

基于渐进式自训练开集域适应的辐射源个体识别

张涛涛, 谢钧, 乔平娟

引用本文

张涛涛, 谢钧, 乔平娟. 基于渐进式自训练开集域适应的辐射源个体识别[J]. 计算机科学, 2025, 52(7): 279-286.

ZHANG Taotao, XIE Jun, QIAO Pingjuan. [Specific Emitter Identification Based on Progressive Self-training Open Set Domain Adaptation](#) [J]. Computer Science, 2025, 52(7): 279-286.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于小样本对比学习的甲型流感抗原性预测](#)

Prediction of Influenza A Antigenicity Based on Few-shot Contrastive Learning

计算机科学, 2025, 52(6A): 240800053-6. <https://doi.org/10.11896/jsjcx.240800053>

[融合情感词典和图对比学习的中文零样本立场检测](#)

Zero-shot Stance Detection in Chinese by Fusion of Emotion Lexicon and Graph Contrastive Learning

计算机科学, 2025, 52(6A): 240500051-7. <https://doi.org/10.11896/jsjcx.240500051>

[混合对比学习和多视角CLIP的多模态图文情感分析](#)

Multi-view CLIP and Hybrid Contrastive Learning for Multimodal Image-Text Sentiment Analysis

计算机科学, 2025, 52(6A): 240700060-7. <https://doi.org/10.11896/jsjcx.240700060>

[基于显著性掩模混合的小样本图像分类](#)

Saliency Mask Mixup for Few-shot Image Classification

计算机科学, 2025, 52(6): 256-263. <https://doi.org/10.11896/jsjcx.240600123>

[面向开放环境的PRNU指纹提纯算法](#)

PRNU Fingerprint Purification Algorithm for Open Environment

计算机科学, 2025, 52(6): 187-199. <https://doi.org/10.11896/jsjcx.241100190>

基于渐进式自训练开集域适应的辐射源个体识别

张涛涛 谢钧 乔平娟

中国人民解放军陆军工程大学指挥控制工程学院 南京 210007

(ztt6691@163.com)

摘要 针对闭集场景中训练的辐射源个体识别模型部署在包含有新类别的辐射源个体环境条件中时会出现已知类识别性能下降以及新类识别错误的问题,提出了一种噪声变化场景下的基于开集域适应辐射源个体识别方法。利用最大最小阈值判别已知类和未知类并通过渐进式自训练的方法训练一个目标分类器用于测试场景。目标分类器的一个未知分类要同时拟合多个未知类的特征分布,可能会导致学习到的已知未知特征分布的边界混淆。基于此,提出了一个多中心损失用于增加目标已知类和未知类内的紧凑性以及类间的可区分性,可提高目标分类器判别的准确性。同时,为了减少源域和目标域之间因为噪声造成的指纹特征偏移问题,使用了基于原型到原型的对比学习来学习域不变特征。在公开数据集上进行了6组实验,所提方法在其中5组中的HOS指标好于其他方法,甚至在10dB-8dB的任务中HOS达到了93.8%,实验结果验证了所提方法的有效性。

关键词: 辐射源个体识别;开集域适应;自训练;中心损失;对比学习

中图分类号 TP391

Specific Emitter Identification Based on Progressive Self-training Open Set Domain Adaptation

ZHANG Taotao, XIE Jun and QIAO Pingjuan

School of Command and Control Engineering, Army Engineering University of the PLA, Nanjing 210007, China

Abstract Aiming at the problem that the specific emitter identification model trained in the closed set scene will suffer from the degradation of the known class recognition performance and the error of the new class recognition when deployed in the environmental conditions of the specific emitter identification containing the new class, this paper proposes an specific emitter identification method based on open set domain adaptation in the noise change scene. The maximum and minimum thresholds are used to distinguish the known class and the unknown class, and a target classifier is trained by a progressive self-training method for testing the scene. An unknown classification of the target classifier fit the feature distribution of multiple unknown classes at the same time may lead to the problem of boundary confusion of the learned known and unknown feature distribution. Based on this, a multi-center loss is proposed to increase the compactness within the unknown class of the target known class and the distinguish ability between classes, which can improve the accuracy of the target classifier. At the same time, in order to reduce the problem of fingerprint feature offset caused by noise between the source domain and the target domain, a prototype-to-prototype contrastive learning is used to learn domain invariant features. Six groups of experiments are carried out on the public data set. The HOS index of the proposed method in five groups is better than other methods, and the HOS reaches 93.8% in the task of 10dB-8dB. The experimental results show the effectiveness of the proposed method.

Keywords Specific emitter identification, Open set domain adaptation, Self-training, Center loss, Contrastive learning

1 引言

辐射源个体识别(Specific Emitter Identification, SEI)技术在军事和民用领域起着越来越重要的作用^[1]。随着深度学习的快速发展,基于深度神经网络(Deep Neural Network, DNN)的SEI技术有了新的进展^[2-5]。但是在一些环境条件下,尤其是复杂的电磁环境下,辐射源个体发射的信号受到了噪声的干扰,使得信号中的指纹特征分布发生了不同程度的偏移,导致基于DNN的SEI方法出现了性能下降的问题^[6]。无监督域适应(Unsupervised Domain Adaptation, UDA)方法可以解决此类问题。收集的带标签训练数据(源域)和无标签

测试数据(目标域)通过UDA可以有效地学习到域不变特征,在图像领域以及SEI领域均有广泛应用^[7-12]。在实际的开放环境中一个值得考虑的情况是,目标域中出现了多个新类别的辐射源个体。一方面,闭集UDA设置类别数目是一致固定的,所以无法识别出未知类;另一方面,目标域中存在未知类,在使用UDA时部分已知类和未知类错误地匹配导致类间混淆,出现了负迁移。目前,开集域适应(Open Set Domain Adaptation, OSDA)在图像领域已经有了很多的研究,用于解决未知类的检测以及域适应的问题^[13-16]。OSDA的关键是尽可能地分离出目标域中的未知样本,然后使用UDA来完成目标域已知样本和源域的域适应,减少了未

知样本对 UDA 造成的影响。在 SEI 领域中,暂未检索到 OS-DA 的相关方法。

Satio 等^[13]提出了反向传播开集域适应(OSBP)模型,OSBP 为未知类设定一个固定的概率阈值,通过反向传播来实现已知类和未知类的分离。单一的阈值并不是安全的,置信度在阈值附近的目标样本很可能被错误判别。针对这个问题,本文设计了最大最小阈值。将置信度大于等于最大阈值的目标样本判定为已知类,置信度小于等于最小阈值的目标样本判定为未知类。利用这些目标样本训练一个目标分类器,用于测试场景。为了提高目标分类器判别的准确率,结合中心损失和单中心损失提出了多中心损失,通过特征中心来对目标特征空间进行约束,增加了已知类和未知类分类边界的清晰性以及类内的紧凑性。最后利用原型到原型的对比学习对目标已知类和源域进行了域适应。由于控制了最大最小阈值,每个批次检测出的目标已知样本和未知样本数量较少,而且不能够完整地覆盖所有的类别。基于这个问题,本文设计了一种渐进式的自训练方法,对每个批次检测出的目标已知类和未知类进行累加,当到达设定的批次数后再进行目标分类器的训练、多中心学习,以及对比学习。本文的主要贡献如下:

- 1)探索了开集场景的 SEI,提出了一个新的 SEI 框架。
- 2)通过设置最大最小阈值来检测未知类和已知类,确保了较高的检测准确率。
- 3)结合单中心损失和中心损失提出了一个多中心损失。在目标域中,所有的未知类学习一个共享中心,每个已知类分别学习一个中心。通过多中心损失增加了已知类和未知类之间的可区分性,以及它们内部的紧凑性。
- 4)为了缓解较高的检测准确率导致每个批次检测出的样本数相对较少、覆盖的类别不全的问题,本文设计了一个渐进式自训练方法以促进目标分类器的学习、中心学习,以及对比学习。
- 5)在公开数据集上进行了对比实验和消融实验,证明了本文方法的有效性。

2 相关工作

2.1 基于闭集域适应的辐射源个体识别

当数据特征分布发生偏移后,使用源数据训练的模型进行测试时出现了性能下降的问题。闭集域适应通过学习源域数据和偏移后的目标域数据之间的域不变特征来解决这个问题。闭集域适应的一个重要设置是源域和目标域共享相同的标签集。现有的闭集域适应主要包括基于对抗学习和基于差异度量两类方法。Zhu 等^[17]提出了深度子域适应(DSAN)模型,利用局部最大均值差异(LMMD)作为度量方法,将度量的差异作为优化目标,不断缩小域之间的差异,从而达到域不变特征的学习目标。Ganin 等^[18]提出了深度对抗神经网络(DANN),通过混淆源域和目标域来促使特征提取器生成域不变特征。

在 SEI 领域中,当辐射源个体发射的信号受到噪声的干扰时会导致信号中的指纹特征偏移。在噪声变化的任务场景中,Qin^[19]提出了基于 MK-MMD 的 SEI 方法,Wang 等^[20]则将 DANN 应用于 SEI 中,这些方法都提高了测试场景目标

辐射源个体识别的精度。

2.2 开集域适应

开集域适应与闭集域适应的主要区别是,开集的目标域标签集中类别的数量比源域标签集多。这给域适应带来了很大的麻烦,在域适应的过程中很可能错误地匹配源域的已知类和目标域的未知类,导致负迁移。开集域适应的关键是,尽可能地识别出未知类来减小对 UDA 造成的影响。OSBP 利用固定的概率值来分离目标未知类。Gao 等^[21]设计了阈值域对抗网络(ThDAN),在训练过程中逐步调整阈值,以便能够正确地从未知类中选择越来越多的目标样本进行对抗性训练。Jang 等^[22]提出了未知感知领域对抗学习(UADAL),该方法在特征对齐过程中分离目标域未知类分布,在熵最小化的优化中使用了一个阈值。单个阈值可能导致置信度在阈值附近的样本被误判别。与以上方法不同,本文设计了一种最大最小阈值来检测已知类和未知类。

2.3 中心损失

中心损失^[23]用于学习类的特征,促使同一类的特征更靠近对应的类中心,增加了类内的紧凑性。为了学习一个单中心来分离自然面孔和伪造面孔特征,Li 等^[24]设计了一个单中心损失。以自然面孔特征中心为中心,单中心损失在增加自然面孔特征紧凑性的同时推远伪造面孔特征与中心的距离,这样可实现两者特征的分离。基于单中心损失思想,本文切换了场景,将未知类别等价于自然面孔来学习一个未知类别的中心。通过这种方式,促使已知类和未知类别特征的分离;同时,结合中心损失可增加已知同类内的紧凑性。

2.4 自训练

自训练是一种半监督方法,主要思想是利用带标签数据训练过的模型对未标记数据打伪标签,然后利用带伪标签的样本进行训练^[25]。本文利用训练过的源分类器对目标域样本打伪标签,已知类被分配具体的类标签,未知类被统一分配一个固定的标签,利用这些目标本来训练目标分类器,并与源域进行域适应操作。

3 本文方法

本文方法对应的网络框架如图 1 所示,包括特征提取器 F 、源分类器 C_S 、目标分类器 C_T 、全连接层 FC_S 和 FC_T 、对比学习模块、多中心学习模块、目标样本检测模块,以及渐进式自训练方法。

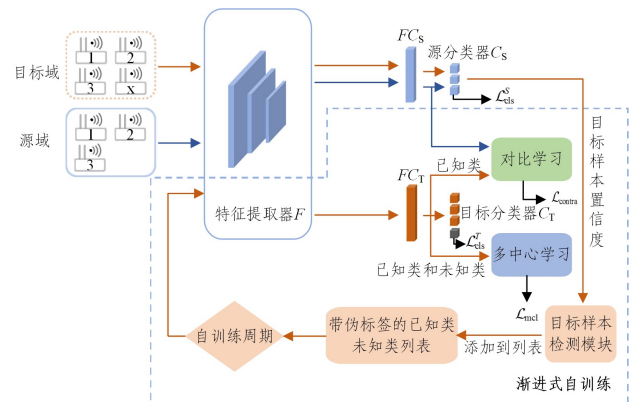


图 1 网络框架

Fig. 1 Network framework

3.1 问题定义

开域适应中包含一个有 N_s 个带标签样本的源域 $D_s = \{(x_i^s, y_i^s)\}_{i=1}^{N_s}$ 和一个有 N_T 个不带标签样本的目标域 D_T 。源域的标签集定义为 $L_s = \{0, 1, \dots, K\}$, 目标域的标签集为 L_T , 其中 $L_s \subset L_T$, 在目标域标签集中包含 v 种未知类, 标签统一定义为 $L_{T \cup S} = \{K+1\}$, 则 $L_T = \{0, 1, \dots, K, K+1\}$ 。

3.2 目标样本检测模块

首先进行预训练,以提高源分类器对目标样本的置信

$$y_i^T = \begin{cases} \arg \max(C_s(FC_s(F(x_i^T)))) , & \max(C_s(FC_s(F(x_i^T)))) \geq \max_threshold \\ K+1, & \max(C_s(FC_s(F(x_i^T)))) \leq \min_threshold \end{cases} \quad (1)$$

3.3 分类损失

源域中共有 $0 \sim K$ 个类别。为了实现源样本分类特征的学习,使用式(2)对网络进行有监督训练, \mathcal{L}_{CE} 代表交叉熵损失, \mathcal{L}_{cls} 代表源分类损失, n_s 代表源样本的数量, $y_i^s \in \{0, 1, \dots, K\}$ 。

$$\mathcal{L}_{cls}^s = \frac{1}{n_s} \sum_{i=1}^{n_s} \mathcal{L}_{CE}(C_s(FC_s(F(x_i^s))), y_i^s) \quad (2)$$

目标域中共有 0 到 $K+1$ 个类别,通过式(3)实现对目标样本分类特征的学习, \mathcal{L}_{cls}^T 表示目标分类损失, n_T^{kn} 和 n_T^{un} 分别代表目标已知样本和目标未知样本的数量, $y_i^T \in \{0, 1, \dots, K+1\}$ 。

$$\mathcal{L}_{cls}^T = \frac{1}{n_T^{kn} + n_T^{un}} \sum_{i=1}^{n_T^{kn} + n_T^{un}} \mathcal{L}_{CE}(C_T(FC_T(F(x_i^T))), y_i^T) \quad (3)$$

在训练阶段,源分类器在域适应的帮助下可以学习到域不变分类特征,以提高下一次迭代目标已知类和未知类检测的准确率,实现对目标分类特征的学习,但是无法学习到未知类的分类特征。利用分离出的目标已知样本和目标未知样本训练目标分类器,可以实现未知类分类特征的学习。

3.4 多中心学习模块

在目标域中,当有多种未知类时,通过目标分类器很难准确地拟合出一条清晰的决策边界,在已知类和未知类之间存在混淆的问题。同时,部分已知目标类之间也可能存在一定程度的混淆。本文结合中心损失^[23]和单中心损失^[24]提出了一个多中心损失,如式(4)所示。如图2(a)所示,每个样本使用一个二维特征表示,中间灰色部分代表目标未知类样本,其他代表目标已知类样本。多中心损失将每个目标已知类和未知类样本特征到其所属类别特征中心的距离作为优化目标,通过不断缩小这一距离,使得同类别的样本紧紧地靠拢在一起,这样类别之间的距离就增加了,图2(a)中的“拉”就是这个优化项产生的作用。同时,为了能够更好地区分开目标已知类与未知类,多中心损失在目标已知类样本特征和未知类样本特征中间设置一个间隔,促使目标已知类样本特征远离未知类样本特征,图2(a)中的“推”就是通过这个优化项来完成的。通过以上优化,类别与类别之间的决策边界更加清晰,减少了混淆的问题。每个目标已知类的中心集合定义为 $\{c_0, c_1, \dots, c_K\}$, 目标未知类的中心定义为 c_{K+1} 。

$$\mathcal{L}_{mcl} = \alpha \mathcal{L}_c + \beta \mathcal{L}_{scl} \quad (4)$$

其中, \mathcal{L}_c 代表目标已知类中心损失,利用欧氏距离对特征提取器提取的目标已知类样本特征与其所属类别特征中心的距离进行求解,将结果作为优化项,在每个目标已知类特征空间

度。在正式训练开始后,利用源分类器对目标样本进行预测,得到每个样本属于每个类别的概率值,然后取最大概率值和预设的最大阈值 $\max_threshold$ 以及最小阈值 $\min_threshold$ 进行比较,将大于 $\max_threshold$ 的判定为已知类并将最大概率值对应的类别作为该已知样本的伪标签,将小于 $\min_threshold$ 的判定为未知类,并将标签设置为 $K+1$ 。如式(1)所示,其中 x_i^T 表示目标样本, y_i^T 表示预测标签。

内部产生“拉”的效果,如式(5)所示。

$$\mathcal{L}_c = \frac{1}{n_T^{un}} \sum_{i=1}^{n_T^{un}} \|FC_T(F(x_i^T)) - c_{y_i^T}\|_2 \quad (5)$$

其中, \mathcal{L}_{scl} 包含两项优化项,如式(6)所示。其中第一项 $M_{unknown}$ 表示目标未知类样本特征到未知类特征中心的距离,利用欧氏距离进行求解,在目标未知类特征空间内部产生“拉”的作用,如式(7)所示。 M_{known} 用于衡量已知类特征到中心 c_{K+1} 的距离,如式(8)所示。

$$\mathcal{L}_{scl} = M_{unknown} + \max(M_{unknown} - M_{known} + m \sqrt{Dim}, 0) \quad (6)$$

$$M_{unknown} = \frac{1}{n_T^{un}} \sum_{i=1}^{n_T^{un}} \|FC_T(F(x_i^T)) - c_{K+1}\|_2 \quad (7)$$

$$M_{known} = \frac{1}{n_T^{kn}} \sum_{i=1}^{n_T^{kn}} \|FC_T(F(x_i^T)) - c_{K+1}\|_2 \quad (8)$$

其中, m 是超参数, Dim 表示特征维度。




图2 多中心学习和对比学习

Fig. 2 Multi-center learning and contrastive learning

根据式(5),式(7)和式(8)可以看出,欧氏距离与样本的特征维度相关。 $m \sqrt{Dim}$ 是一个与维度相关的阈值,用于确保在目标已知类样本特征和未知类样本特征之间至少保持 $m \sqrt{Dim}$ 欧氏距离的间隔。

当目标已知类样本特征与未知类样本特征的间隔小于阈值,如式(9)所示,将式(10)作为优化项,对目标已知类特征产生“推”的作用。

$$M_{unknown} - M_{known} + m \sqrt{Dim} > 0 \Rightarrow M_{known} - M_{unknown} < m \sqrt{Dim} \quad (9)$$

$$\max(M_{unknown} - M_{known} + m \sqrt{Dim}, 0) = M_{unknown} - M_{known} + m \sqrt{Dim} \quad (10)$$

与式(9)相反,当间隔大于等于 $m \sqrt{Dim}$ 时,无须优化,如式(11)所示。

$$\max(M_{unknown} - M_{known} + m \sqrt{Dim}, 0) = 0 \quad (11)$$

根据式(9)一式(11), \mathcal{L}_{cl} 的第二个优化项的主要作用是通过设置一个间隔来将目标已知类样本特征“推”开。

3.5 对比学习模块

对比学习^[26]通过拉近与正对之间的距离、推远与负对之间的距离来学习判别表示,对比学习定义如式(12)所示。

$$\mathcal{L}(q, k^+, k^-) = -\log \frac{\exp(q \cdot k^+ / t)}{\exp(q \cdot k^+ / t) + \sum_{k^-} \exp(q \cdot k^- / t)} \quad (12)$$

其中, k^+ 和 k^- 代表正负对, t 是常量, q 代表一个查询样本。正对和查询样本之间有相同的标签,负对和查询样本的标签不同。将式(12)作为优化目标,促使特征提取器提取样本 q 的特征更加接近于正对 k^+ , 偏离负对 k^- 。

原型是域内同类样本在共享特征空间的特征平均值。Yue 等^[27]通过使用样本到原型的对比学习实现了源域和目标域的特征对齐。本文通过在源域原型和目标域原型之间执行对比学习来实现域适应。在目标域中,每个已知 k 类的原型可表示为:

$$u_k^T = \frac{1}{n_k^T} \sum_{i=1}^{n_k^T} FC_T(F(x_i^T)) \quad (13)$$

其中, n_k^T 表示 k 类样本的数量。

在源域中, k 类的原型可表示为:

$$u_k = \frac{1}{n_k^S} \sum_{i=1}^{n_k^S} FC_S(F(x_i^S)) \quad (14)$$

其中, n_k^S 表示 k 类样本的数量。

结合式(13)和式(14),基于原型的对比损失可表示为:

$$\mathcal{L}_{\text{contra}} = -\sum_{k=0}^K \log \frac{\exp(u_k^T \cdot u_k^S / t)}{\sum_{j=0}^K \exp(u_k^T \cdot u_j^S / t)} \quad (15)$$

其中,源域中原型 u_k^S 是目标域中 k 类原型 u_k^T 的正对,源域中其他类别的原型 u_j^S 作为负对。通过式(15)的优化,特征提取器提取目标域样本中与其正对相似的特征,实现了图 2(b)中“拉”的效果,提取的特征远离负对,实现了图 2(b)中“推”的效果。最终学习到了域不变特征,完成了域适应。

3.6 渐进式自训练

在目标样本检测模块,为了得到较高的未知类检测准确率,设定了最大最小阈值。这带来的一个问题是,每个批次检测出的未知样本数量相对较少,并且难以覆盖全部的类别,这对于目标分类器的学习、中心学习以及对比学习都是不利的。为了解决这个问题,为自训练设定一个周期 sl_epoch ,在这个周期内累加每个批次检测出的目标样本用于目标分类器的训练,从而在中心学习模块和对比学习模块都有了较多较全的目标样本输入。整个渐进式自训练过程如算法 1 所示。

算法 1 渐进式自训练

输入:源域和目标域数据

1. for epoch=1 to T_1 do
2. 使用源域数据和式(2)预训练 F, C_S ;
3. end for
4. 批次计数 $b_count = 0$;
5. 自训练周期 $b_epoch = sl_epoch$, 每 sl_epoch 个批次执行一次;
6. 带伪标签的目标样本列表 $T_List = []$;
7. for epoch= T_1+1 to T_2 do

8. for iteration= 1, 2, ..., do
9. 获取一个批次的源样本和目标样本;
10. 将原样本输入网络并执行式(2)得到 $\mathcal{L}_{\text{cls}}^S$;
11. $b_count = b_count + 1$;
12. 使用 C_S 预测目标样本得到 output;
13. 将 output 输入目标样本检测模块可检测出带伪标签的目标样本 $t_samples$;
14. $T_List.append(t_samples)$;
15. if $b_count == b_epoch$ then
16. 将 T_List 中的目标样本输入网络并执行式(3)得到 $\mathcal{L}_{\text{cls}}^T$;
17. 执行式(4)得到 $\mathcal{L}_{\text{mcl}}^T$;
18. 计算源样本和目标样本每个类别的原型;
19. 将原型输入到式(15)得到 $\mathcal{L}_{\text{contra}}$;
20. 重新计数 $b_count = 0$;
21. 清空目标样本列表 $T_List = []$;
22. end if
23. 通过 $\mathcal{L}_{\text{cls}}^T, \mathcal{L}_{\text{cls}}^S, \mathcal{L}_{\text{mcl}}, \mathcal{L}_{\text{contra}}$ 更新 F, C_S, C_T ;
24. end for
25. end for

3.7 总目标函数

本文的优化过程分为两个部分,在未执行到自训练周期时,目标函数如式(16)所示。

$$\mathcal{L} = \mathcal{L}_{\text{cls}}^S \quad (16)$$

当执行到自训练周期时,目标函数如式(17)所示。

$$\mathcal{L} = \mathcal{L}_{\text{cls}}^S + \mathcal{L}_{\text{cls}}^T + \gamma \mathcal{L}_{\text{mcl}} + \varphi \mathcal{L}_{\text{contra}} \quad (17)$$

通过优化最终学习到的源域和目标域理想的特征空间如图 2(c)所示。

4 实验

4.1 数据集及预处理

ORACLE^[28]是一个公开的 SEI 数据集,其中包括 16 个辐射源类别,每个发射机在室内采集了超过 2 000 万个 I/Q 样本点。为了研究基于噪声场景的 SEI 方法,文献[29]在采集的数据中加入了高斯白噪声,文献[30]在数据中添加了人工噪声,本文实验数据也添加了高斯白噪声。相比原始数据,增强数据不能够完全地反映真实环境的噪声,但是很难采集到真实环境中场景比较全面的数据。而增强数据集可以使训练和测试有多样化的信息,进行更全面的测试和验证。

将每个辐射源的原始样本点以 256 的长度每隔 256 个样本点截取一次,共截取 2000 个样本。然后向每个样本中分别添加 0 dB, 4 dB, 6 dB, 8 dB, 10 dB, 12 dB 信噪比的高斯白噪声,得到了 6 个数据集。不同的信噪比大小代表了指纹特征受噪声影响的程度。信噪比越大,每个样本中的噪声就越小,指纹特征信息更加接近原始样本。信噪比越小,每个样本中的噪声就越大,这时样本中的指纹特征信息也发生了较大的偏移。将 6 个数据集分为两组:4 dB, 8 dB, 10 dB 为一组;0 dB, 6 dB, 12 dB 为另一组。每个数据集保存两份,一份用作源域,一份用作目标域。每个数据集都选择了相同的 14 个类,其中包括 8 个已知类和 6 个未知类。源域取前 8 个类用于已知类,共 8 个类;目标域取前 8 个作为已知类,后 6 个作为未知类,共 14 个类。实验将在这两个数据集上验证本文方法的性能。

4.2 评估指标

在现有开集域适应方法中^[22,31-32],通用的相关评估指标有 OS^* , UNK 和 HOS。 OS^* 表示已知类的识别准确率; UNK 表示未知类的识别准确率; HOS 指标权衡了 OS^* 和 UNK 指标的重要性,只有对已知类和未知类的识别准确率都较高时, HOS 才会取得较高的分数,如式(18)所示。

$$HOS = 2 \times \frac{OS^* \times UNK}{OS^* + UNK} \quad (18)$$

4.3 实验细节

4.3.1 实验参数

本文方法在 PyTorch 框架上运行,使用 ResNet50^[33] 作为主干网络,并采用 Adam 优化器来进行训练,学习率设为 0.00068,每个批次 64 个样本,共训练 100 轮。

本文方法设置了阈值、自训练周期以及多个损失项超参数。在训练过程中,一部分目标未知样本与某个已知类相似度比较高,为了过滤掉这些样本,将最大阈值 $\max_threshold$ 设置为 0.99,最小阈值从 0.5 调整到 0.9,在调整过程中发现当阈值小于 0.5 时,每个批次检测到未知类样本特别少,当逐渐增加 0.9 时,检测到未知样本数量增多,而样本多有利于对目标分类器的训练。逐渐增加自训练周期,当增加到 5 时,各项指标几乎不再变化。边缘系数 m 设置为 0.8,在调整过程中发现对结果的影响较小。多中心损失参数 α, β 分别设置为 0.01 与 1,目标函数超参数 γ, φ 分别设置 0.1 与 0.001,这些超参数经过多次尝试调整得到了一个较优的组合。

多中心学习模块的每个特征中心都按照给定特征维度大小进行随机初始化,然后每个自训练周期通过 SGD 优化器来学习特征中心,学习率设为 0.35。

4.3.2 对比方法

本文选取了 3 类对比方法:1) ResNet50,使用源域数据训练好的 ResNet50 模型直接在目标域上进行测试;2) DSAN^[17],

闭集域适应方法;3) OSBP^[13] 和 UADAL^[22],开集域适应方法。

4.3.3 实验内容

基于两组数据,分别在每组数据内构建 3 个任务。在 4 dB, 8 dB, 10 dB 组数据中构建 3 个迁移任务:10 dB 迁移至 8 dB, 10 dB-8 dB; 8 dB 迁移至 4 dB, 8 dB-4 dB; 4 dB 迁移至 10 dB, 4 dB-10 dB。同样地,在 0 dB, 6 dB, 12 dB 组数据中构建 3 个迁移任务:12 dB-6 dB; 6 dB-0 dB; 0 dB-12 dB。本文方法和对比方法分别执行上述 6 个实验,在每个任务中,每个方法都使用相同的目标测试集。

4.4 实验结果

表 1 和表 2 分别列出了本文方法在 2 组数据上 6 个任务中 3 个指标的情况。本文方法和对比方法 3 个指标的差值图如图 3 所示。

表 1 4 dB, 8 dB, 10 dB 组实验结果

Table 1 Experimental results of 4 dB, 8 dB and 10 dB groups

方法	10 dB-8 dB			8 dB-4 dB			4 dB-10 dB		
	OS*	UNK	HOS	OS*	UNK	HOS	OS*	UNK	HOS
ResNet50	87.2	0.0	0.0	74.9	0.0	0.0	71.4	0.0	0.0
DSAN	93.7	0.0	0.0	90.6	0.0	0.0	85.0	0.0	0.0
OSBP	69.2	37.0	48.2	48.4	41.1	44.5	27.1	64.8	38.2
UADAL	87.1	74.7	80.4	64.0	88.4	74.3	83.8	61.6	71.0
本文方法	94.5	93.2	93.8	76.4	83.8	79.9	69.1	85.6	76.5

表 2 0 dB, 6 dB, 12 dB 组实验结果

Table 2 Experimental results of 0 dB, 6 dB and 12 dB groups

方法	10 dB-8 dB			8 dB-4 dB			4 dB-10 dB		
	OS*	UNK	HOS	OS*	UNK	HOS	OS*	UNK	HOS
ResNet50	76.4	0.0	0.0	26.7	0.0	0.0	57.2	0.0	0.0
DSAN	91.8	0.0	0.0	70.1	0.0	0.0	37.7	0.0	0.0
OSBP	57.3	57.9	57.6	32.0	28.9	30.4	25.1	45.7	32.4
UADAL	70.4	81.0	75.4	58.4	56.1	57.2	28.6	73.0	41.1
本文方法	82.7	74.0	78.1	32.5	48.0	38.8	58.0	71.6	64.1

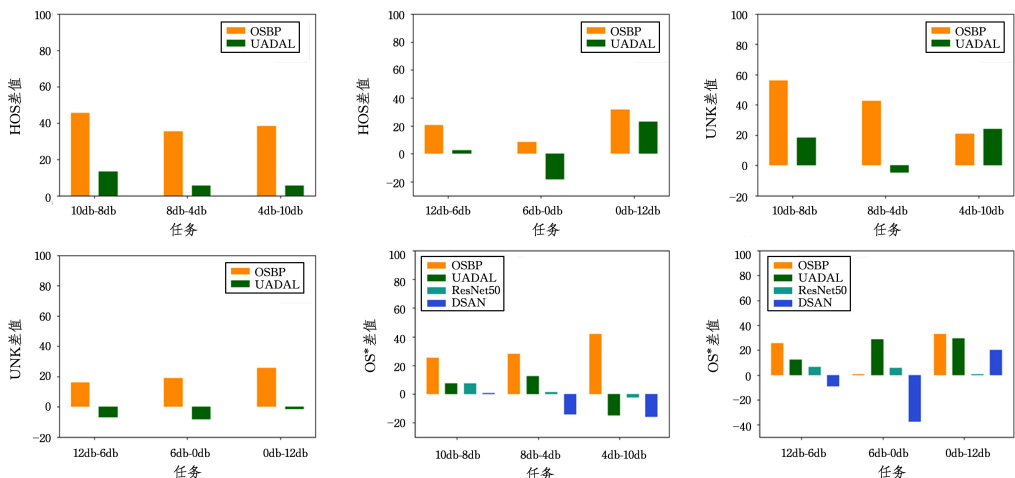


图 3 本文方法与对比方法 3 个指标的差值图

Fig. 3 Difference map between the three indexes of the proposed method and the comparison methods

差值表示本文方法指标值大于对比方法指标的数量值,当差值小于 0 时,说明本文方法的指标值小于对比方法。在 ResNet50 和 DSAN 方法的实验结果中,未知类的识别率为 0,说明了在开集场景下,闭集方法无法直接适用。DSAN 方

法相比 ResNet50 方法,已知类的识别率有了一定的提升,表明了域偏移的情况下域适应方法的有效性。OSBP 和 UADAL 都是开集域适应方法,它们都实现了对已知类和未知类的检测。OSBP 的已知类和未知类检测的准确率相对较

低。UADAL 和 OSBP 相比 3 项指标都有了提升,在 8 dB-4 dB,12 dB-6 dB,6 dB-0 dB,0 dB-12 dB 任务中 UNK 指标最好,说明了 UADAL 在未知类检测方法上有一定优势。和其他方法相比,本文方法在保证已知类有较高识别率的同时未知类也能有相对较高的识别率,除了 6 dB-0 dB 任务,本文方法的 HOS 指标均优于其他方法。在 10 dB-8 dB 任务中,所有的指标都优于其他方法。在 10 dB-8 dB 和 0 dB-12 dB 两个任务中,本文方法的已知类的识别率优于 DSAN,在其他任务中均低于 DSAN。这说明了未知类的存在导致了一定程度的负迁移,本文方法在一定程度上减少了未知类带来的影响但并没有完全消除。

图 4 对比了本文方法和 OSBP 以及 UADAL 方法的 HOS 指标趋势图,随着训练周期的增加 HOS 呈上升趋势,且本文方法优于对比方法。




图 4 10 dB-8 dB 任务中 HOS 指标趋势图

Fig. 4 Trend chart of HOS index in 10 dB-8 dB task

4.5 消融实验

为了验证所提改进策略的有效性,分别在 10 dB-8 dB 和 8 dB-4 dB 两个任务中执行了多个消融实验。

表 3 列出了本文方法在有多中心损失和没有多中心损失时 3 个指标的情况,实验结果表明,添加多中心损失的 3 个指标均优于没有添加多中心损失的。这说明了多中心损失的有效性。

表 3 10 dB-8 dB 和 8 dB-4 dB 任务中多中心损失消融实验结果

Table 3 Ablation experimental results of multi-center loss in 10 dB-8 dB and 8 dB-4 dB tasks

是否加多中心损失	10 dB-8 dB			8 dB-4 dB		
	OS*	UNK	HOS	OS*	UNK	HOS
×	89.2	76.4	82.3	75.9	67.5	71.5
√(本文方法)	94.5	93.2	93.8	76.4	83.8	79.9

表 4 列出了自训练周期分别在 1,3 和 5 个批次时 3 个指标的情况。随着自训练周期的增加,10 dB-8 dB 任务的每个指标都在增加;8 dB-4 dB 任务除了 UNK 指标,其他指标也都在增加。这说明多个批次的累加,使得有了足够的样本和足够的样本类别来训练目标分类器。

图 5 是最小阈值分别为 0.5,0.7 和 0.9 时目标分类器预测的 HOS 指标趋势图。当最小阈值为 0.5 时,HOS 曲线振荡幅度较大,无法收敛。造成这个问题的主要原因是阈值过小,而源分类器对目标未知类预测的置信度大多都大于 0.5,造成每个批次检测出的未知样本数很少且数量也不一致,这使得目标分类器很难得到充分的训练。当最小阈值增加到 0.7 时,此时 HOS 指标相对稳定上升直到收敛。当最小阈值

增加到 0.9 时,HOS 指标更加稳定,且到最后阶段和阈值为 0.7 时的 HOS 指标相比有了一定幅度的提升。

表 4 10 dB-8 dB 和 8 dB-4 dB 任务不同自训练周期实验结果

Table 4 Experimental results of different self-training epoch in 10 dB-8 dB and 8 dB-4 dB tasks

自训练周期	10 dB-8 dB			8 dB-4 dB		
	OS*	UNK	HOS	OS*	UNK	HOS
1	92.7	89.7	91.2	59.3	85.8	70.1
3	93.1	91.0	92.0	70.5	80.4	75.1
5(本文方法)	94.5	93.2	93.8	76.4	83.8	79.9




图 5 不同最小阈值目标分类器预测的 HOS 指标趋势

Fig. 5 HOS index trend predicted by different minimum threshold target classifiers

4.6 特征可视化

图 6 依次是 10 dB-8 dB 任务中 ResNet50、OSBP、本文方法(不加多中心损失)、本文方法(加多中心损失)使用相同目标测试集提取的特征并利用 t-SNE^[34] 进行可视化的结果。如图 6(d)所示,在本文方法学习到的特征空间中,未知类被拉近到一起,与已知类之间有了更加清晰的边界,已知类和未知类的内部变得更加紧凑。如图 6(c)所示,本文方法不加多中心损失时,未知类和已知类的边界存在较多的混淆,未知类内紧凑性较差,出现了两个局部的分布。这说明了提出的多中心损失的有效性。图 6(a)和图 6(b)中,已知类和未知类的混淆边界相较于本文方法更大。

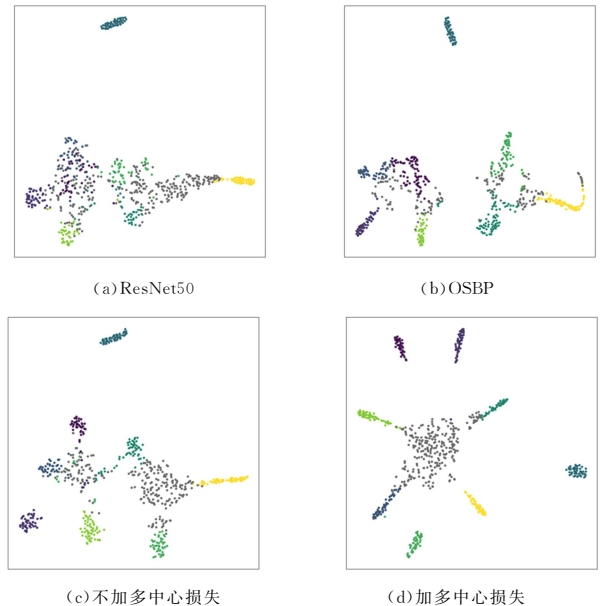


图 6 不同方法特征可视化

Fig. 6 Feature visualization of different methods

图7是在8 dB-4 dB和10 dB-8 dB任务中,本文方法提取的目标域和源域的特征可视化。在域适应的作用下,源域和目标域的特征实现了对齐,学习到了域不变特征。与在8 dB-4 dB任务下学习的特征空间相比,10 dB-8 dB学习到的特征空间更加紧凑有序,准确率更高。这说明了域偏移越小,域适应的过程就越容易且越准确。




图7 源域和目标域特征可视化

Fig. 7 Features visualization of source domain and target domain

结束语 本文提出了一种渐进式自训练开集域适应的SEI方法。该方法首先通过最大最小阈值来判定目标已知类未知类,从而获得较高的检测准确率;然后,提出的多中心损失使得学习的特征空间中同类别内部较为紧凑,已知类和未知类之间的判别边界较为清晰,增加了目标分类器判别的准确性;其次,在源域和目标域之间通过引入对比学习拉近了同类别之间的距离,由于未知类检测准确率较高,因此减少了负迁移的问题。本文还设计了一种渐进式自训练方法,为自训练设置一个周期,这样可以获取合适的目标样本数量和较全的样本类别用于上述多个模块。通过多组实验以及消融实验证明了本文方法的有效性。

本文方法虽然减少了未知类带来的负迁移问题,检测出了未知类,但是也存在一些问题。首先,当域之间差异较大且样本中噪声较大时,迁移的效果相对不太理想。其次,在部分应用场景中仍然存在一些限制。在实际的环境中,不仅目标域中存在未知辐射源类别,源域中也会存在一些目标域中没有的辐射源类别,这给目标样本的检测带来了干扰,此种场景更加具有挑战性。另外,当训练样本数量增加时,计算的复杂度也越来越大。未来计划对上述问题进行更深入的研究,着重探索针对上述应用场景的解决方法。

参考文献

[1] GU C M, CAO J J, WANG B W, et al. Individual identification of radiation sources based on hybrid feature selection [J]. *Computer Science*, 2024, 51(5): 267-276.

[2] WANG B, GAO N, WANG F. Specific Emitter Identification based on CNN and Transformer[C]// 2023 5th International Academic Exchange Conference on Science and Technology Innovation. IEEE, 2023: 571-575.

[3] SU J, LIU H, YANG L. Specific Emitter Identification Based on CNN via Variational Mode Decomposition and Bimodal Feature Fusion[C]// 2023 IEEE 3rd International Conference on Power, Electronics and Computer Applications. IEEE, 2023: 539-543.

[4] YAN G, CAI Z, LIU Y, et al. Intelligent Specific Emitter Identification Using Complex-Valued Convolutional Neural Network [C]// 2023 IEEE 23rd International Conference on Communication Technology. IEEE, 2023: 1259-1263.

[5] ZHANG Y, ZHANG Q, ZHAO H, et al. Multisource Heterogeneous Specific Emitter Identification Using Attention Mechanism-Based RFF Fusion Method[J]. *IEEE Transactions on Information Forensics and Security*, 2024, 19: 2639-2650.

[6] YIN L, FU X, SHI S, et al. Few-Shot Domain Adaption-Based Specific Emitter Identification Under Varying Modulation[C]// 2023 IEEE 23rd International Conference on Communication Technology. IEEE, 2023: 1439-1443.

[7] XU C, ZHOU M, GE T, et al. Unsupervised domain adaptation with pixel-level discriminator for image-aware layout generation [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2023: 10114-10123.

[8] LIU Y, ZHOU Z, SUN B. Cot: Unsupervised domain adaptation with clustering and optimal transport[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2023: 19998-20007.

[9] ZHA X, LI T, QIU Z, et al. Cross-receiver radio frequency fingerprint identification based on contrastive learning and subdomain adaptation[J]. *IEEE Signal Processing Letters*, 2023, 30: 70-74.

[10] ZHANG X, LI T, GONG P, et al. Variable-modulation specific emitter identification with domain adaptation[J]. *IEEE Transactions on Information Forensics and Security*, 2022, 18: 380-395.

[11] WANG M, LIN Y, JIANG H, et al. TESPDA-SEI: Tensor embedding substructure preserving domain adaptation for specific emitter identification [J]. *Physical Communication*, 2023, 57: 101973.

[12] LI D, YAO B, SUN P, et al. Specific emitter identification based on ensemble domain adversarial neural network in multi-domain environments[J]. *EURASIP Journal on Advances in Signal Processing*, 2024, 2024(1): 42.

[13] SAITO K, YAMAMOTO S, USHIKU Y, et al. Open set domain adaptation by backpropagation[C]// Proceedings of the European Conference on Computer Vision. Springer, 2018: 153-168.

[14] JANG J H, NA B, SHIN D H, et al. Unknown-aware domain adversarial learning for open-set domain adaptation[J]. *Advances in Neural Information Processing Systems*, 2022, 35: 16755-16767.


[15] LI W, LIU J, HAN B, et al. Adjustment and alignment for unbiased open set domain adaptation[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2023: 24110-24119.

[16] YU Q, IRIE G, AIZAWA K. Self-labeling framework for open-set domain adaptation with few labeled samples [J]. *IEEE Transactions on Multimedia*, 2023, 26: 1474-1487.

[17] ZHU Y, ZHUANG F, WANG J, et al. Deep subdomain adaptation network for image classification[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 32(4): 1713-1722.

[18] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adver-

- serial training of neural networks[J]. *Journal of Machine Learning Research*, 2016, 17(59):1-35.
- [19] QIN J. Individual identification of communication emitters based on deep learning [D]. Beijing: Beijing University of Posts and Telecommunications, 2019.
- [20] WANG C, DAN B, ZHANG C S. A channel adaptive unsupervised training and recognition method for radiation sources[J]. *Journal of Ordnance and Equipment Engineering*, 2023, 44(4): 211-216.
- [21] GAO Y, MA A J, GAO Y, et al. Adversarial open set domain adaptation via progressive selection of transferable target samples [J]. *Neurocomputing*, 2020, 410:174-184.
- [22] JANG J H, NA B, SHIN D H, et al. Unknown-aware domain adversarial learning for open-set domain adaptation[J]. *Advances in Neural Information Processing Systems*, 2022, 35: 16755-16767.
- [23] WEN Y, ZHANG K, LI Z, et al. A discriminative feature learning approach for deep face recognition[C]// *European Conference on Computer Vision*. Cham: Springer, 2016: 499-515.
- [24] LI J, XIE H, LI J, et al. Frequency-aware discriminative feature learning supervised by single-center loss for face forgery detection[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Springer, 2021: 6458-6467.
- [25] AMINI M R, FEOFANOV V, PAULETTO L, et al. Self-training: A survey[J]. *arXiv:2202.12040*, 2022.
- [26] CHEN T, KORNBLITH S, NOROUZI M, et al. A simple framework for contrastive learning of visual representations [C]// *International Conference on Machine Learning*. ACM, 2020:1597-1607.
- [27] YUE X, ZHENG Z, ZHANG S, et al. Prototypical cross-domain self-supervised learning for few-shot unsupervised domain adaptation[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. IEEE, 2021: 13834-13844.
- [28] SANKHE K, BELGIOVINE M, ZHOU F, et al. ORACLE: Optimized radio classification through convolutional neural networks[C]// *IEEE INFOCOM 2019-IEEE Conference on Computer Communications*. IEEE, 2019:370-378.
- [29] WONG L J, MCPHERSON S, MICHAELS A J. Assessing the value of transfer learning metrics for RF domain adaptation[J]. *arXiv:2206.08329*, 2022.
- [30] SHEN G, ZHANG J. Exploration of transferable deep learning-aided radio frequency fingerprint identification systems[J]. *Security and Safety*, 2024, 3:2023019.
- [31] LI W, LIU J, HAN B, et al. Adjustment and alignment for unbiased open set domain adaptation[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. IEEE, 2023:24110-24119.
- [32] GAO F, PI D, CHEN J. Balanced and robust unsupervised Open Set Domain Adaptation via joint adversarial alignment and unknown class isolation[J]. *Expert Systems with Applications*, 2024, 238:122127.
- [33] HE K, ZHANG X, REN S, et al. Deep residual learning for imagerecognition[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. IEEE, 2016: 770-778.
- [34] WANG Y, HUANG H, RUDIN C, et al. Understanding how dimension reduction tools work: an empirical approach to deciphering t-SNE, UMAP, TriMAP, and PaCMAP for data visualization[J]. *Journal of Machine Learning Research*, 2021, 22(201): 1-73.



ZHANG Taotao, born in 1992, postgraduate. His main research interests include wireless network and specific emitter identification.



XIE Jun, born in 1973, Ph.D, professor, Ph.D supervisor. His main research interests include wireless networks and intelligent network management.

(责任编辑:柯颖)