

面向无监督跨域开集场景的动态熵阈值辐射源个体识别方法

王 闯¹ 俞 璐¹
WANG Chuang YU Lu

摘 要

辐射源个体识别 (specific emitter identification, SEI) 技术在军事和民用领域应用广泛, 在多数情况下, 训练和测试数据并不满足独立同分布假设, 且往往测试数据包含比源域更多类别, 为了解决这一问题, 文章提出了一种面向无监督跨域开集场景的动态熵阈值辐射源个体识别方法。该方法引入最大均值差异 (maximum mean discrepancy, MMD) 以减小训练数据和测试数据之间的差异, 解决训练和测试数据分布不同导致的模型性能降低的问题。将分类器输出各类别熵的平均值作为未知类鉴别的阈值, 并通过移动平均方式更新各类别平均熵, 以动态获得熵阈值。实验结果表明, 所提方法在 Oracle 和 Wisig 射频指纹数据集上均具有较高的识别准确率, 验证了其有效性。

关键词

辐射源个体识别; 开集域适应; 熵阈值; 最大均值差异

doi: 10.3969/j.issn.1672-9528.2025.09.031

0 引言

辐射源个体识别 (specific emitter identification, SEI) 技术, 也称特定辐射源个体识别技术, 是一种通过对辐射源发射的电磁信号进行分析, 提取其特有的特征, 从而实现对辐射源

个体身份识别的技术。SEI 技术在军事和民用领域均具有极大应用价值。不同辐射源个体, 由于其制造工艺差异、元件特性以及使用过程中的衰减等因素, 会形成独特的信号特征, 这些特征被称为“射频指纹”。通过对接收信号数据的分析, 提取这些指纹特征, 并结合先验知识, 即可实现对辐射源个体的识别。

近年来, 随着人工智能技术的迅猛发展, 深度学习在图像识别、图像分割、自然语言处理等领域得到广泛应用, 并

1. 陆军工程大学 江苏南京 210000

[基金项目] 国家自然科学基金资助项目“复杂对抗条件下的电磁信号高可靠智能识别方法研究”(62471486)

参考文献:

- [1] 张静, 高子信, 丁伟杰. 基于 BERT-DPCNN 的警情文本分类研究 [J]. 数据分析与知识发现, 2025, 9(2): 48-58.
- [2] 赵聚雪. 基于短文本相似度分析的测试用例自动批改研究 [J]. 电脑编程技巧与维护, 2023(12): 127-129.
- [3] 王西子, 李英, 吴联生. 客户重要性与关键审计事项披露: 基于关键审计事项披露数量与文本相似度的分析 [J]. 会计研究, 2023(12): 159-173.
- [4] 杨宏伟, 张红梅, 张骥, 等. 基于 TF-IDF 加权文本语义相似度算法的变电站一键顺控测试方法研究 [J]. 电力科学与技术学报, 2023, 38(5): 269-278.
- [5] 高彦婷. 新型主流媒体中新闻文本和评论的语义相似度分析: 基于上观新闻语料库的 LDA 主题建模 [J]. 新闻传播, 2023(11): 18-20.
- [6] 李莹, 伍胜, 徐聪, 等. 语义文本相似度计算方法研究综述 [J]. 软件导刊, 2024, 23 (11): 1-11.

- [7] 蒋晨. 基于 BERT 模型的电气设备相似文本检索与故障聚类识别研究 [D]. 北京: 华北电力大学, 2022.
- [8] 张琳琳, 杨雅婷, 陈沾衡, 等. 基于深度学习的相似语言短文本的语种识别方法 [J]. 计算机应用与软件, 2020, 37(2): 124-129.
- [9] 贺益侗. 基于 doc2vec 和 TF-IDF 的相似文本识别 [J]. 电子制作, 2018(18): 37-39.
- [10] 郑建波. 警情信息识别学习模型应用研究 [J]. 消防界 (电子版), 2023, 9(9): 51-53.

【作者简介】

李也桐 (1998—), 女, 山东德州人, 硕士研究生, 助教, 研究方向: 自然语言处理、公安大数据等。

刘致用 (2005—), 男, 河北沧州人, 本科在读, 研究方向: 大数据、自然语言处理。

(收稿日期: 2025-03-20 修回日期: 2025-09-03)

取得显著成果。作为一种典型数据驱动技术,深度学习在辐射源个体识别领域中有极大应用价值,通过深度神经网络的训练学习,可以实现不同辐射源信号指纹特征的自动提取和分类,极大提升模型分类性能。

传统深度学习方法通常假设训练集和测试集数据独立同分布,然而,在实际应用中,由于空间中复杂电磁环境的干扰、信号采集设备和环境的差异,测试数据与训练数据往往具有不同分布,这种现象被称为分布偏移。为解决该问题,Pan 等人^[1]提出了迁移学习方法,将从训练数据中学习到的知识应用到测试数据中,以减轻分布偏移对模型性能产生的负面影响。其中,域适应方法作为迁移学习的重要分支,能够有效处理相同任务和特征空间下的迁移学习问题。

然而,在无监督开集场景下,辐射源个体识别面临着更多的挑战。一方面,数据易得标签难得,因为人工标注数据往往需要大量时间、人力成本,而在非合作通信辐射源个体识别中,标签信息更是难以获得,从而影响模型识别能力;另一方面,需要识别的通信辐射源个体中包含在模型训练过程中不曾出现的未知类别,这要求模型在识别时要兼顾未知类对模型性能的影响。本研究正是考虑这一场景,提出了一种无监督开集域适应方法用于通信辐射源个体识别。具体而言,本文主要贡献如下:

(1) 提出了一种面向无监督跨域开集场景的动态熵阈值辐射源个体识别方法,引入最大均值差异(maximum mean discrepancy, MMD)以减小训练数据和测试数据之间的差异,以解决训练和测试数据分布不同导致的模型性能降低的问题;

(2) 将分类器输出各类别熵的平均值作为未知类鉴别的阈值,并通过移动平均方式更新各类别平均熵,以动态获得熵阈值;

(3) 本文在 Wisig、Oracle 射频指纹数据集和实采射频指纹数据集上均验证了本方法的有效性,并进一步在 Wisig 射频指纹数据集上进行了消融实验,验证算法中各组分的作用。

1 相关工作

1.1 基于闭集域适应的辐射源个体识别

传统的深度学习方法假设训练数据和测试数据满足独立同分布的假设,当假设不成立时,由于分布偏移的存在,导致模型性能下降。为解决这一问题,闭集域适应(close-set domain adaptation, CSDA),将训练数据称为源域,测试数据称为目标域,在 CSDA 中,源域数据和目标域数据虽

然存在分布偏移,但二者标签空间相同,在模型训练中,通过提取源域和目标域之间域不变特征,将从源域中学习到的知识迁移到目标域中,实现目标域数据的分类。Pan 等人^[2]提出迁移成分分析(transfer component analysis, TCA)方法,通过在再生核希尔伯特空间(reproducing kernel hilbert space, RKHS)中学习迁移组件,使用 MMD 来减少不同领域之间的分布差异;在此基础上,Long 等人^[3]提出联合分布适应(joint distribution adaptation, JDA)方法,通过扩展 MMD 来衡量边缘分布和条件分布的差异,并将其与主成分分析(principal component analysis, PCA)相结合,以构建新的特征表示,有效应对源域和目标域的分布差异。Wang 等人^[4]提出一种基于深度对抗域适应(deepadversarial domain adaptation, DADA)的 SEI 方法,并首次将深度学习和对抗学习引入 SEI 领域,通过引入全局域判别器和局部域条件判别器,同时对齐源域和目标域数据的边缘分布和条件分布,从而更有效地减少不同域之间的差异,增强网络的自适应性和泛化能力;Zhang 等人^[5]提出一种基于域自适应的可变调制 SEI 框架,通过引入域对抗神经网络(domain adversarial neural network, DANN)^[6],最小化源域和目标域特征分布之间的差异,提高了模型在不同调制方式下的识别性能。

1.2 开集识别

在闭集条件下,训练和测试数据具有相同的特征分布和标签空间,明显与真实情况不符。实际场景中,随着新类不断增加,要求训练数据包含所有类别的样本是不现实的,因此要求模型在没有任何辅助信息的条件下,不仅能够分类已知类数据,还能鉴别出未知类数据,为解决这一问题,Scheirer 等人^[7]提出开集识别(open set recognition, OSR)概念,并从约束开放空间的角度建立了 1-vs-set 模型,该模型以支持向量机(support vector machine, SVM)^[8]为基础,通过引入两个平行的超平面分别捕捉已知类的核心区域和扩展区域来定义决策边界,从而在保持对已知类别的高准确率的同时,减少对未知类别的误分类;Bendale 等人^[9]提出了一种开集深度网络方法,引入新的模型层 OpenMax,通过计算输入与已知类模型向量(mean activation vector, MAV)之间的距离,使用 Weibull 分布估计测试数据属于未知类的概率,实验结果表明,OpenMax 方法在拒绝未知类别和减少明显错误方面具有显著优势;Sun 等人^[10]提出条件高斯分布学习方法(conditional gaussian distribution Learning, CGDL),在变分自动编码器(variational auto-Encoder, VAE)^[11]的基础上,通过在潜空间中强制后验分布近似不同的多元高斯模型,从而实现目标域已知类分类和未知类鉴别;Shu 等人^[12]提出一种基于原型的开放深度网络(prototype-based open deep network, P-ODN),该方法包括两个阶段:初始训练阶段学

习每个已知类的原型和原型半径,增量训练阶段使用基于距离的多类三元组阈值方法检测未知类样本,相比传统基于特征的检测方法更具鲁棒性。

1.3 开集域适应

在 CSDA 场景中,源域和目标域数据特征空间不同但标签空间相同,在 OSR 中,训练数据和测试数据特征空间相同但标签空间不同,然而,在实际应用中,往往存在源域和目标域数据特征空间不同时标签空间也不同的情形,相比 CSDA 和 OSR,该情境更加贴近实际也更具挑战。为此, Saito 等人^[13]提出开集域适应(open-set domain adaptation, OSDA)以应对该问题,并提出了一种基于反向传播的开集域适应(open set domain adaptation by backpropagation, OSBP)方法,通过分类器和特征生成器之间的博弈,使特征生成器学习到能够分类目标域已知类和未知类的特征表示,该方法在多个数据集上验证了有效性; Shermin 等人^[14]在 OSBP 的基础上,设计了一个加权网络模块为每个输入样本自动计算特定的阈值,并以权重的形式加入到模型的训练中,进一步提升了模型性能; Saito 等人^[15]提出一对多网络(one-vs-all network, OVANET)方法,通过训练 OVA 分类器自动学习源域中最小类间距作为阈值,实现阈值的自动学习调整,并设计了一种硬负样本分类器(hard negative classifier sampling, HNCS),通过选择与正样本最相似的负样本来训练分类器,使得分类器能够更有效地学习正样本与负样本之间的边界; Liu 等人^[16]提出了一种用于开放集故障诊断(open-set fault diagnosis, OSFD)的方法,通过引入正则化模块到传统的 GAN 网络中,生成与源域数据分布相似但与每个类分布显著不同的数据作为未知类数据,从而将开集转化为伪闭集,使得源域和目标域类别数相同。

2 面向无监督跨域开集场景的动态熵阈值辐射源个体识别方法

2.1 问题的形式化描述

在 OSDA 中,域 D 由特征空间 $\mathcal{X}$ 和边缘概率分布 $P(X)$ 组成,其中 $X = (x_1, x_2, \dots, x_n) \in \mathcal{X}$, 给定域 $D = \{\mathcal{X}, P(X)\}$, 任务 T 由标签空间 $\mathcal{Y}$ 和目标预测函数 $f(\cdot)$ 组成,从概率的角度看,目标预测函数也可以被视为条件概率分布 $P(Y|X)$ 。

给定 s 个有标签的源域 $D_s = \{x_i^s, y_i^s\}_{i=1}^{n_s}$ 。其中 i 为源域样本索引; x_i^s 为源域第 i 个样本; y_i^s 为源域第 i 个样本的标签; n_s 为源域样本数量和一个无标签的目标域 $D_t = \{x_j^t\}_{j=1}^{n_t}$ 。其中, x_j^t 为目标域第 j 个样本, n_t 为目标域样本数量。

源域数据样本共有 K 个类别,目标域数据样本共有 $K+M$ 个类别。OSDA 的任务就是在目标域中含有未知类别的情况

下,利用有标签的源域数据 D_s 学习一个分类器 $f: x \rightarrow y$ 来很好地预测目标域数据 D_t 的标签 $y' \in \mathcal{Y}$ 。通常将目标域数据与源域数据分布不一致的情况定义为域偏移(Domain Shift)或协变量偏移(Covariate Shift)^[17],类偏移(Class Shift)作为域偏移的一种形式,特指目标域包含私有类的情况;同时,将源域和目标域数据都存在的类别称为已知类(或公有类),仅在目标域数据中存在的类别称为未知类(或私有类)。

2.2 模型训练及损失函数

本文所用神经网络主要由 2 个部分组成,分别是特征提取器 G 和类别预测器 F ,具体网络结构如图 1 所示。其中,特征提取器 G 由 1 个卷积层和 4 个深度残差网络组成,用以深度提取源域和目标域信号数据的指纹信息 $G(x_s)$ 和 $G(x_t)$,类别预测器 F 使用 2 层线性全连接层和 Softmax 函数对源域数据深度指纹特征 $G(x_s)$ 进行分类,分类输出维度为 K 维,激活函数为 tanh 函数,并使用 LayerNorm 对单个样本进行层归一化。




图 1 所提方法神经网络结构

在模型训练过程中,假设源域数据分布为 $P(x_s, y_s)$,目标域数据分布为 $P(x_t, y_t)$,通过特征提取器 G 的映射,将输入信号 x 变换为 D 维深度指纹特征向量 $G(x) \in \mathbb{R}^D$,而后将源域数据指纹特征通过分类器 F 得到 K 维分类预测结果 $F(G(x)) \in \mathbb{R}^K$,并通过交叉熵损失 $\mathcal{L}_{src}$ 进行反向传播:

$$\mathcal{L}_{src} = -E_{(x_s, y_s) \in \mathcal{X}_s \times \mathcal{Y}_s} \sum_{k=1}^K q_k \log \delta_k (F(G(x^s))) \quad (1)$$

式中: $\delta_k(a) = \frac{\exp(a_k)}{\sum_i \exp(a_i)}$ 表示 K 维向量 a 经 Softmax 函数输出的第 k 个元素; q_k 表示源域数据标签的独热编码向量。

将源域和目标域数据指纹特征通过最小化 MMD 损失减少两域分布差异:

$$\mathcal{L}_{\text{mmd}} = \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \phi(G(x_i^s)) - \frac{1}{n_t} \sum_{j=1}^{n_t} \phi(G(x_j^t)) \right\|_{\mathcal{H}}^2 \quad (2)$$

式中: ϕ 为映射函数, 将原数据映射到 RKHS 中。

总体损失函数:

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{src}} + \mathcal{L}_{\text{mmd}} \quad (3)$$

在训练过程中, 目标域数据可以通过分类器输出获得属于已知类的伪标签。

$$\hat{y}^t = \arg \max_j P_i(j) \quad (4)$$

式中: $P_i(j)$ 为样本 x_i 属于类别 j 的概率。

实际上, 目标域中不仅包含已知类数据, 还包含未知类数据。为此, 引入信息论中熵的概念, 能够反映出随机变量的不确定性, 目标域数据输出熵值越大, 表示该样本分类为已知类的不确定性越大, 即更可能属于未知类; 反之, 该目标域数据属于已知类的可能性越大。本方法中, 为每个已知类都设置了单独的熵阈值 Ent_{th}^k (表示第 k 类熵阈值)。考虑到固定熵阈值通常需要大量实验调试以确定最佳阈值, 且对不同数据集往往需要调整不同阈值, 因此本文采取移动平均的方式动态调整熵阈值:

$$\overline{\text{Ent}}_{\text{batch}}^k = -\frac{1}{|S_k|} \sum_{i \in S_k} \sum_{j=1}^c P_i(j) \log P_i(j) \quad (5)$$

式中: $\overline{\text{Ent}}_{\text{batch}}^k$ 表示小批量数据中第 k 类的平均熵; $S_k = \{i | \arg \max_j (P_i) = k\}$ 表示小批量数据中所有被预测为类别 k 的样本的索引集合; $P_i(j)$ 表示样本 x_i 属于类别 j 的概率。

$$\text{Ent}_{\text{th}}^k = \alpha \cdot \text{Ent}_{\text{original}}^k + (1 - \alpha) \cdot \overline{\text{Ent}}_{\text{batch}}^{s,k} \quad (6)$$

式中: $\text{Ent}_{\text{original}}^k$ 为原始第 k 类熵阈值; $\overline{\text{Ent}}_{\text{batch}}^{s,k}$ 为源域小批量数据中第 k 类平均熵, 每次训练更新后 Ent_{th}^k 自动转化为 $\text{Ent}_{\text{original}}^k$, α 为超参数, 本文取 0.8。

$$\text{Ent}_{\text{th}}^k = \alpha \cdot \text{Ent}_{\text{original}}^k + (1 - \alpha) \cdot \overline{\text{Ent}}_{\text{batch}}^{t,k} \quad (7)$$

式中: $\overline{\text{Ent}}_{\text{batch}}^{t,k}$ 为目标域小批量数据中第 k 类平均熵。

至此, 根据各类熵阈值对目标域数据伪标签进行调整:

$$y_j^t = \begin{cases} k & \text{if } y^t = k, \text{Ent}_j^t < \lambda \cdot \text{Ent}_{\text{th}}^k \\ k+1 & \text{if } y^t = k, \text{Ent}_j^t \geq \lambda \cdot \text{Ent}_{\text{th}}^k \end{cases} \quad (8)$$

式中: Ent_j^t 表示目标域数据中第 j 个样本模型输出的熵值; λ 表示超参数, 本文取 $\lambda=2$ 。

2.3 算法流程

本节主要介绍面向无监督跨域开集场景的动态熵阈值辐射源个体识别方法的基本算法, 如算法 1 所示。主要由 3 部分组成, 步骤 1~5 为模型训练部分, 步骤 6~9 为各已知类熵阈值动态更新部分, 步骤 10 根据模型分类器的输出和每类熵阈值对目标域数据标签进行预测。

算法 1 所提方法实现算法

1. 预搭建深度模型的特征提取器 G 和分类器 F , 输入源域数据 x_i^s 、源域数据标签 y^s 和目标域数据 x_j^t , 迭代次数为 epoch, 初始熵阈值 $\text{Ent}_{\text{original}}^k = 0$
2. for epoch in 1:T do
3. x_i^s 和 x_j^t 先后分别输入模型特征提取器 G 和分类器 F , 得到 $F(G(x_i^s))$ 和 $F(G(x_j^t))$;
4. 将 $F(G(x_i^s))$ 和 $F(G(x_j^t))$ 输入到 Softmax 层, 得到 $\delta_k(F(G(x_i^s)))$ 和 $\delta_k(F(G(x_j^t)))$;
5. 根据式 (1~3) 分别计算源域数据训练的交叉熵损失函数 $\mathcal{L}_{\text{src}}$ 、MMD 损失 $\mathcal{L}_{\text{mmd}}$, 并最终得到模型总的损失 $\mathcal{L}_{\text{total}}$;
6. 根据分类器输出和式 (4), 为目标域数据打上伪标签 y^t ;
7. 根据式 (5) 计算小批量源域和目标域数据中各类样本的平均熵 $\overline{\text{Ent}}_{\text{batch}}^{s,k}$ 和 $\overline{\text{Ent}}_{\text{batch}}^{t,k}$;
8. 根据式 (6) 熵阈值 Ent_{th}^k , 而后令 $\text{Ent}_{\text{original}}^k = \text{Ent}_{\text{th}}^k$;
9. 根据式 (7) 更新熵阈值 Ent_{th}^k , 而后令 $\text{Ent}_{\text{original}}^k = \text{Ent}_{\text{th}}^k$;
10. 根据式 (8) 更新标签 $\hat{y}^t$ 为模型预测标签 y_j^t ;
11. end

3 实验

3.1 实验数据集

实验中使用 Oracle^[18] 数据集和 Wisig^[19] 数据集对所有算法进行测试。

(1) Oracle 数据集。Oracle 数据集是目前公开的具有代表性的射频指纹识别数据集之一, 该数据集包含从 100 多个商用现货 (COTS) Wi-Fi 设备和 16 个 USRPX310 软件定义无线电 (SDR) 节点中收集的大量 IQ 样本数据, 这些数据在静态和动态信道环境下捕获。本实验选取 USRP X310 SDR 测试平台数据子集作为源域数据, 该数据子集中包含 16 个发射器和 1 个接收器的 IQ 样本数据。本实验选取其中前 12 个发射器信号为已知类, 后 4 个发射器信号为未知类, 在该源域数据上加上不同功率的高斯白噪声作为目标域数据。

(2) Wisig 数据集: 是目前公开的最大规模的 Wi-Fi 射频指纹识别数据集, 该数据集包含 1 000 万个数据包, 这些

数据包来自 174 个商用 Wi-Fi 发射器和 41 个 USRP 接收器，在 1 个月内的 4 次采集捕获。其中包含原始数据集和已经处理过的 4 个数据子集（ManySig、ManyTx、ManyRx 和 SingleDay），本实验选取 SingleDay 数据子集作为基本集，该数据子集中包含 28 个发射器和 10 个接收器的 800 个信号，为进一步控制变量，在该子集中选择第 1 个接收器接收到的 28 个发射器的 800 个信号作为源域数据，其中前 25 个发射器信号为已知类，后 3 个发射器信号为未知类，在该源域数据上加上不同功率的高斯白噪声作为目标域数据。

在 Oracle 和 Wisig 数据集中，用 Draw 表示原始数据集，用 D_0 、 D_1 、 D_2 、 D_3 、 D_4 、 D_8 、 D_{10} dB 分别表示向原始数据集中加入 0、1、2、3、4、8、10 dB 噪声的数据集。

3.2 评价指标

在开集域适应场景中，通常以已知类平均准确性（OS*）、未知类的准确性（UNK）和 H 分数（harmonic open set, HOS）^[20] 作为评价指标，HOS 表示 OS* 和 UNK 的调和平均值，既考虑了模型对已知类分类水平，也考虑了对未知类鉴别能力，因此更能反映出模型的性能，HOS 计算为：

$$H = 2 \cdot \frac{\text{OS}^* \cdot \text{UNK}}{\text{OS}^* + \text{UNK}} \quad (9)$$

3.3 实验结果与分析

本节在 Oracle 和 Wisig 数据集上对现有具有代表性的开集域适应方法的性能进行了比较，所有算法的特征提取器和分类器保持一致，并对参数进行了合理调整，以获得最佳模型性能。

表 1 为代表性开集域适应方法在 Oracle 数据集上的实验结果，表 2 为代表性开集域适应方法在 Wisig 数据集上的实验结果。在表 1~2 中，选取经典闭集域适应方法中域对抗神经网络（domain-adversarial training of neural networks, DANN），以及开集域适应方法中 OSBP 和 OVANET 方法与本方法进行比较，从结果中可以看出，闭集域适应方法（DANN）无法鉴别未知类，不适用于开集域适应场景，在使用时需要改进；相比其他代表性开集域适应方法（OSBP、OVANET），本文方法在 Oracle 和 Wisig 数据集上的整体性能均

较优。特别是在低信噪比条件下，本文方法在 OS*、UNK 和 HOS 指标上均表现出色，这表明本文方法在处理开集域适应问题时具有显著优势。

4 结语

本文提出了一种面向无监督跨域开集场景的动态熵阈值辐射源个体识别方法，通过引入最大均值差异（MMD）和动态熵阈值策略，有效解决了训练和测试数据分布不同导致的模型性能降低问题。实验结果表明，该方法在 Oracle 和 Wisig 射频指纹数据集上均具有较高的识别准确率，验证了其有效性。未来的研究将集中在进一步优化模型结构和算法，以提高识别准确率和鲁棒性，并探索在更复杂的实际应用场景中的应用。

表 1 代表性开集域适应方法在 Oracle 数据集上的实验结果

方法	Draw $\rightarrow D_0$ dB			Draw $\rightarrow D_1$ dB			Draw $\rightarrow D_2$ dB			Draw $\rightarrow D_3$ dB		
	OS*	UNK	HOS	OS*	UNK	HOS	OS*	UNK	HOS	OS*	UNK	HOS
DANN	58.37	—	—	66.99	—	—	73.40	—	—	79.46	—	—
OSBP	43.30	60.39	50.44	50.90	54.10	52.92	44.33	40.92	42.56	58.80	50.57	56.84
OVANET	57.24	73.96	64.53	38.87	98.25	55.70	51.51	92.34	66.13	64.21	90.90	75.6
本文方法	73.15	82.65	77.61	73.36	93.27	82.12	78.95	94.9	86.19	83.92	98.16	90.48
方法	Draw $\rightarrow D_4$ dB			Draw $\rightarrow D_8$ dB			Draw $\rightarrow D_{10}$ dB			平均		
	OS*	UNK	HOS	OS*	UNK	HOS	OS*	UNK	HOS	OS*	UNK	HOS
DANN	84.64	—	—	94.79	—	—	97.77	—	—	79.35	—	—
OSBP	71.27	98.36	82.65	63.01	94.11	75.48	78.19	85.43	81.65	59.14	68.67	62.87
OVANET	69.43	98.69	81.51	95.03	100	97.45	99.07	99.78	99.42	67.91	93.56	77.19
本文方法	88.95	98.78	93.61	95.87	99.39	97.6	96.01	99.8	97.87	84.32	95.28	89.35

表 2 代表性开集域适应方法在 Wisig 数据集上的实验结果

方法	Draw $\rightarrow D_0$ dB			Draw $\rightarrow D_1$ dB			Draw $\rightarrow D_2$ dB			Draw $\rightarrow D_3$ dB		
	OS*	UNK	HOS	OS*	UNK	HOS	OS*	UNK	HOS	OS*	UNK	HOS
DANN	67.05	—	—	73.42	—	—	78.01	—	—	87.83	—	—
OSBP	46.34	66.80	54.72	56.28	66.40	60.93	60.01	68.76	64.09	66.61	68.76	67.67
OVANET	57.24	73.96	64.53	38.87	98.25	55.70	51.51	92.34	66.13	64.21	91.90	75.60
本文方法	63.03	84.25	72.11	66.89	83.81	74.4	72.20	85.56	78.31	76.21	88.40	81.85
方法	Draw $\rightarrow D_4$ dB			Draw $\rightarrow D_8$ dB			Draw $\rightarrow D_{10}$ dB			平均		
	OS*	UNK	HOS	OS*	UNK	HOS	OS*	UNK	HOS	OS*	UNK	HOS
DANN	89.99	—	—	99.28	—	—	99.74	—	—	85.05	—	—
OSBP	66.43	71.32	68.79	73.58	48.92	58.77	75.57	35.76	48.54	63.55	60.96	60.50
OVANET	69.43	98.69	81.51	95.03	100	97.45	99.07	99.78	99.42	67.91	93.56	77.19
本文方法	76.43	91.47	83.28	86.37	96.28	91.05	91.05	99.12	94.92	76.03	89.84	82.27

参考文献:

- [1] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE transactions on knowledge and data engineering, 2010, 22(10): 1345-1359.
- [2] PAN S J, TSANG I W, KWOK J T, et al. Domain adaptation via transfer component analysis[J]. IEEE transactions on neural networks, 2011, 22(2): 199-210.
- [3] LONG M S, WANG J M, DING G G, et al. Transfer feature learning with joint distribution adaptation[C]//2013 IEEE International Conference on Computer Vision. Sydney, Piscataway: IEEE, 2013: 2200-2207.
- [4] WANG J, ZHANG B N, ZHANG J, et al. Specific emitter identification based on deep adversarial domain adaptation[C/OL]//2021 4th International Conference on Information Communication and Signal Processing (ICICSP).Piscataway: IEEE, 2021[2025-01-22].<https://ieeexplore.ieee.org/document/9611854>.DOI:10.1109/ICICSP.54369.2021.9611854.
- [5] ZHANG X L, LI T Y, GONG P, et al. Variable-modulation specific emitter identification with domain adaptation[J].IEEE transactions on information forensics and security, 2022, 18: 380-395.
- [6] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks[J].Domain adaptation in computer vision applications, 2017: 189-209.
- [7] SCHEIRER W J, DE REZENDE R A, SAPKOTA A, et al. Toward open set recognition[J]. IEEE transactions on pattern analysis and machine intelligence, 2013, 35(7): 1757-1772.
- [8] CORTES C, VAPNIK V. Support-vector networks[J].Machine learning, 1995,20:273-297.
- [9] BENDALE A, BOULT T E. Towards open set deep networks[EB/OL].(2015-11-19)[2025-05-23].<https://doi.org/10.48550/arXiv.1511.06233>.
- [10] SUN X, YANG Z N, ZHANG C, et al. Conditional gaussian distribution learning for open set recognition[C/OL]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Piscataway: IEEE, 2020[2025-03-12]. <https://ieeexplore.ieee.org/document/9157396>.DOI:10.1109/CVPR42600.2020.01349.
- [11] KINGMA D P, WELLING M. Auto-encoding variational bayes[EB/OL].(2022-12-10)[2025-04-12].<https://doi.org/10.48550/arXiv.1312.6114>.
- [12] SHU Y, SHI Y M, WANG Y W, et al. P-ODN: prototype-based open deep network for open set recognition[J]. Scientific reports, 2020, 10(1): 7146.
- [13] SAITO K, YAMAMOTO S, USHIKU Y, et al. Open set domain adaptation by backpropagation[C]//Computer Vision – ECCV 2018.Berlin:Springer, 2018: 156-171.
- [14] SHERMIN T, LU G J, TENG S W, et al. Adversarial network with multiple classifiers for open set domain adaptation[J]. IEEE transactions on multimedia, 2021, 23: 2732-2744.
- [15] SAITO K, SAENKO K. OVANet: one-vs-all network for universal domain adaptation[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2021: 8980-8989.
- [16] LIU Y, DENG A D, DENG M Q, et al. Transforming the open set into a pseudo-closed set: a regularized GAN for domain adaptation in open-set fault diagnosis[J/OL]. IEEE transactions on instrumentation and measurement, 2023[2024-11-12].<https://ieeexplore.ieee.org/abstract/document/10251634>.DOI:10.1109/TIM.2023.3315362.
- [17] SUGIYAMA M, KRAULEDAT M, MÜLLER K. Covariate shift adaptation by importance weighted cross validation[J]. The journal of machine learning research, 2007,8:985-1005.
- [18] SANKHE K, BELGIOVINE M, ZHOU F, et al. ORACLE: optimized radio classification through convolutional neural networks[C/OL]// IEEE INFOCOM 2019-IEEE Conference on Computer Communications. Piscataway: IEEE, 2019[2025-06-14].<https://ieeexplore.ieee.org/document/8737463>.DOI:10.1109/INFOCOM.2019.8737463.
- [19] HANNA S, KARUNARATNE S, CABRIC D. WiSig: a large-scale Wi-Fi signal dataset for receiver and channel agnostic RF fingerprinting[J]. IEEE access, 2022, 10:22808-22818.
- [20] FU B, CAO Z J, LONG M S, et al. Learning to detect open classes for universal domain adaptation[C/OL]//Computer Vision-ECCV 2020. Berlin: Springer, 2020: 567-583.

【作者简介】

王闯（1995—），男，安徽滁州人，硕士研究生，研究方向：迁移学习、模式识别。

俞璐（1973—），女，吉林长春人，博士，副教授，研究方向：多媒体信息处理、模式识别、图像处理等。

（收稿日期：2025-03-12 修回日期：2025-09-03）