

DOI:10.19651/j.cnki.emt.2312998

基于零样本学习的未知辐射源个体识别研究

孙程远 杜奕航 张涛 杨小蒙

(国防科技大学第六十三研究所 南京 210007)

摘要: 针对辐射源个体识别基本遵循闭集假设无法有效识别未知类的问题,提出了一种基于零样本学习的辐射源个体识别模型实现对已知类和未知类辐射源个体识别。通过搭建卷积神经网络提取隐藏在辐射源信号数据下的语义特征,引入注意力模块增强对关键特征的关注,提出一种组合损失函数促使不同类辐射源信号在语义特征空间分离,根据辐射源信号在语义特征空间的分布进行辐射源个体分类识别。实验结果表明,相较于传统闭集识别,本文所提模型在能够在保持已知类识别率的前提下识别未知类且能在未知类之间区分,平均识别率达到90%以上。在工程化验证中,搭建的未知辐射源个体识别平台能够在室内及室外场景下实现快速准确识别。

关键词: 辐射源个体识别;零样本学习;卷积神经网络;注意力模块;组合损失

中图分类号: TN971. +1 文献标识码: A 国家标准学科分类代码: 510. 4010

Research on the unknown specific emitter identification based on zero shot learning

Sun Chengyuan Du Yihang Zhang Tao Yang Xiaomeng

(The 63rd Research Institute, National University of Defense Technology, Nanjing 210007, China)

Abstract: Aiming at the problem that specific emitter identification basically follows the closed set hypothesis and cannot effectively identify unknown classes, a specific emitter identification model based on zero sample learning is proposed to identify known and unknown specific emitter. By building a convolution neural network to extract the semantic features hidden under the emitter signal data, the attention module is introduced to enhance the focus on key features, and a combined loss function is proposed to separate different types of emitter signals in the semantic feature space, and the specific emitter classification and recognition are carried out according to the distribution of emitter signals in the semantic feature space. The experimental results show that compared with traditional closed set recognition, the proposed model can recognize unknown classes and distinguish between unknown classes while maintaining the recognition rate of known classes, with an average recognition rate of more than 90%. In engineering verification, the established unknown specific emitter identification platform can achieve fast and accurate recognition in indoor and outdoor scenes.

Keywords: specific emitter identification; zero shot learning; convolutional neural network; attention module; combined loss

0 引言

辐射源个体识别(specific emitter identification, SEI)^[1]是指提取接收射频信号的特征来识别产生信号的辐射源个体的过程,在军事通信、频谱安全防护等领域具有重要作用。传统的辐射源个体识别主要基于人工提取的特征来实现,主要包括瞬时频率和振幅^[2]、信号的双谱^[3]、分形维数^[4]、模糊函数切片^[5]、功率谱密度系数^[6]以及接收端的信道状态信息^[7]等特征。在传统算法中,人工提取的特征

存在耗时且低效的问题,识别系统的性能依赖于专家对信号参数先验知识的理解。

近年来,深度学习技术^[8]因其能够提供从特征提取到分类的端到端解决方案而获得了广泛的普及。随着深度学习模型在图像识别、语音识别等领域^[9-10]的成功,人们也将其应用于信号识别领域,并证明了该技术在目标信号特征提取及分类识别上具有强大优势。Youssef等^[11]使用支持向量机(support vector machine, SVM)和卷积神经网络(convolutional neural networks, CNN)进行辐射源个体识

别。Merchant 等^[12]应用深度学习检测物理层属性,用顶域复杂基带误差信号识别认知无线电设备。曲凌志等^[13]提出了一种结合双层注意力机制和残差网络的辐射源个体识别方法,来提升低信噪比条件下模型的稳定性。唐震等^[14]利用深度残差收缩网络来消除数据噪声改进对辐射源个体的识别效果。但以上这些工作基本上遵循闭集假设,即他们的深度学习模型只能区分已知的信号类别,并没有考虑到某些类的训练数据是不可获得的。这种假设在一个动态和开放的环境中受到挑战,新的辐射源可能会继续出现,更真实的场景是开集识别。零样本学习^[15-16]是解决上述问题的一种途径,它能够通过语义知识对未知类进行预测,且已经被广泛应用于图像分类任务。Palatucci 等^[17]提出了一个零样本学习框架,该框架可以利用语义知识库来预测训练集中没有的未知类。文献[18]提出了一种嵌入模型,探索文本和图像特征之间的函数关系,用于传输模型间和模型内标签,以实现对图像进行标注。Frome 等^[19]扩展了深度架构来学习视觉和语义嵌入,它还可以使用标记的图像数据以及从未注释的文本中收集到的语义信息来识别视觉对象。零样本学习在图像处理领域的效率主要得益于可以通过高级描述来手动定义的语义特征,然而关于信号的语义特征却难以描述和人为指定。郝云飞等^[20]提出了一种基于生成对抗网络的信号调制方式开集识别,设计了适用于一维信号数据的重构判别网络模型,能够实现信号调制方式的开集识别。然而,将零样本学习用于辐射源个体识别还很少被研究。

为了解决未知辐射源个体难以识别的问题,本文提出了一种基于零样本学习的辐射源个体识别模型(zero-shot learning specific emitter identification model, ZLSEIM)。首先使用 CNN 自动提取出辐射源信号的语义特征,在网络中加入注意力模块增强重要信息减少无关信息的干扰,联合交叉熵损失和中心损失促使辐射源个体在语义特征空间中类内聚拢类间分离,然后根据语义特征空间中辐射源信号之间的距离进行分类。此外,鉴于信号的语义特征难以描述,使用 T-SNE^[21]算法对信号的语义特征进行可视化处理来解释不同信号之间的区别。实验使用一台 USRP2974 设备采集了来自 4 种不同型号的共 7 台对讲机的射频 IQ 信号,分别进行了闭集识别和开集识别测试。结果表明 ZLSEIM 能保持已知类的识别率并识别出多个未知类,已知类和未知类平均识别率均能达到 90% 以上。

1 数据采集及预处理

实验所用数据为一台 USRP 设备采集的来自 4 种不同型号的共 7 台对讲机的射频 IQ 信号。采集环境如图 1 所示,接收设备 USRP-2974 与天线相连,通过 Labview 软件搭建辐射源信号采集平台可以直接收集和存储对讲机工作时的 I/Q 数据,7 台对讲机分别为 1 台 BAOFENG 型号、2 台 SHIDA 型号、1 台 TCL 型号和 3 台 TYT 型号,对讲

机统一采用调频工作方式,频率设置为 450 MHz。

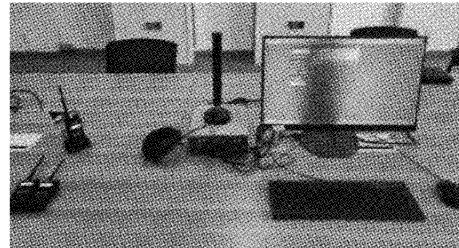


图 1 设备采集环境

每一台设备采集了 3 段信号,每段信号为约 1 min 的信号采样点,在使用这些数据前还需要进行分段标准化的预处理:对这些连续的采样点进行切片并做归一化,切片出的每一段信号为一个样本,可视化后如图 2 所示。

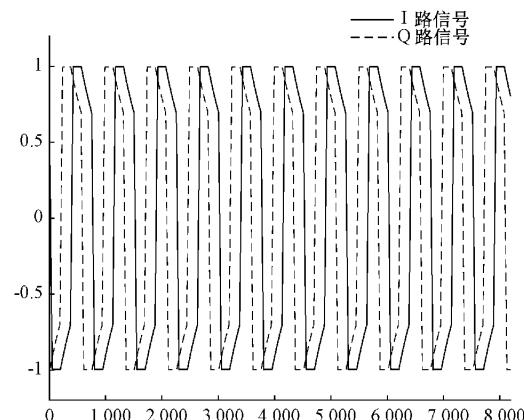


图 2 分段标准化信号

经过处理的数据集为每一台设备对应 1 000 个样本,每个样本尺寸大小为 8192×2 ,训练集、测试集按照 8:2 的比例进行随机划分,在实验中会根据分类任务挑选出不同的设备作为未知类。作为未知类时不会划分样本到训练集中,只挑选 20% 的样本作为测试集。

2 ZLSEIM 模型架构

2.1 模型组成

ZLSEIM 模型主要由特征提取模块和分类识别模块两部分组成。特征提取模块以 CNN 为基础构建而成,在训练阶段,特征提取模块通过最小化损失函数更新神经网络参数和已知类的语义特征中心,网络训练好后,输入测试样本,特征提取模块按照保存的网络参数提取出信号的语义特征然后送入分类识别模块,分类识别模块通过计算样本与已知类语义特征中心的距离然后设定阈值进行识别,模型结构如图 3 所示。

2.2 特征提取模块

1) 组合损失函数设计

特征提取模块使用 CNN 来提取信号的语义特征,训练过程中网络通过梯度反向传播降低损失来达到优化目

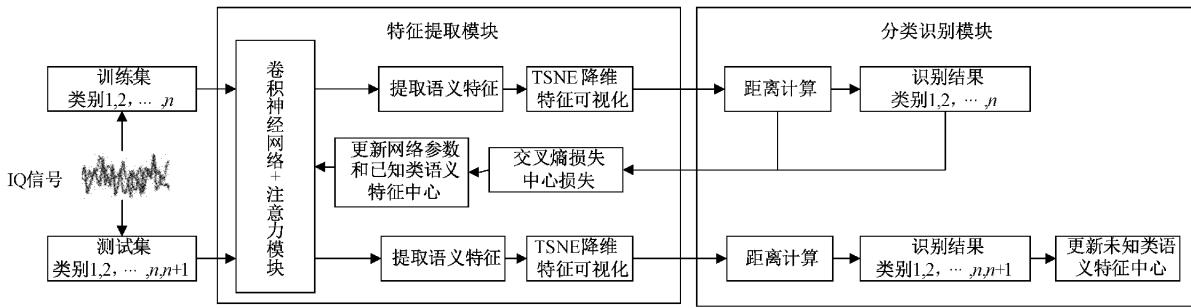


图 3 ZLSEIM 结构

标,为了使语义特征能够有效辅助模型对已知类和未知类的识别,需要合理地设计损失以控制网络的特征提取过程。为此模块考虑了交叉熵损失和中心损失两种损失的组合使用。

交叉熵损失用于增强不同类之间的区分度,表示为真实概率分布与预测概率分布之间的差异,其数学表达式如下:

$$L_{ce} = -\frac{1}{N} \sum_{i=1}^N y_i \log(C(F(x_i))) \quad (1)$$

其中, x_i 为样本, $F(x_i)$ 表示 CNN 提取的样本语义特征, $C(F(x_i))$ 为网络根据语义特征输出的预测标签, y_i 为样本真实标签。

中心损失用于促使同一类的语义特征接近一个中心,间接和其他类分离。经 CNN 提取后的语义特征本质上为一个向量,因此中心损失的效果可以表述为在迭代过程中使同一类语义特征之间的向量距离减小,间接使不同类语义特征之间的向量距离增大。中心损失表示如下:

$$L_{ct} = \frac{1}{2N} \sum_{i=1}^N \|F(x_i) - C_{y_i}\|_2^2 \quad (2)$$

其中, C_{y_i} 表示标签为 y_i 类的语义中心向量,随着类的语义特征变化,需要更新。理想情况下,应该考虑到整个训练数据集,并且需要在每个迭代中对每个类的特征进行平均。在应用中根据 $C_{y_i} \leftarrow C_{y_i} - \Delta C_{y_i}$ 每批次进行更新,其中 α 为学习率, ΔC_{y_i} 的计算方法如下:

$$\Delta C_{y_i} = \frac{\sum_{i=1}^N \delta(y_i = y_j) (C_{y_i} - F(x_i))}{1 + \sum_{i=1}^N \delta(y_i = y_j)} \quad (3)$$

其中, $\delta(y_i = y_j)$ 是个条件等式,当括号内条件满足时 $\delta(y_i = y_j) = 1$,否则为 0,这保证了当样本标签相同即为同一类时才更新类语义中心。用于训练网络的总损失 L 是交叉熵损失 L_{ce} 和中心损失 L_{ct} 的和,其中 λ 为超参数,代表了中心损失所占权重:

$$L = L_{ce} + \lambda L_{ct} \quad (4)$$

2) 注意力模块

辐射源个体信号样本存在周期性,同型号下的不同辐射源个体差异性往往体现在细微处,因此本文使用卷积块注意模块 (convolutional block attention module, CBAM)^[22] 来提高神经网络对关键特征的提取能力。

CBAM 分为空间注意力模块和通道注意力模块两个顺序子模块,其结构如图 4 所示。

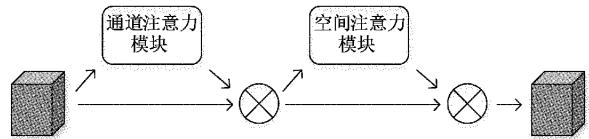


图 4 CBAM 结构

通道注意力模块对输入特征层进行全局平均池化和全局最大池化,将两个结果进行相加后用一个 sigmoid 函数激活,获得输入特征层每一个通道的权值然后乘上原输入特征层,以此提高对通道关键信息的提取能力。计算公式如下:

$$M_c(F) = \sigma(MLP(AvgP(F)) + MLP(MP(F))) \quad (5)$$

式中: $\sigma()$ 代表 sigmoid 激活函数, MLP 代表多层感知器 (全连接隐藏层和全连接输出层), $AvgP$ 代表全局平均池化, F 代表输入特征, MP 代表全局最大池化。

空间注意力模块对输入特征层在每一个特征点的通道上取最大值和平均值后将这两个结果进行一个堆叠,利用一个卷积核调整通道数,考虑 IQ 信号为 $N \times 2$ 的维度,卷积核大小设置为 3×2 ,然后用一个 sigmoid 函数激活,获得输入特征层每一个特征点的权值然后乘上原输入特征层,以此提高对特征层中每个空间位置信息的提取能力。计算公式如下:

$$M_s(F') = \sigma(f^{2 \times 2}([AvgP(F'); MP(F')])) \quad (6)$$

式中: $f^{2 \times 2}$ 代表边长为 2 的卷积核, F' 代表经由通道间注意力模块输出的特征图。

综上,得到 CBAM 模块的计算过程如下:

$$F' = M_c(F) \otimes F, \\ F'' = M_s(F') \otimes F' \quad (7)$$

式中: \otimes 代表逐点相乘, $M_c(F)$ 代表通道间注意力特征图, F' 代表经由通道间注意力子模块输出的中间特征图, $M_s(F')$ 代表空间注意力特征图, F'' 代表经由空间注意力子模块输出的结果特征图。

将 CBAM 添加至卷积层后然后构建网络,网络的低层由 4 个卷积层(convolution, Conv)组成,高层由 4 个全连接

层(fully connected layers, FC)组成, 第 3 个全连接层输出的高维特征向量作为语义特征, 最后一层在训练时输出预

测标签用于训练过程中计算中心损失和交叉熵损失。网络整体结构如图 5 所示。

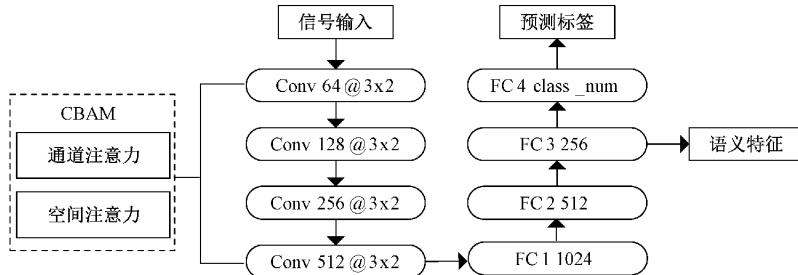


图 5 特征提取网络结构

2.3 分类识别模块

分类识别模块根据特征提取模块提取的信号语义特征来区分已知类和未知类, 经过网络模型提取的信号语义特征是一个高维向量, 因此可以依据向量距离来实现分类。每个样本的语义特征 $F(x_i)$ 和已知类语义中心向量 C_{y_i} 的欧式距离为:

$$d(F(x_i), C_{y_i}) = \sqrt{(F(x_i) - C_{y_i})^T (F(x_i) - C_{y_i})} \quad (8)$$

计算出信号和几个已知类语义中心的距离后, 首先通过比较距离和一个设定好的阈值 θ 来区分出信号属于已知类还是未知类; 阈值的设定参照了经常被用于识别异常值的三西格玛经验法则。如表 1 所示。其中, μ 为平均值, σ 为标准差。一般可以认为, 一组检测数据的取值几乎全部集中在 $(\mu - 3\sigma, \mu + 3\sigma)$ 区间内, 超出该范围的数据可以认为是异常值。因此阈值 θ 的设定为 $\theta = 3\sigma$, 其中 σ 为训练样本语义特征和其类语义中心的标准差。

表 1 三西格玛经验法则

数值分布	$(\mu - \sigma, \mu + \sigma)$	$(\mu - 2\sigma, \mu + 2\sigma)$	$(\mu - 3\sigma, \mu + 3\sigma)$
概率	0.682 7	0.954 5	0.997 3

当 $d < \theta$, 信号判定已知类, 进一步可以通过搜寻最小距离获得其标签:

$$y_i = \operatorname{argmin}_k d(F(x_i), C_{y_k}) \quad (9)$$

反之样本被判定为未知类, 此时为其新建一个代表未知类的标签 $y_{i_{un}}$ 和类语义中心 $C_{y_{i_{un}}}$, 并添加至已有标签和语义中心集合中, 后续出现的未知类会计算与已知类语义中心和已有的未知类语义中心的距离以此辨别是否为出现过的未知类还是新的未知类, 实现在未知类之间区分。判定过程整体步骤如图 6 所示。

3 实验过程及结果

为了评估本文所提出的辐射源个体识别模型的可行性和有效性, 实验使用实测对讲机信号作为测试对象, 设置了存在 1 类未知类、2 类未知类的两种开集识别任务, 模

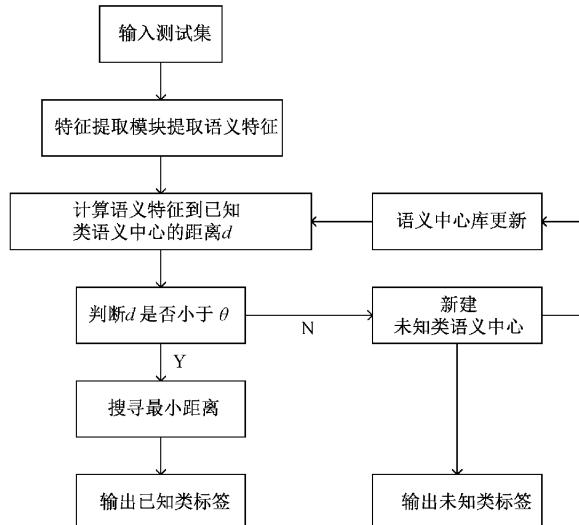


图 6 分类识别模块判定过程

型的训练使用 Windows 11 平台下的 Pytorch 框架, 在 NVIDIA RTX A6000 上进行训练和测试。

3.1 实验过程

将划分好的数据集送入模型进行训练, 训练设置 200 次迭代, 学习率设置为 0.001, 中心损失的权重 λ 设置为 0.3, 图 7 给出了训练过程中的交叉熵损失、中心损失及由两者构成的总损失函数曲线, 可以看出, 总损失在训练迭代约 100 次时收敛, 而后轻微波动。

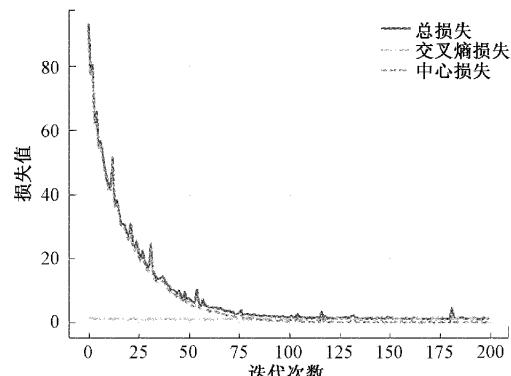


图 7 训练损失曲线

为了获取特征提取模块在训练过程中的最优效果, 在实验过程中每 25 个 epoch 保存模型参数并获取从训练集提取的语义特征, 而后利用 T-SNE 可视化特征观察已知类分类效果, 取分类效果最好时的模型输入测试集进行识别。图 8 为特征经 T-SNE 降维后输出的可视化聚类流形,

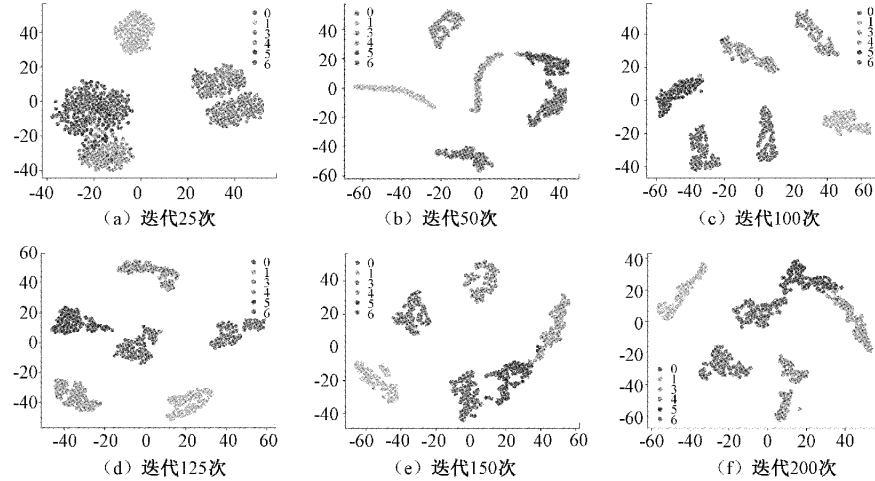


图 8 训练阶段特征聚类效果

3.2 实验结果

实验识别对象为 7 台对讲机的信号数据, 即 7 类辐射源个体, 分别进行了存在 1 类未知类和 2 类未知类情况下的

展示了存在 1 类未知类条件下训练集 6 个已知类别在训练阶段的分类效果。

根据图 8 的结果可以看出, 迭代 100 次时类内聚集度和类间分离度达到相对最优, 易于分类模块进行识别, 因此后续实验使用迭代 100 次时保存的模型进行测试。

测试, 挑选了同一型号下包含多台设备的类作为未知类以验证模型的性能, 此外在 Alexnet 上进行了闭集识别作为对比, 表 2 给出了相关识别结果, 其中未知类进行了标注。

表 2 识别结果

类别	识别率		
	1类未知类	2类未知类	Alexnet
BF(0)	100%	98.50%	100%
SHIDA-1(1)	100%	100%(未知类)	100%
SHIDA-2(2)	100%(未知类)	85.50%	100%
TCL(3)	98%	91%	100%
TYT-1(4)	96.00%	96%	95%
TYT-2(5)	93.00%	81.00%(未知类)	82%
TYT-3(6)	92.00%	86%	92%
已知类平均识别率	96.50%	91.4%	95.57%
未知类平均识别率	100%	90.75%	—

图 9(a)、(b)展示了包含未知类的测试集输入模型后得到的混淆矩阵, 分别对应存在 1 类和 2 类未知类的情况, 可以看出存在 2 类未知类时的识别率相较于存在 1 类未知类时有所下降, 这是因为 ZLSEIM 使用语义特征作为分类依据, 当出现更多的未知类, 相应的更多未知数据的语义特征没有经过训练时的损失控制导致不能形成良好的类内聚拢和类间分离, 这影响了其他已知类的识别率, 图 11 的聚类流形也体现了这一点。

Alexnet 闭集识别的测试结果如图 10 所示, 在所有类可知的情况下平均识别率为 95.57%。对比可知, ZLSEIM

虽然与传统 CNN 分类方法不同, 但在存在 1 类未知类情况下已知类识别率平均识别率达到 96.5%, 即使在存在多个未知类的情况下对已知类的平均识别率仍达到 90%以上, 验证了本文所提模型依靠语义特征的向量距离来区分不同类别是可行的, ZLSEIM 能在保持已知类识别率的基础上对未知类进行识别。

图 11(a)、(b)分别展示了包含 1 类未知类和 2 类未知类的测试集经网络提取语义特征后通过 T-SNE 降维形成的聚类流形, 可以看出存在 1 类未知类情况下未知类 SHIDA2 的聚类与已知类分离效果良好, 所以在根据距离

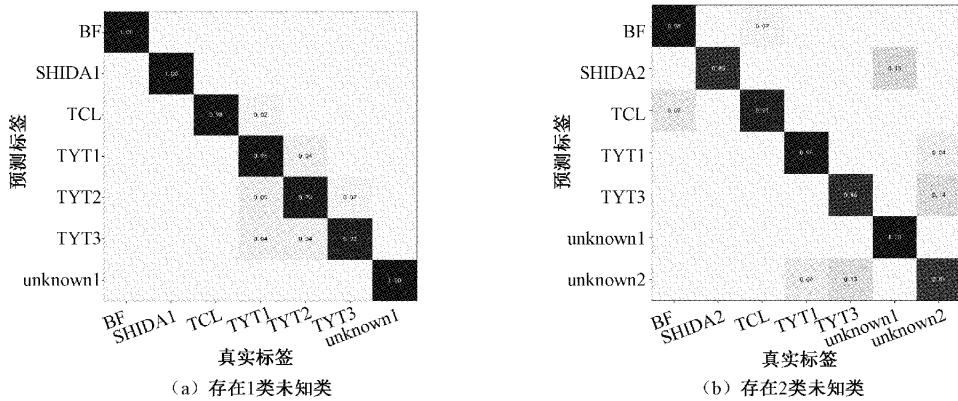


图 9 开集识别混淆矩阵

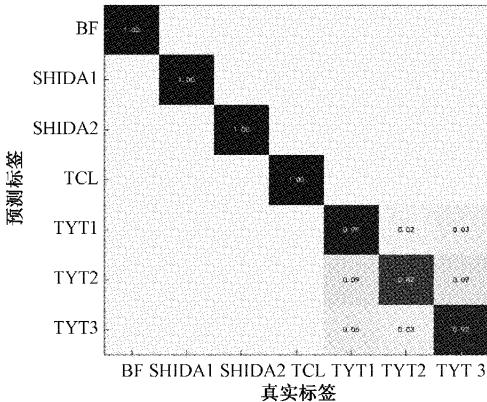


图 10 闭集识别混淆矩阵

判断时能达到 100% 识别率。在存在 2 类未知类 SHIDA1

和 TYT2 的情况下, TYT2 对应的聚类 unknown2 和 TYT3 的聚类 6 产生了重叠, 导致他们的识别率分别是 81%、86%, 相较于 TYT 型号对讲机未作为未知类时均有下降, 这可以解释为同一型号设备信号数据的相似性, 从闭集识别的结果可以看出相较于 SHIDA 型号, TYT 型号的个体更难区分。ZLSEIM 在已知的 TYT1、TYT3 数据上训练好模型, 用以提取未知类 TYT2 的特征时, 因 TYT2 数据与 TYT1、TYT3 相似且 TYT2 未参加训练, 特征提取模块不能通过损失惩罚去寻找 TYT2 与 TYT1、TYT3 之间的细微差别, 导致提取的语义特征相似而影响判别, 但 ZLSEIM 还是保持了对未知类一个较高的识别率。实验表明, ZLSEIM 对未知类的平均识别率均达到 90% 以上, 用 ZLSEIM 来对未知类进行识别是有效的。

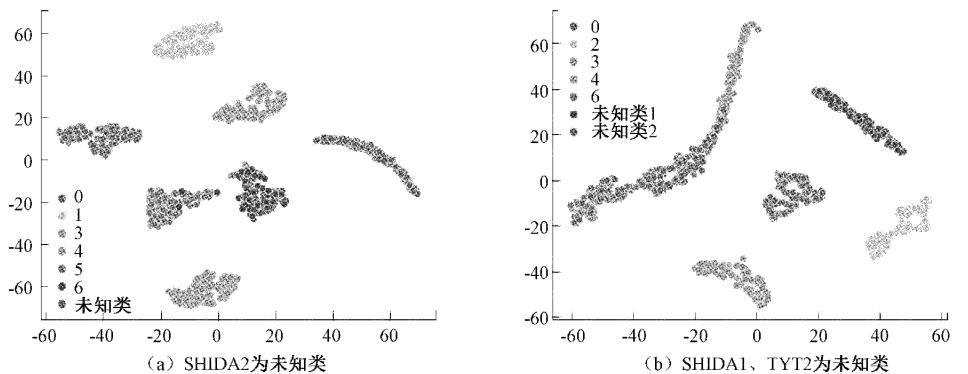


图 11 测试集分类效果可视化

3.3 工程验证

本文基于 Labview 软件搭建未知辐射源个体识别平台进行工程化验证, 将在 NVIDIA RTX A6000 上训练好的 ZLSEIM 模型移植至 USRP-2974 端, USRP 实时接收对讲机发送的信号, 信号接收完成后用封装好的 Matlab 预处理函数对信号进行归一化处理, 然后通过 Labview 调用 ZLSEIM 对信号进行识别并显示结果, 实测流程如图 12 所示。

为了评估未知辐射源个体识别平台的实用性, 实验保

持接收机 USRP 在室内位置不变, 根据发射源对讲机位置不同设置了 3 种场景, 分别为: 场景 1(室内)、场景 2(同一楼层室外)、场景 3(不同楼层)。使用存在两类未知类时训练的模型移植实测, 实测时将接收信号划分出 10 个测试样本送入模型进行, 计算识别为某一类型的概率及识别耗时, 7 台对讲机在 3 种场景下的识别结果如表 3 所示。图 13 给出了已知类 BF 对讲机和未知类 TYT2 对讲机在场景 1 下的平台识别界面。

从表 3 结果可以看出, 因场景 1 与训练数据的采集环

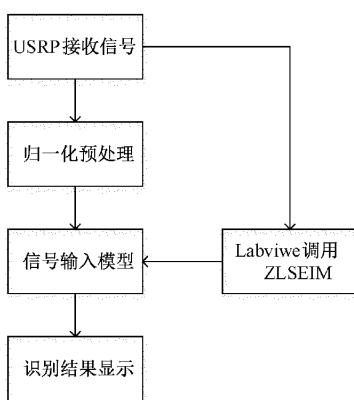


图 12 实测流程

境相同,实测时能保持一个很好的识别率。随着场景变化,信道、衰落等因素影响,识别率不可避免的下降,在场景 2 对讲机位于同一楼层室外发送信号时,还能保持一个较好的识别率,但在场景 3 中识别率急剧下降。此外,在实测中发现包含未知类的型号对应的多台个体更易被识

别为未知类,因为环境变化导致的接收信号与训练信号的差异使得模型更容易把已知的个体判断为未知,这使得没被训练的未知类反而能被正确识别。此外,平台的平均识别时间约在 5 s 左右,结果表明,本文所提 ZLSEIM 在一定场景下能稳定识别信号,且识别速度快,具有一定实际价值。

表 3 不同场景的实测识别率及识别时间

类别	场景 1		场景 2		场景 3	
	识别率/%	耗时	识别率/%	耗时	识别率/%	耗时
BF	100	5.92	100	5.33	70	5.05
SHIDA-1	100	5.47	90	4.87	60	5.82
SHIDA-2	90	4.93	70	5.69	30	5.17
TCL	100	5.18	80	5.50	60	4.90
TYT-1	100	5.23	90	5.34	50	5.58
TYT-2	90	5.07	80	4.99	60	5.32
TYT-3	90	4.96	70	5.11	20	5.14

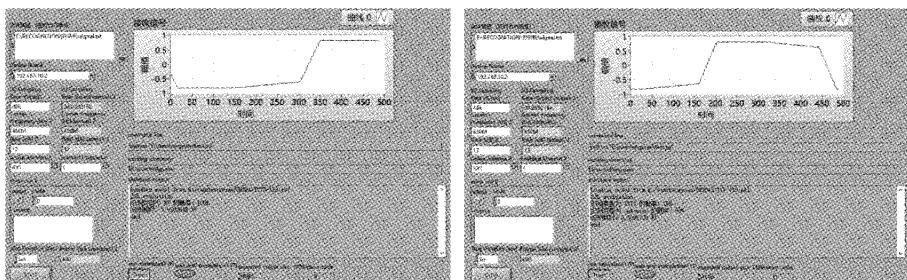


图 13 BF 和 TYT2 在场景 1 的实测效果

4 结 论

本文提出了一种基于零样本学习的未知辐射源识别模型。首先采集了 4 种不同型号共 7 台对讲机信号数据构成数据集并根据实验任务划分出未知类,然后使用融合了交叉熵损失、中心损失及添加了注意力机制的 CNN 对已知类数据样本进行训练,用训练好的神经网络模型提取测试集中已知类和未知类信号的语义特征,最后基于语义特征的聚类流形和距离度量来实现已知类和未知类信号的识别。实验表明,本文提出的基于零样本学习的辐射源分类识别模型在存在多个未知类时能对不同未知类进行区分且保持 90% 以上的平均识别率。在工程化验证中,室内场景下的实测几乎达到 100% 识别,且识别迅速,对不同场景也有较好的鲁棒性,具有一定的实际价值。

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] URETN O, SERINKEN N. Wireless security through RF fingerprinting[J]. Canadian Journal of Electrical and Computer Engineering: J-CJECE, 2007, 32(1): 27-33.
[3] 蔡忠伟, 李建东. 基于双谱的通信辐射源个体识别[J]. 通信学报, 2007, 28(2): 5.
[4] DUDCZYK J, KAWALEC A. Identification of emitter sources in the aspect of their fractal features[J]. Bulletin of the Polish Academy of Sciences Technical Sciences, 2013, 61(3): 623-628.
[5] 李林, 姬红兵. 基于模糊函数的雷达辐射源个体识别[J]. 电子与信息学报, 2009, 31(11): 2546-2551.
[6] SCANLON P, KENNEDY I O, LIU Y. Feature extraction approaches to RF fingerprinting for device identification in femtocells[J]. Bell Labs Technical Journal, 2010, 15(3): 141-151.
[7] YU P L, SADLER B M. MIMO authentication via deliberate fingerprinting at the physical layer [J]. IEEE Transactions on information forensics and

- security, 2011, 6(3): 606-615.
- [8] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [9] 孙晓, 潘汀, 任福继. 基于 ROI-KNN 卷积神经网络的面部表情识别[J]. 自动化学报, 2016, 42(6): 883-891.
- [10] 马飞, 王金明, 朱森. 基于深度卷积神经网络的连续语音识别研究[J]. 军事通信技术, 2016, 37(4): 37-40.
- [11] YOUSSEF K, BOUCHARD L, HAIGH K, et al. Machine learning approach to RF transmitter identification[J]. IEEE Journal of Radio Frequency Identification, 2018, 2(4): 197-205.
- [12] MERCHANT K, REVAY S, STANTCHEV G, et al. Deep learning for RF device fingerprinting in cognitive communication networks[J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(1): 160-167.
- [13] 曲凌志, 杨俊安, 刘辉, 等. 嵌入注意力机制的通信辐射源个体识别方法[J]. 系统工程与电子技术, 2022, 44(1): 20-27.
- [14] 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.
- [15] FU Y, XIANG T, JIANG Y G, et al. Recent advances in zero-shot recognition: Toward data-efficient understanding of visual content [J]. IEEE Signal Processing Magazine, 2018, 35(1): 112-125.
- [16] POURPANAH F, ABDAR M, LUO Y, et al. A review of generalized zero-shot learning methods[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, DOI:10.1109/TPAMI.2022.3191696.
- [17] PALATUCCI M, POMERLEAU D, HINTON G E, et al. Zero-shot learning with semantic output codes[C]. International Conference on Neural Information Processing Systems. Curran Associates Inc, 2009.
- [18] QI G J, LIU W, AGGARWAL C, et al. Joint intermodal and intramodal label transfers for extremely rare or unseen classes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(7): 1360-1373.
- [19] FROME A, CORRADO G S, SHLENS J, et al. Devise: A deep visual-semantic embedding model[C]. Neural Information Processing Systems. Curran Associates Inc, 2013.
- [20] 郝云飞, 刘章孟, 郭福成, 等. 基于生成对抗网络的信号调制方式的开集识别[J]. 系统工程与电子技术, 2019, 41(11): 2619-2624.
- [21] 徐森, 花小朋, 徐静, 等. 一种基于 T 分布随机近邻嵌入的聚类集成方法[J]. 电子与信息学报, 2018, 40(6): 1316-1322.
- [22] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision(ECCV), 2018: 3-19.

作者简介

孙程远,硕士研究生,主要研究方向为辐射源个体识别,深度学习。

E-mail:sunchengyuan202109@163.com

杜奕航,高级工程师,博士研究生,主要研究方向为频谱安全管理。

E-mail:dyhcs1991@163.com

张涛,博士,副研究员,主要研究方向为电磁频谱安全与控制,智能无线通信与网络。

E-mail:ztc001@126.com

杨小蒙,硕士研究生,主要研究方向为调制识别,深度学习。

E-mail:yxiaomeng128@163.com