定位辐射源指纹最明显的信号区间，从而筛选掉无用的信号，降低了有效特征提取的难度。在筛选出有效指纹区间的基础上，构建了如图 3 所示的辐射源信号数据的深度自编码器开集识别网络。




Fig.3 Overall framework of open-set recognition model
图 3 开集识别模型整体框架

2.1 指纹特征有效指纹区间筛选

对于采样总点长为 l 的信号数据，若将其均等划分为 k 段 l/k 长的数据，每段数据所含有的辐射源个体指纹特征的信息量不是均等的。记原始信号数据为 s_t ，窗为：

$$w(t_0, b) = \begin{cases} 1 & t_0 < t \leq t_0 + b \\ 0 & \text{其他} \end{cases}, t_0 \in \mathbf{R}, b \in \mathbf{R}_+ \quad (1)$$

加窗后数据为 $s_w = s_t \cdot w$ ，通过调整 t_0 可以实现窗的滑动。若原始数据集为 $\mathbf{S} = (s_1, s_2, \dots, s_n)$ ，加窗后数据集为 $\mathbf{S}_{w(t_0, b)} = (s_1 \cdot w, s_2 \cdot w, \dots, s_n \cdot w)$ ，分别取 $t_0 = t_k, k \in \mathbf{R}_+, k \in \mathbf{N}_+$ ，固定窗宽度 b 。分别提取出不同窗的信号 $\mathbf{S}_{w(t_0, b)}$ 进行深度学习训练。

基于 7 架民航飞机机载雷达信号数据集(见第 3 节)进行实验，取 $t_0 = 50k, k = 1, 2, \dots, b = 128$ 。对不同的 t_0 情况下的数据集分别进行训练测试，得到准确率的变化曲线如图 4 所示。从图中可以看出，使用信号最前沿的 128 点数据即突发上升沿部分进行训练识别，能够取得最高的识别准确率(实际上与输入整段 4 096 点数据的准确率相当)。当窗滑动至未包括前段数据的信号段时，识别率会迅速下降，且这些信号段的数据具有不同的识别率，从而得出这样一个结论：辐射源个体时域的不同分段具有的指纹特征信息量是有差异的。对于突发数据，突发的上升沿基本上包含了所有的指纹特征信息。

为了实现对指纹特征的准确定位，本文提出指纹特征有效区间筛选方法，基于神经网络分类器，利用其特征可视化中的类别热力图^[12]，发现输入信号数据中对网络响应贡献最高的部分。网络响应贡献越高，在最后分类时 SoftMax 输出得分则越高，则可认为具有更多的辐射源个体指纹特征信息。通过应用 CAM 技术获得的可视化的信息，能够引导网络更好地学习，如可以利用 CAM 信息剔除指纹特征信息较少的输入信号数据段，在提取鲁棒且有效的特征的同时，也能提高计算效率。




Fig.4 Change of recognition accuracy rate
图 4 识别准确率变化曲线

本文采用基于梯度的 CAM 技术(Grad-CAM)^[16], 在原有图像视觉方法的基础上, 将其应用至一维信号数据。在第 3.2 节的实验结果中可以发现, 输入数据前段对网络响应贡献最高。

2.2 自编码器开集识别网络

Ranya Almohse 等^[17]使用对抗自编码器(Adversarial Auto-Encoder, AAE)^[13], 与开集识别中的常用极值理论^[14]结合, 提出了基于 AAE 的开集识别网络。由于 SEI 识别任务各类的类间距离非常小, 难以使用无监督的方式实现开集识别, 还需要结合标签信息使重构数据服从原始类别分布。本文在半监督 AAE 模型^[13]的基础上, 构建图 5~图 6 所示的开集识别模型。图中的“+”、“-”号表示作为输入鉴别器的真、伪输入。 x 为原始一维信号输入, x' 为解码器重构输出, z 为编码器输出隐变量, z^+ 为从正态分布采样, y^+ 为输入信号真实标签 one-hot 表示, y^- 为编码器 SoftMax 输出。

在模型训练阶段, 通过 3 个鉴别器 D_z , D_y , D_x 实现对抗, 训练生成器最终目的是使伪输入能够欺骗鉴别器, 即使伪输入与真输入尽可能地逼近。3 个鉴别器的作用分别为:

1) 通过 D_z 使隐变量符合正态分布: 在与编码器 E 的对抗训练过程中, 鉴别器 D_z 会迫使隐变量(伪输入, 标签为假)与随机变量(真输入, 标签为真)分布相同, 从而实现基本的对抗自编码器结构;

2) 通过 D_y 使分类空间符合闭集分类: 在与编码器 E 对抗训练过程中, 由于输入真实分类标签作为真输入, 从而鉴别器 D_y 会迫使编码器 SoftMax 输出(伪输入)逼近真实闭集分类空间;

3) 通过 D_x 使重构与原始输入更加近似: 在与解码器 D 对抗训练过程中, 由于真输入为原始样本, 则编码器 D 生成的伪样本 x' 会尽可能与 x 趋向一致。

在模型测试阶段, 通过使用编码器输出可实现闭集分类。对重构误差使用极值理论模型进行概率门限检测^[17]则可以实现开集识别。

3 开集实验及结果分析

3.1 实验数据集

使用采集自 7 架民航飞机搭载的工作于模式 S 的二级监视雷达数据, 对提出方法有效性进行实验。信号采集时使用的信道环境和接收设备保持不变。采样频率为 250 MHz, 采样中频为 60 MHz。对每个 SSR 发射机, 有 300 个高质量样本, 共 2 100 条数据。

二次雷达 S 模式应答数据块可容纳 56 bit 或 112 bit 的数据, 只有下行链路 AP 字段的编码从 24 位模式 S 地址序列中直接产生, 除全呼应答外, 4 种应答数据格式中的飞机 AP 字段均位于最后 24 位数据位^[18]。本文截取突发信号前 4 096 点对应前 16 μ s 的信号, 每一数据位持续时间为 1 μ s, 前 16 位数据位。本文截取的信号数据只有采集到的全呼应答会包含 8 位的 AP 字段, 除全呼应答之外的数据格式均不包含 AP 字段。由于数据集为对飞机应答信号的随机采集, 对于同一辐射源目标的多种应答数据格式均进行了采集。而只有少部分数据为全呼应答, 大部分数据不包含各个飞机独有数据段, 从而可以认为传输数据的不同不会对准确率产生影响。

本文采用开放度(Openness)来描述不同实验条件下的开集识别难度, 开放度定义为:

$$Openness = 1 - \sqrt{\frac{2C_{TR}}{C_{TR} + C_{TE}}} \quad (2)$$

式中: C_{TR} 表示训练中会出现的类数; C_{TE} 表示测试中会出现的类数。开放度取值越大, 表明 UUCs 越多, 开集识

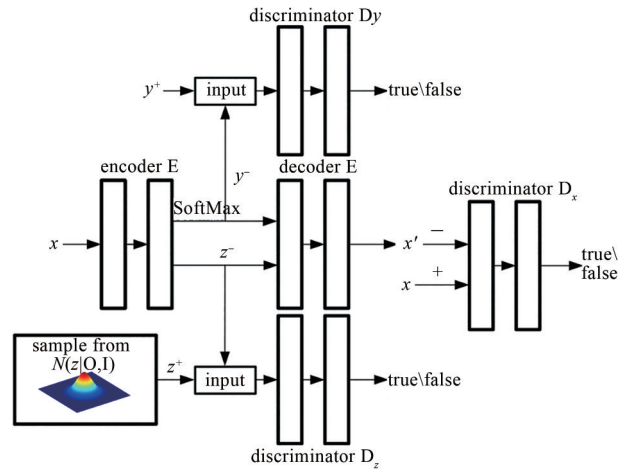


Fig.5 Training process of open-set model
图 5 开集模型训练流程




Fig.6 Testing process of open-set model
图 6 开集模型测试流程

别难度越大。

在 7 类中选择 4 类作为 KKC 进行闭集识别，剩下 3 类作为 UUCs 依次加入进行开集识别($C_{TR}=4, C_{TE}=4,5,6,7$)，则开集任务的开放度分别为 0,0.057,0.105,0.147。

采用受试者工作特征曲线(Receiver Operating Characteristic Curve, ROC)下的面积(Area Under Curve, AUC)^[19]和 F1 分数(F1-Score)对开集识别方法的性能进行评估。对于分类器来说，AUC 作为一个数值，对应 AUC 更大的分类器效果更好，当 AUC 数值接近于 1，分类器接近完美。一般来说当 AUC 在 0.85~0.95 时，分类效果可以认为很好。另外一个指标 F1-Score 用于综合考虑分类器识别结果的精准率(precision)和召回率(recall)，定义如下：

$$F_1 = 2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (3)$$

当 F1-Score 越接近于 1，表示分类器分类效果越好，目前图像领域开集识别中，F1-Score 达到 0.6 可以认为有较好的开集识别效果。

模型进行训练、测试的软件环境为：Python 3.8.0,Pytorch 1.6.0,NVIDIA Cuda 10.2,NVIDIA Cudnn 7.6.5。硬件配置为 Intel Xeon Gold 6230R CPU 2.10 GHz,RAM 128 G,Nvidia Tesla V100S。

3.2 特征有效指纹区间筛选实验

本文采用在数据集下训练好的 VGG19 网络^[20]进行 Grad-CAM 可视化。本文所用到的 VGG19 及 VGG11 网络参数设置如表 1 所示。其中 conv 表示卷积层，maxpool 表示最大池化层，FC 表示全连接层。与图像识别网络的区别主要在于，为了适应一维信号输入，将 3×3 的二维卷积核替换 1×3 的一维卷积核。

对 2 100 条数据，截取突发信号的前 4 096 点，按照 8:2 划分训练集与测试集，在不过拟合的情况下，测试集上识别精确度达到 95%，总共使用 71 个训练 epoch，训练耗时 3 min 12 s，网络参数量为 40 247 110。

然后进行 Grad-CAM 计算，结果如图 7 所示，图 7(a)~(g) 分别为从接收机 1 到 7 随机选取的一个信号样本及对应 Grad-CAM 类别激活热力图。对于整个数据集，除去个别离群数据，Grad-CAM 高激活的部分基本上都在前 500 点内。从 Grad-CAM 可视化结果推断，对于二次雷达突发信号数据集，前 500 点具有的指纹特征要比后段要高。

表 1 网络参数设置

Table1 Network parameter setting

VGG11	VGG19
input(1×4 096 signal data)	
conv1×3-64	conv1×3-64
	conv1×3-64
maxpool	
conv1×3-128	conv1×3-128
	conv1×3-128
maxpool	
	conv1×3-256
conv1×3-256	conv1×3-256
conv1×3-256	conv1×3-256
	conv1×3-256
maxpool	
	conv1×3-512
conv1×3-512	conv1×3-512
conv1×3-512	conv1×3-512
	conv1×3-512
maxpool	
	conv1×3-512
conv1×3-512	conv1×3-512
conv1×3-512	conv1×3-512
	conv1×3-512
maxpool	
	FC-512
	FC-7
	SoftMax

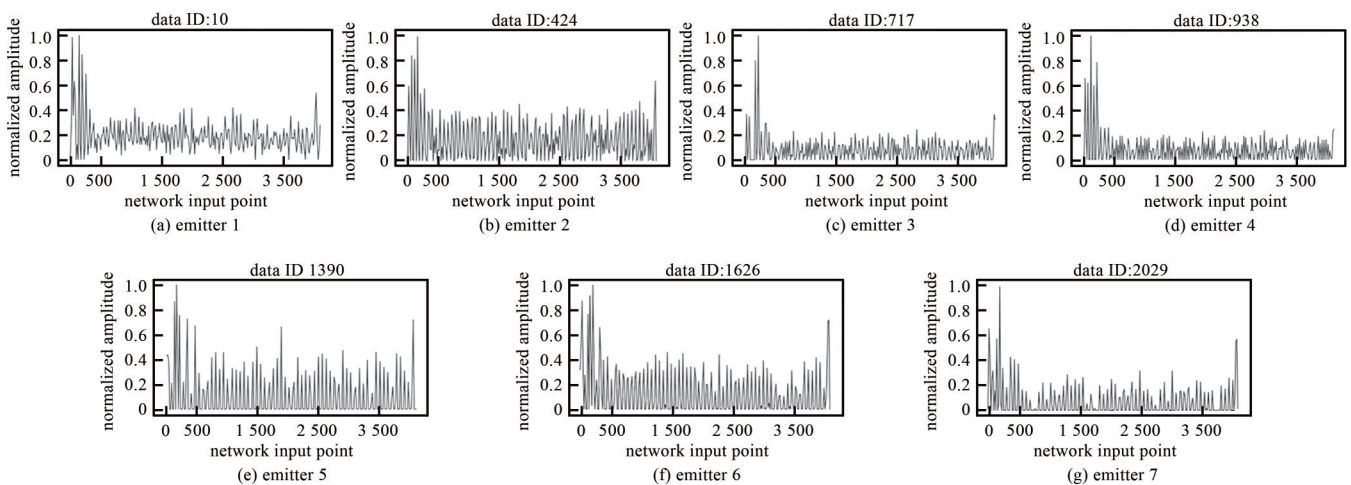


Fig.7 Visualization results of Grad-CAM

图 7 Grad-CAM 可视化结果

在相同的条件下, 只取数据集中各条数据前 512 点, 同样使用 VGG19 进行网络训练, 仅使用 30 个 epoch, 测试集上识别精确度达到 95%。但网络输入维度由 4 096 减小到 512, 训练耗时 52 s, 网络参数数量为 10 886 982, 参数数量的减小主要在于全连接层。

由实验结果来看, 使用 Grad-CAM 可以很好地剔除指纹特征信息较少的输入信号数据段, 避免这些信号段对特征提取的干扰, 使特征提取模块提取到更加鲁棒、有效的特征, 同时可以减小网络输入维度、参数规模, 提高学习效率与识别精确度。

3.3 开集识别实验

在本节, 使用数据前段 512 点进行开集识别实验。自编码器开集识别网络可以根据不同任务需要选择不同深度的网络作为编码器和解码器。本节实验中, 由于输入数据长度由 4 096 点降为 512 点, 不再需要网络容量较大的 VGG19 网络。编码器使用 VGG11 网络(1×3 卷积核)作为特征层与两个全连接层连接分别输出隐变量 z^- 与标签 y^- , 解码器使用 VGG11 对应的反卷积网络(网络各层反向排列, 使用转置卷积层、上采样层分别替代卷积层、池化层), 各鉴别器为 3 层的全连接网络。通过设置 100 个 epoch 的训练, 耗时 128 s, 通过观察损失函数的变化, 网络已完全收敛。

在图 8 中展示了数据集中 KKC_s($C_{TR}=4$) 的重构概率误差的二范数的概率分布, 可以看到闭集重构误差的二范数基本分布在 1.95~1.97 之间。由极值定理^[15]来看, 该概率分布与广义极值分布没有完全拟合的原因为数据集样本数过少。

使用训练好的网络模型对 KKC_s 数据进行测试, 对重构误差进行极值概率分析, 完成开集识别。使用第 3.1 节所述的 AUC 和 F1-Score 对开集识别方法的性能进行评估, 结果如表 2 所示。观察表中各行结果, 可以看到随着开放度的提高, 开集识别指标 AUC 与 F1-Score 是随之下降的, 而闭集识别精确度保持不变。从而可以得出以下 3 个结论: 第一, 本文所提出的开集识别网络可以有效地进行开集识别; 第二, 对于开放度越高的分类任务, 开集识别能力越差; 第三, 对于不同开放度的数据集, 模型闭集识别能力基本不受影响, 可以保持较高的闭集识别精确度。

表 2 开集识别结果
Table2 Open-set recognition results

openness	0	0.057	0.105	0.147
AUC	0	0.928	0.858	0.792
F1-Score	0.740	0.687	0.652	0.645
close-set accuracy	0.972	0.962	0.973	0.966

4 结论

为解决深度学习在解释中面临的开集识别挑战, 本文通过使用 Grad-CAM 实现深度网络激活可视化的方法确定输入信号中对神经网络激活贡献较高的部分, 从而筛选出最有利的提取信号指纹的数据部分, 大幅提高了特征提取的精确度和效率。在此基础上, 使用基于半监督对抗自编码器的开集识别模型, 实现了辐射源个体的开集识别。针对民航飞机二次雷达信号的实测数据实验表明, 本文提出的开集识别模型与方法, 能够在不损失闭集识别率的条件下实现高精确度的开集识别。由于数据集限制, 对算法的性能测试存在一定局限。后续工作中将采集其他信号样式数据集进行测试, 深入考虑引起高网络激活的原因, 同时精简优化开集识别网络结构, 将深度学习技术与 SEI 课题更好地结合。

参考文献:

- [1] YUAN Y J, WANG X, HUANG Z T, et al. Detection of radio transient signal based on permutation entropy and GLRT[J]. *Wireless Personal Communications*, 2015, 82(2):1047-1057. doi:10.1007/s11277-014-2265-2.
- [2] HUANG G, YUAN Y, WANG X, et al. Specific emitter identification for communications transmitter using multi-measurements[J]. *Wireless Personal Communications*, 2017, 94(3):1523-1542. doi:10.1007/s11277-016-3696-8.

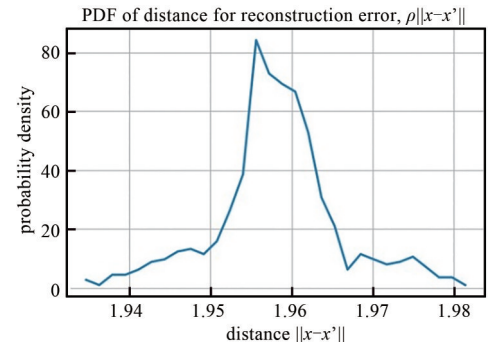


Fig.8 Probability Distribution Function(PDF) of distance for reconstruction error

图 8 重构误差距离概率分布

- [3] 任东方,张涛,韩洁. 基于双谱与特征选择的通信辐射源识别算法[J]. 信息工程大学学报, 2018,19(4):410–415. (REN Dongfang,ZHANG Tao,HAN Jie. Communication emitter identification based on bispectrum and feature selection[J]. Journal of Information Engineering University, 2018,19(4):410–415.) doi:CNKI:SUN:XXGC.0.2018–04–005.
- [4] 柳征,姜文利,周一宇. 基于小波包变换的辐射源信号识别[J]. 信号处理, 2005,21(5):460–464. (LIU Zheng,JIANG Wenli,ZHOU Yiyu. Emitter signals recognition based on wavelet packet transform[J]. Signal Processing, 2005,21(5):460–464.) doi: JournalArticle/5af18150c095d718d8e7d98a.
- [5] WISELL D,ÖBERG T. Analysis and identification of transmitter non-linearities[Z]. CiteSeer, 2000.
- [6] SATIJA U,TRIVEDI N,BISWAL G,et al. Specific emitter identification based on variational mode decomposition and spectral features in single hop and relaying scenarios[J]. IEEE Transactions on Information Forensics and Security, 2019,14(3):581–591. doi:10.1109/TIFS.2018.2855665.
- [7] REISING D R,TEMPLE M A,MENDENHALL M J. Improved wireless security for GMSK-based devices using RF fingerprinting[J]. International Journal of Electronic Security and Digital Forensics, 2010,3(1):41–59. doi:10.1504/IJESDF.2010.032330.
- [8] BRIK V,BANERJEE S,GRUTESER M,et al. Wireless device identification with radiometric signatures[C]// Proceedings of the 14th ACM International Conference on Mobile Computing and Networking. San Francisco,California,USA:ACM, 2008:116–127. doi:10.1145/1409944.1409959
- [9] 王艳丽. 基于并行 Boosting 算法的雷达辐射源识别系统的设计与实现[D]. 西安:西安电子科技大学, 2008. (WANG Yanli. Design and implementation of radar emitter recognition system based on parallel boosting algorithm[D]. Xi'an,China: Xidian University, 2008.)
- [10] O'SHEA T,HOYDIS J. An introduction to deep learning for the physical layer[J]. IEEE Transactions on Cognitive Communications and Networking, 2017,3(4):563–575. doi:10.1109/TCCN.2017.2758370.
- [11] YE H,LI G Y,JIANG B H. Power of deep learning for channel estimation and signal detection in OFDM systems[J]. IEEE Wireless Communications Letters, 2018,7(1):114–117. doi:10.1109/LWC.2017.2757490.
- [12] ZHOU B,KHOSLA A,LAPEDRIZA A,et al. Learning deep features for discriminative localization[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas,NV,USA:IEEE, 2016. doi:10.1109/CVPR.2016.319.
- [13] MAKHZANI A,SHLENS J,JAITLEY N,et al. Adversarial autoencoders[J/OL]. arXiv:1511.05644, 2016.
- [14] III J P. Statistical inference using extreme order statistics[J/OL]. The Annals of Statistics, 1975,3(1):119–131.
- [15] GENG C,HUANG S,CHEN S. Recent advances in open set recognition:a survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020,43(10):3614–3631. doi:10.1109/TPAMI.2020.2981604.
- [16] SELVARAJU R R,COGSWELL M,DAS A,et al. Grad-CAM: visual explanations from deep networks via gradient-based localization[C]// 2017 IEEE International Conference on Computer Vision(ICCV). Venice,Italy:IEEE, 2017. doi:10.1109/ICCV.2017.74.
- [17] PIDHORSKYI S,ALMOHSEN R,ADJEROH D A,et al. Generative probabilistic novelty detection with adversarial autoencoders[C]// Proceedings of the 32nd International Conference on Neural Information Processing Systems. Montreal Canada:[s. n.], 2018: 6823–6834.
- [18] 周水平. 二次雷达 S 模式询问与应答研究[J]. 电子世界, 2017(5):57–58. (ZHOU Shuiping. Secondary radar S mode inquiry and response study[J]. Electronics World, 2017(5):57–58.)
- [19] 汪云云,陈松灿. 基于 AUC 的分类器评价和设计综述[J]. 模式识别与人工智能, 2011,24(1):64–71. (WANG Yunyun,CHEN Songcan. A survey of evaluation and design for AUC based classifier[J]. Pattern Recognition and Artificial Intelligence, 2011,24(1):64–71.)
- [20] SIMONYAN K,ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J/OL]. arXiv:1409.1556, 2015.

作者简介:

林子榆(1997-),男,在读硕士研究生,主要研究方向为智能电子对抗.email:linziyumail@foxmail.com.

柯 达(1994-),男,在读博士研究生,主要研究方向为智能电子对抗.

王 翔(1978-),男,博士,讲师,主要研究方向为航天电子侦察、信号处理、模式识别等.

柳 征(1978-),男,博士,研究员,主要研究方向为智能电子对抗.

孙丽婷(1994-),女,在读博士研究生,主要研究方向为认知无线电,信号处理,物理层安全.