

基于域适应的辐射源个体识别研究综述

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, 江苏 南京 210001)

摘要: 辐射源个体识别技术在军事场景中发挥着越来越重要的作用, 在实际环境中辐射源设备发射的信号经常会受到噪声等因素影响, 导致信号特征分布发生变化。由于域适应方法能有效解决这一问题, 为此对近几年基于域适应的辐射源个体识别技术的发展现状进行综述。首先, 概述域适应方法及其分类, 介绍不同场景下的域适应方法; 其次, 介绍域适应方法的相关原理及其在辐射源个体识别领域的应用; 再次, 收集现有可用于辐射源个体识别研究的公开数据集; 最后, 根据辐射源个体识别存在的问题提出未来的发展方向。

关键词: 辐射源个体识别; 迁移学习; 域适应; 最大均值差异; 对抗学习

DOI: 10.11907/rj.241261

开放科学(资源服务)标识码(OSID):

中图分类号: TN957.51

文献标识码: A

文章编号: 1672-7800(2024)006-0205-09



A Review of Specific Emitter Identification Based on Domain Adaptation

ZHANG Taotao, XIE Jun, QIAO Pingjuan

(College of Command and Control Engineering, Army Engineering University of the PLA, Nanjing 210001, China)

Abstract: The individual identification technology of radiation sources is playing an increasingly important role in military scenarios. In actual environments, the signals emitted by radiation source equipment are often affected by factors such as noise, leading to changes in the distribution of signal characteristics. Due to the effective solution of domain adaptation methods to this problem, this article reviews the current development status of domain adaptation based radiation source individual identification technology in recent years. Firstly, provide an overview of domain adaptation methods and their classification, and introduce domain adaptation methods for different scenarios; Then introduce the relevant principles of domain adaptation methods and their applications in the field of individual identification of radiation sources; Next, collect publicly available datasets that can be used for individual identification research of radiation sources; Finally, based on the existing problems in individual identification of radiation sources, future development directions are proposed.

Key Words: specific emitter identification; transfer learning; domain adaptation; maximum mean discrepancy; adversarial learning

0 引言

辐射源个体识别(Specific Emitter Identification, SEI)是一种通过分析辐射源无线电信号特征区分各辐射源的技术。该技术在军事场景中发挥着越来越重要的作用,常被用于识别敌方雷达和其他无线电信号源。由于辐射源设备硬件部分在生产和制造过程中存在一定的差异,使辐射源个体的某种属性独一无二,难以伪造,这种属性也被称为射频指纹,通过识别射频指纹就能识别辐射源个体^[1]。

传统SEI技术主要通过人工提取指纹特征,然后使用提取的指纹特征训练分类器。梁江海等^[2]、桂云川等^[3]采用经验模态分解方法提取特征,然后使用支持向量机算法对多个通信辐射源个体进行分类识别。张国柱等^[4]使用小波变换提取包络特征,采用 k 近邻算法进行分类识别。然而传统的辐射源个体识别技术需要人工提取特征,因此必须要具有一定先验知识的人才可能完成操作。

随着人工智能的快速发展,深度学习在许多领域得到了成功应用。将深度学习应用于SEI,可通过深度神经网络(Deep Neural Networks, DNN)深入提取辐射源信号的指纹特征,以提高识别性能。目前,在辐射源个体识别领域

收稿日期: 2024-03-18

作者简介: 张涛涛(1992-),男,中国人民解放军陆军工程大学指挥控制工程学院硕士研究生,研究方向为辐射源识别和无线网络;谢钧(1973-),男,博士,中国人民解放军陆军工程大学指挥控制工程学院教授、博士生导师,研究方向为无线网络;乔平娟(1999-),女,中国人民解放军陆军工程大学指挥控制工程学院硕士研究生,研究方向为辐射源识别和无线网络。本文通讯作者: 谢钧。

中已有多种基于深度学习的方法。Wong 等^[5]提出一种利用卷积神经网络(Convolutional Neural Networks, CNN)识别辐射源的方法,仅使用接收到的原始 IQ 信号数据作为输入来估计每个辐射源的 IQ 不平衡参数。Wang 等^[6]通过压缩复值神经网络提高 SEI 性能。Tyler 等^[7]使用长短期记忆递归神经网络(Long Short Term Memory, LSTM)网络从预处理后的射频信号中学习指纹特征。

然而,上述两类方法只有在训练数据和测试数据遵循独立同分布条件下才成立。实际中,信道环境、发射距离、时间、空间等条件的变化都会使辐射源发射信号发生变化,导致数据分布发生差异,造成训练好的模型泛化能力较差。随后,迁移学习(Transfer Learning, TL)的出现突破了这些限制,已成功应用于医学图像诊断、生物信息分析和交通应用等领域^[8-10]。其中,域适应是迁移学习中较为流行的方法,被认为是一种可靠的 SEI 解决方案。

1 域适应介绍

1.1 迁移学习与域适应

在传统方法中,当数据集样本没有标签时就无法使用有监督的机器学习方法,而迁移学习利用在源域任务中学习到的知识提高与源域相似的目标域任务的性能,无需目标域任务的数据有标签,目前已在多个领域广泛使用。

域适应(Domain Adaptation, DA)是一种较为流行的迁移学习方法。目前,在计算机视觉中应用了很多 DA 方法,主要用于图像分类、目标识别和目标检测等任务,虽然输入数据的形式不一样,但通过改进和扩展可将同样的方法应用在 SEI 领域中^[11-15]。此外,DA 能在源域数据有标注和目标域数据无标注的情况下,通过训练一种模型将源域的知识或特征表示转移到目标域中,以提高目标域数据的预测准确性。在现实世界中,由于目标域的数据很难获取并标注,因此 DA 方法在解决跨域问题上具有很大的应用价值。

1.2 域适应方法分类

根据源域的数量,域适应可分为单源域适应、多源域适应和无源域适应。根据源域和目标域标签集关系的约束,可将 DA 分为闭集域适应、开集域适应、部分域适应和通用域适应,如图 1 所示。

其中,单源域适应只包含一个源域和一个目标域;多源域适应包含多个源域和一个目标域;无源域适应没有源域数据,主要考虑数据的隐私保护及数据传输的成本需求^[16,17]。此外,闭集域适应指源域的标签集和目标域的标签集所包含的类别相同,以下介绍的 SEI 方法都基于闭集场景;开集域适应指源域的标签集包含的类别是目标域的一个子集^[18-20];部分域适应指目标域标签集包含的类别是源域的一个子集^[21-23];通用域适应指源域和目标域的标签集关系未知^[24,25]。




Fig. 1 Domain adaptation method classification

图 1 域适应方法分类

2 基于域适应的辐射源个体识别

目前,基于域适应的 SEI 研究方法大多集中在单源域适应场景,还有部分基于多源域适应场景。基于域适应的辐射源个体识别方法分类如图 2 所示。




Fig. 2 SEI method classification based on domain adaptation

图 2 基于域适应的 SEI 方法分类

2.1 基于单源域适应的辐射源个体识别方法

在单源域 SEI 场景中,只有一个源域和一个目标域,基本思想是通过学习源域和目标域间的域不变特征,将源域和目标域特征分布对齐,从而提高目标域的识别准确率。学习域不变特征主要有最大均值差异(Maximum Mean Discrepancy, MMD)和对抗学习。

2.1.1 基于 MMD 的辐射源个体识别

MMD 是度量两个分布之间差异的一种方法,在域适应方法中应用广泛^[26-29]。该方法将两个域的分布映射到一个高维再生核希尔伯特空间,然后在新的空间内计算两个域分布的差值。通过将 MMD 计算的结果作为优化目标,然后最小化 MMD 实现源域和目标域的差异最小化,从而学习到域不变特征使源域和目标域分布对齐。源域和目标域数据分布的 MMD 计算公式如式(1)所示。

$$MMD(p, q) \triangleq \left\| E_p[\varphi(x^s)] - E_q[\varphi(x^t)] \right\|_H \quad (1)$$

由于式(1)中期望 E_p 、 E_q 期望为无偏差估计,无法直接得到,因此使用均值替代期望,如式(2)所示。

$$MMD(X^s, X^t) \triangleq \left\| \frac{1}{n} \sum_{i=1}^n \varphi(x_i^s) - \frac{1}{m} \sum_{i=1}^m \varphi(x_i^t) \right\|_H \quad (2)$$

式中: H 为再生核希尔伯特空间; φ 将源样本特征分布 x_i^s ; 目标样本特征分布 x_i^t 映射到 H 空间; n 为源域样本的数量, m 为目标域样本的数量; X^s 表示源域 n 个样本的特征分布; X^t 表示目标域 m 个样本的特征分布。

迁移成分分析(Transfer Component Analysis, TCA)使用 MMD 作为源域和目标域边缘分布之间的差异度量方法^[30]。Long 等^[31]在 TCA 基础上进行了改进, 提出了联合分布域适应(Joint Distribution Adaptation, JDA), 将源域和目标域的条件分布和边缘分布进行对齐。在基于 MMD 的域适应方法中大多直接使用一个高斯核, 为了选择出最优核函数, Long 等^[32]提出多核 MMD(MK-MMD), 利用多个加权核构造一个总的核, 其平方定义如式(3)所示。

$$d_k^2(p, q) = \left\| E_p[\phi(x^s)] - E_q[\phi(x^t)] \right\|_{H_k}^2 \quad (3)$$

特征核 k 定义如式(4)所示。

$$\kappa \triangleq \left\{ k = \sum_{u=1}^m \beta_u k_u : \sum_{u=1}^m \beta_u = 1, \beta_u \geq 0, \forall u \right\} \quad (4)$$

式中: p, q 分别代表两个域的分布, 与 MMD 的区别在于 H_k 为具有特征核 k 的再生核希尔伯特空间; m 为核函数的个数; β_u 为核函数权重; k_u 代表一个具体的核; k 代表各个核的加权之和。

同时, Long 等^[32]提出一种基于 MK-MMD 的深度域适应网络(Deep Adaptation Networks, DAN), 如图 3 所示。该网络将前 3 个卷积层冻结, 后两个卷积层进行参数微调, 最后 3 个全连接层使用 MK-MMD 进行适配训练, 主要思想是前 3 层提取的通用特征是可迁移的, 无需再调整; 中间两层提取的特征迁移性稍差, 微调即可; 最后 3 个全连接层提取的特征不可直接迁移, 所以使用 MK-MMD 进行适配以实现特征的可迁移。




Fig. 3 DAN network structure

图3 DAN网络结构

(1) 针对跨接收机场景的辐射源个体识别。史萌恺^[33]对同一组辐射源设备, 使用不同接收机接受的样本指纹特征具有不同的分布。为了实现跨接收机的 SEI, 分别使用 TCA 和 JDA 的域适应方法。在实验中, 将接收机 A 接收的信号作为源域样本, 接收机 B 接收的信号作为目标域样本, 分别使用 TCA 和 JDA 方法进行训练。实验表明, JDA 识别的准确率相较于 TCA 略高, 证明了基于 TCA 和 JDA 的域适应可用于跨接收机场景。

(2) 针对信道噪声变化场景的辐射源个体识别。秦嘉^[34]通过实验说明, 当待识别信号受到的噪声干扰较大

时, 模型识别性能会受到影响。因此, 在高信噪比条件下训练的模型并不能保证可适用于低信噪比信号。为此, 提出了基于 MK-MMD 的 SEI 方法, 将 CNN 网络最后的两个全连接层的输出使用 MK-MMD 进行适配。

(3) 针对中心频率变化场景的辐射源个体识别。郭梁^[35]提出深度适配网络, 使用 ResNet-50 作为主干网络, 并在全连接层后使用 MMD 进行适配来减小源域与目标域间的差异^[36]。实验证明, 在经过 MMD 适配层后的模型识别准确率相较于没有适配层的模型提升很大。为了进一步提高识别准确率, 还对网络结构进行了优化, 提出了多表征域适配的深度神经网络, 将输入的时频信号图通过子网络分成多个不同的特征表示, 然后将每个特征表示都使用 MMD 进行适配, 以实现源域与目标域间更准确的特征对齐。以上方法优缺点如表 1 所示。

Table 1 Comparison of SEI methods based on MMD

表1 基于 MMD 的 SEI 方法比较

文献	方法	优点	缺点
	TCA	简单易用, 可处理高维数据	TCA: 只考虑了边缘分布忽略了条件分布
[33]	TCA 和 JDA	JDA: 同时考虑了边缘和条件分布, 能够保留类别结构信息	JDA: 依赖伪标签的准确率, 计算复杂度较高
[34]	MK-MMD	多个核可以捕获不同数据结构特征, 具有较高的鲁棒性和灵活性	计算复杂度较高, 确定最优核函数需要大量的实验验证; 忽略了条件分布
[35]	多表征 MMD	考虑了局部的语义结构信息, 特征匹配更加准确	网络结构较为复杂, 参数量较大; 忽略了条件分布

2.1.2 基于对抗学习的辐射源个体识别

对抗生成网络(Generative Adversarial Networks, GANs)是一种由生成器与判别器组成的神经网络模型, 其核心是生成器和判别器之间的对抗过程, 即生成器的目标是生成尽可能逼真的假样本, 而判别器的目标是尽可能准确区分真实样本和生成的假样本^[37]。Ganin 等^[38]将这种对抗思想融入 DA 中, 提出了领域对抗神经网络(Domain Adversarial Neural Networks, DANN)。

DANN 主要由特征提取器、域判别器和源分类器组成, 如图 4 所示。在图 4 和式(5)一式(12)中: $G_f(\cdot; \theta_f)$ 代表特征提取器; θ_f 为特征提取器的网络参数; $G_y(\cdot; \theta_y)$ 代表源分类器; θ_y 为源分类器的网络参数; $G_d(\cdot; \theta_d)$ 代表域判别器; θ_d 为域判别器的网络参数; L_y 代表源分类器的损失函数; L_d 代表域判别的损失函数; y 代表源分类标签, 一般从 0 开始递增; d 代表域标签, 取值为 0 和 1; ∂ 为求偏导符号, 对网络参数进行优化。

为了在准确源分类的同时, 实现域不变特征的学习, 需要如下优化过程:

步骤 1: 通过式(5)计算每个样本的分类损失, 通过式(6)计算每个样本的域分类损失。




Fig. 4 DANN network structure

图4 DANN网络结构

$$L_y^i(\theta_f, \theta_y) = L_y(G_y(G_f(x_i; \theta_f); \theta_y), y_i) \quad (5)$$

$$L_d^i(\theta_f, \theta_d) = L_d(G_d(G_f(x_i; \theta_f); \theta_d), d_i) \quad (6)$$

式中: i 代表一个样本; n 代表源域样本的个数; n' 代表目标样本的个数。

步骤2: 计算源域样本的平均分类损失, 同时计算源域样本和目标域样本的域判别器的平均损失, 如式(7)所示。

$$E(\theta_f, \theta_y, \theta_d) = \frac{1}{n} \sum_{i=1}^n L_y^i(\theta_f, \theta_y) - \lambda \left(\frac{1}{n} \sum_{i=1}^n L_d^i(\theta_f, \theta_d) + \frac{1}{n'} \sum_{i=n+1}^N L_d^i(\theta_f, \theta_d) \right) \quad (7)$$

式中: E 为总损失。

步骤3: 式(8)通过学习参数 θ_f, θ_y 使总损失最小化, 以实现准确分类; 式(9)通过学习参数 θ_d 使域判别器损失最大化, 目的是促使特征提取器学习域不变的特征来混淆域判别器。联合式(8)、式(9)可学习到一个平衡参数, 即在学习到域不变特征的同时实现准确分类。

$$(\hat{\theta}_f, \hat{\theta}_y) = \arg \min_{\theta_f, \theta_y} E(\theta_f, \theta_y, \hat{\theta}_d) \quad (8)$$

$$\hat{\theta}_d = \arg \max_{\theta_d} E(\hat{\theta}_f, \hat{\theta}_y, \theta_d) \quad (9)$$

步骤4: 通过反向传播更新特征提取器参数, 包括源分类器和域判别器产生的分类损失, 如式(10)所示。其中, 反向传播可最小化损失进而优化目标, 为了在最大化域判别器损失的同时保持反向传播方向, 在网络中还使用了梯度反转层。

$$\theta_f \leftarrow \theta_f - \mu \left(\frac{\partial L_y^i}{\partial \theta_f} - \lambda \frac{\partial L_d^i}{\partial \theta_f} \right) \quad (10)$$

步骤5: 分别对源分类器与域判别器的参数进行更新, 如式(11)、式(12)所示。

$$\theta_y \leftarrow \theta_y - \mu \frac{\partial L_y^i}{\partial \theta_y} \quad (11)$$

$$\theta_d \leftarrow \theta_d - \mu \lambda \frac{\partial L_d^i}{\partial \theta_d} \quad (12)$$

2.1.3 针对信道噪声变化场景的辐射源个体识别

针对信道噪声变化场景, Wang等^[39]提出一种基于深度对抗域适应的SEI方法, 使用改进的深度残差网络(Deep Residual Network, DRN)^[36]作为主干网络, 将功率谱

作为频域信息具有操作简单、高噪声条件下性能优越等特点^[26]。将原始数据转换为功率谱图输入网络, 实验表明该方法能有效提高网络在不同信噪比条件下的识别性能, 具有良好的适应性和泛化性能。

王聪等^[40]提出一种信道自适应的辐射源训练与识别方法, 借鉴了域对抗网络方法, 将域判别模块替换为信道判别模块, 并使用ResNet-18作为主干网络^[36]。具体为, 首先在源域数据上预训练特征提取模块和分类模块, 保存训练好的模型参数; 其次将源域数据、目标域数据送入训练好的网络, 通过信道判别模块进行对抗训练。

2.1.4 针对载波频率变化场景的辐射源个体识别

由于同一辐射源在不同载波频率下工作时的设备特性有所不同, 从而导致同一辐射源接收到的信号不同。当从不同频率的同一辐射源收集训练数据和测试数据时, SEI方法的识别率可能会下降。为了提高SEI在不同频率下的泛化性能, Huang等^[41]提出一种基于连续小波变换(Continuous Wavelet Transform, CWT)与DANN的方法CWT-DANN。该方法通过CWT将信号转换为时频分布图, 然后将时频图输入DANN进行训练。Baldini等^[42]将信号转化为图像作为卷积神经网络的输入, 然后通过各种方法进行比较, 包括递归图、连续小波变换和短时傅里叶变换, 实验表明基于小波的方法优于其他方法。

2.1.5 针对调制方式变化场景的辐射源个体识别

除了基于频率、噪声等场景的SEI方法, 还有一些研究调制方式改变场景的SEI方法。Zhang等^[43]提出一种基于DANN网络的可变调制SEI框架, 使用深度残差收缩网络(Deep Residual Shrinkage Networks, DRSN)作为主干网络, 设计了一个解调和重构模块获取无失真的信号^[44]。

为了更好地实现域转移, 设计了高斯编码器, 首先将提取的指纹特征拟合为高斯分布, 以约束特征映射空间; 然后使用原始信号、重构信号和两者的混合信号分别进行比较, 实验表明混合信号的效果更好。同时, 在相移键控和正交幅度调制方式上的实验可知, SEI框架可大幅度提升单个辐射源对单一调制识别的准确率。上述方法的优缺点如表2所示。

2.1.6 其他方法

(1) 针对信道噪声变化场景的辐射源个体识别。当待检测的信号和训练数据集训练时的信道噪声不一致时, 已训练好的模型识别率将严重退化。为此, 刘剑锋等^[45]提出一种基于迁移学习的辐射源个体识别方法, 将原始的IQ信号转为星座轨迹图输入卷积神经网络的训练网络。由于源域和目标域有相同的标签空间, 该方法通过目标域聚类得到目标域每个类别的分布区域; 然后使用类间紧密性约束将源域和目标域的同一样本推到相同的分布区域, 从而实现源域和目标域对齐。

Wang等^[46]提出多重差异的辐射源个体识别方法, 通

Table 2 Comparison of SEI methods based on DANN
表 2 基于 DANN 的 SEI 方法比较

文献	方法	优点	缺点
[39]	DADA	采用了功率谱特征,可降低噪声对指纹特征的影响;同时对齐边缘分布和条件概率分布	将信号转换为功率谱会受到采样率和数据长度的影响,可能无法准确估计每一个频率点上的功率;对抗平衡训练难度较大
[40]	DANN	领域适应性较强,减少过拟合	没有对齐条件概率分布;对抗平衡训练难度较大
[41]	CWT-DANN	小波变换可同时捕捉到时域特征和频域特征,可以得到更精确的信号表征	小波变换需要一定的专家知识,分析实现难度较大;对抗平衡训练难度较大
[43]	DANN+信号解调与重建+高斯编码器	对信号进行了解调和重建,有利于学习实际与理想信号的差异;引入了高斯编码器,可增强特征的鲁棒性和可区分度	信号解调和重建过程比较复杂;对抗平衡训练难度较大

常使用 MMD 测量源域和目标域整体分布的差异,以测量源域和目标域的每一类别的差异。其中,源域和目标域相同类别之间的差异叫类内差异;源域和目标域不同类别的差异叫类间差异。

将这两个差异作为优化目标,最小化类内差异可使源域和目标域同类别之间尽可能对齐;最大化类间差异使不同类别之间边界更清晰,从而分类更准确。

(2) 针对跨接收机场景的辐射源个体识别。Wang 等^[47]指出现有分布适应方法大多适应边缘分布、条件分布或两者兼有,但这些方法并未考虑到不同分布的重要性。

当数据集差异较大时边缘分布更占优势;当数据集相似时条件分布更占优势。为此,提出了一种域适应方法平衡分布自适应(Balanced Distribution Adaptation, BDA),以自适应利用边缘和条件分布差异的重要性。

针对跨接收机场景,Zheng 等^[48]提出一个结合自注意力和 BDA 的域适应方法。首先,在网络上使用自注意力模块增强特征的可辨别性;然后使用 BDA 方法将不同分布的特征映射到一个高维再生核希尔伯特空间。最后,利用 k 近邻算法识别辐射源,实现不同辐射源间的无监督迁移学习。上述方法的优缺点如表 3 所示。

Table 3 Comparison of other SEI methods
表 3 其他 SEI 方法比较

文献	方法	优点	缺点
[45]	目标聚类+类间紧密约束	星座图能反映出信道对信号的影响,可以了解到信号的失真情况,从而可以对信号做一定的预处理;考虑了类别的分布结构,在约束下可实现更加准确的匹配	星座图的准确性受信号的复杂度影响,且需要一定的专家知识;异常噪声数据、较高的数据维度都会影响到聚类的结果;没有考虑边缘分布对齐
[46]	类内约束+类间约束	类内的约束使得类内更加紧密,类间约束增大类间的距离,可减少不同类边界重合的问题,增加同类的匹配的准确度;同时考虑了边缘分布和条件分布对齐	依赖伪标签的准确性
[48]	BDA	自适应调整边缘分布和条件分布差异权重;可增强特征的可区分性	依赖伪标签的准确性;计算复杂度较高,同时受数据维度和噪声的影响

2.2 基于多源域适应的辐射源个体识别

单源域适应假定标注数据从单一源分布中采样而来,多源域适应(Multi-Source Domain Adaptation, MSDA)中实际标注的数据则从多个源收集而来。相较于单源域,多源域中包含充足的源信息,可将多个源学习到的信息融合迁移到目标域中。目前,多源域适应方法大多基于 MMD 和对抗学习,但与单源域不同的是,每个源都需要与目标域进行 MMD 和对抗学习^[49-51]。

2.2.1 基于 MMD 的辐射源个体识别

基于信道变化的场景,李林等^[52]提出一种多源域适应的辐射源个体识别方法,建立了一个具有和源域数目相同的分支子网络和一个联合网络,每个分支子网络包含一个域特征提取器和一个类别特征提取器。其中,类别特征提取器使用 MMD 学习类别间不变的特征,域特征提取器用

于提取域特定的相关特征。在域提取器和类别特征提取器之间设置一个正则化项并最大化此正则化项,以最大程度学习域相关特征。此外,这些特征主要包含每个域都有的特征及每个域之间互补的特征。联合子网络和每个分支子网络相同,但输入数据由单个源域和目标域变成了多个源域混和目标源。为了保持分类器输出结果的一致性,将分类器的输出差值最小化并作为优化目标。该方法的优点为利用了多源域的知识,可学习更完整的目标域指纹特征;缺点为未考虑域内的结构信息,增加了不同类别边界重合混淆的可能。

2.2.2 基于对抗学习的辐射源个体识别

为了适应信道环境的变化,李林^[53]在 SEI 中设计了多源子网对抗网络(MS-SAN)。通过在每个源域和目标域间增加一个对抗模块实现源域和目标域的特征对齐,并根据

每个源域的不同特征信息对域特征进行分类,以保留足够的域相关信息,从而进行类别特征对齐。该方法的优点为:考虑了域特定的特征信息、域不变特征信息,分类边界更准确;利用多个源域的特征信息可学习到更完整的目标域指纹特征。缺点为多个域对抗模块的对抗平衡相较于单个对抗模块的操作难度更大。

2.3 基于域适应的辐射源个体识别

表4展示了基于域适应辐射源个体识别方法。在迁移场景上,研究信道噪声变化场景占多数,其余为跨接收机场景、中心频率变化场景、调制方法变化场景及载波频率变化场景。在实际环境中,变化因素远不止以上几种,还有距离、码元发送速率等。在主干网络选择上,大多都

使用了深度残差网络,残差块使深度残差网络可提取更深层次的特征,而CNN可能因为网络加深丢失一些深度特征。输入网络的数据形式包括原始数据及原始数据变换后的时频图、功率图及星座轨迹图,在使用图的方法中与原始信号作为输入的情况进行实验发现,前者的效果优于原始信号。ResNet-50等方法在提出时的输入为图片,因此应用在信号上需要改动局部网络,虽然这一改动没有一定的理论依据,但很多方法直接将原始信号作为输入并对网络进行改进取得了很好的效果,因此在实验时可输入多种形式进行尝试。在数据集上,基本都使用了自建数据集,由于实验环境及辐射源设备不同,数据会存在偏差,在实验时可能需要对模型进行微调以适应新的数据集。

Table 4 Comparison of SEI methods based on domain adaptation

表4 基于域适应的SEI方法比较

文献	发表时间	域适应方法	数据集来源	发射机数量	输入数据形式	主干网络	迁移场景
[34]	2019	基于MK-MMD	自建数据集	6	原始信号	CNN	信道噪声
[33]	2021	基于MMD	自建数据集	5	原始信号	无	跨接收机
[35]	2021	基于MMD	自建数据集	9	时频图	ResNet-50	中心频率
[39]	2021	基于对抗学习	自建数据集	20	功率谱	DRN	信道噪声
[41]	2021	基于对抗学习	自建数据集	5	时频图	ResNet-18	载波频率
[45]	2021	基于类内类间约束	自建数据集	5	星座轨迹图	ResNet-50	信道噪声
[43]	2022	基于对抗学习	自建数据集	7	原始信号、解调和重构信号	DRSN	调制方式
[46]	2022	基于类内类间约束	公开数据集 ^[55]	10	原始信号	ResNet-50	信道噪声
[48]	2022	基于BDA	自建数据集	8	原始信号	CNN	跨接收机
[40]	2023	基于对抗学习	自建数据集	10	原始信号	ResNet-18	信道噪声
[52]	2023	基于MMD	公开数据集 ^[55]	16	原始信号	ResNet-50	信道噪声
[53]	2023	基于对抗学习	公开数据集 ^[55]	16	原始信号	ResNet-50	信道噪声

3 实验数据集

由表4可知,现有SEI研究多数集中在自建SEI数据集上,只有少数是在公开的SEI数据集上。使用自建SEI数据集存在以下问题:①自建SEI数据集采集标准配置等实际情况未知,训练模型只能适配此数据集,当切换数据集后训练好的模型性能将下降;②自建SEI数据集研究的场景局限性较高,例如研究跨接收机迁移场景的数据集无法适用载波频率的迁移场景^[54,55]。

因此,一个具有统一性和多样化的大规模公开SEI数据集十分必要。公开SEI数据集应包含更全、更统一的场景,可作为SEI技术的基准。此外,数据集的基准在图像识别等领域也起着重要的作用,公开的SEI数据集将有助于SEI技术的发展。为此,本文收集了公开可用于SEI研究的数据集,他们有着不同的采集配置,主要分为捕获数据集和增强数据集。

3.1 捕获数据集

捕获数据集直接采集无线信道传输的信号,更能反映实际情况,例如信道中包含多种噪声及辐射源设备不同的工作状态,这对测试和验证系统的实际性能有很大的价值,但数据采集过程较为困难,需要考虑设备工作的环境及影响设备工作的因素。捕获数据集如表5所示。

Table 5 Capture dataset

表5 捕获数据集

文献	发射机数量	发射器类型	接收器类型	采集环境	是否公开
[56]	16	USRP X310	USRP B210	室内开放区域	是
[57]	20	USRP X310 USRP N210	USRP N210	室外和室内	是
[58]	4	USRP X310	USRP B210	室外	是
[59]	50	Pycom 设备	USRP B210	室内和室外	是

Sankhe等^[56]创建了用于位相似USRP X310无线电射频指纹识别的数据集。该数据集所有发射器都是位相似USRP X310无线电设备,可发出通过MATLAB WLAN系统工具箱生成的符合IEEE 802.11a协议的数据帧,使用固定的一台USRP B210设备作为接收器。发射器与接收器的间隔距离从2 ft增加到62 ft,间隔为6 ft,每台发射器都收集了超过2 000万个样本。

此外,Shawabka等^[57]还使用了12台USRP N210和8台USRP X310作为发射器,可发出IEEE 802.11a/g协议的数据帧,使用USRP N210作为接受器,在3种不同的信道条件和两种不同的环境下收集了4组数据集。

Reus-Muns等^[58]提供了来自3种无线标准的4个不同发射器发射信号的数据集。其中,4个USRP X310发射器部署在4个不同位置,每个发射器分别传输IEEE 802.11a、长期演进或5G新无线电协议的数据帧,使用USRP B210作为接收机从每个发射器上采集15组数据,每组数据持

续采集2 s,每个协议共采集5组数据。

Elmaghub等^[59]使用50台Pycom设备在室内和室外环境连续工作5天,捕获了超过了2.1 TB通过WI-FI传输的数据。实验使用USRP B210作为接收器,每天以循环方式从每个设备捕获5次样本数据,其中每次捕获50 MB个复值IQ样本数据。

3.2 增强数据集

增强数据集是通过在捕获数据集中添加噪声等方式来提高数据的多样性,以获得多样化的数据信息,使系统能更好地适应多种复杂情况。目前,在SEI领域使用较多的方法是在原始数据中添加加性高斯白噪声来模拟信道噪声环境。Wang等^[46]从文献[56]创建的数据集中选择了10组不同的发射器数据,每组数据包含400 000个采样点,每个发射器有2 000个样本用于源域数据,并在源域数据中添加6种不同信噪比的噪声,以生成不同信噪比的数据。

4 未来发展方向

4.1 结合条件分布与边缘分布

在基于MMD和对抗学习的SEI方法中,大多单方面对源域和目标域进行特征条件分布对齐或边缘分布对齐。如果只对齐边缘分布,没有考虑域内的类别分布结构,可能会导致不同类别局部边界重合,导致混淆;如果只考虑条件分布,又无法从域的全局进行特征对齐。

为此,应考虑使用原型对齐方法对齐源域和目标域的特征条件,以及结合对抗学习的边缘分布对齐。原型是域内同类别样本在共享特征空间的特征平均值,其类别信息充分考虑了域内的语义结构信息,是一种更细粒度的类级对齐方法,通过结合特征分布对齐和边缘分布对齐,可实现更准确的域不变特征学习^[60]。

4.2 在SEI中使用多源域适应方法

影响SEI性能稳定性主要有环境和辐射源设备平台两类因素。环境因素包括一天中的时间、温度、大气条件、信道类型及辐射源设备的移动;平台因素包括设备硬件部分的非线性变化、IQ信号不平衡及信号频率、相位和时序偏移,还有设备工作时使用的中心频率、调制方式等。这两类因素会直接影响接收到的数据,从而影响算法性能。

一方面,在实际运行环境中,辐射源发射的信号数据是在不同影响因素下所收集的,例如不同的接收机、中心频率及信道噪声等,单个域可能会导致次优解^[61,62]。这些数据之间有着相似的特征分布,相较于单源域而言多源域中包含更丰富的知识,泛化能力更好^[63,64]。为此,通过使用多种策略融合多个源域知识可获得更好的迁移效果。

4.3 构建辐射源数据集

现有公开数据集较少,大部分模型都在自建数据集上进行研究。为了能使研究方法更具通用性、泛化性,可考

虑构建一个通用、场景更全的数据集。

4.4 在SEI中使用开集域适应方法

闭集域适应的设置是源域和目标域标签集相同,目前大多数SEI研究都基于闭集场景,但在实际环境中可能会遇到未知的类别,因为每一台的辐射源设备的指纹都独一无二,也可能因环境或设备平台等影响导致该类别无法识别。在闭集场景下,分类器的输出数目固定,如果使用该分类器对未知类进行识别,只会将其分成错误类别^[65]。

因此,开集域适应需要解决的问题是在正确分类已知目标样本的同时,如何区分未知目标样本和已知目标样本。如果不对已知样本和未知样本进行区分,在训练过程中遇到未知目标样本时,特征提取器将会提取其偏向与某已知分类相似的特征,使特征提取器对已知类别与未知类别产生混淆,导致负迁移问题,并且随着未知类别数量增多,产生的负迁移问题也会越来越严重。

5 结语

域适应方法是解决传统机器学习在SEI应用中的一种有效解决方案。在不同的迁移场景中,相较于直接使用训练好的模型,使用域适应方法的效果极大提高了目标域识别的准确率,随着迁移场景越来越多,将会越来越完善。

本文详细介绍了基于域适应的辐射源个体识别方法,并对每个方法进行了分析比较,发现了一些共性,找出了可能存在的一些问题。另外,收集了现有可用于辐射源个体识别的公开数据集。最后,对未来发展进行了展望,以期基于域适应的辐射源个体识别研究的工作者提供参考与借鉴。

参考文献:

- [1] TALBOT K I, DULEY P R, HYATT M H. Specific emitter identification and verification[J]. Technology Review, 2003, 113: 113-130.
- [2] LIANG J H, HUANG Z T, YUAN Y J, et al. A method for individual identification of communication emitters based on empirical mode decomposition[J]. Journal of China Academy of Electronic Sciences, 2013, 8(4): 393-397.
梁江海,黄知涛,袁英俊,等.一种基于经验模态分解的通信辐射源个体识别方法[J].中国电子科学研究院学报,2013,8(4):393-397.
- [3] GUI Y C, YANG J A, LYU J J, et al. Fractal feature extraction algorithm of communication radiation source based on empirical mode decomposition[J]. Journal of Detection and Control, 2016, 38(1): 104-108.
桂山川,杨俊安,吕季杰,等.基于经验模态分解的通信辐射源分形特征提取算法[J].探测与控制学报,2016,38(1):104-108.
- [4] ZHANG G Z, HUANG K S, JIANG W L, et al. Methods for extracting subtle features of emitters based on signal envelope[J]. Systems Engineering and Electronic Technology, 2006, 28(6): 795-797.
张国柱,黄可生,姜文利,等.基于信号包络的辐射源细微特征提取方法[J].系统工程与电子技术,2006,28(6):795-797.
- [5] WONG L J, HEADLEY W C, MICHAELS A J. Specific emitter identification using convolutional neural network-based IQ imbalance estimators[J]. IEEE Access, 2019, 7: 33544-33555.

- [6] WANG Y, GUI G, GACANIN H, et al. An efficient specific emitter identification method based on complex-valued neural networks and network compression [J]. *IEEE Journal on Selected Areas in Communications*, 2021, 39(8): 2305–2317.
- [7] TYLER J H, FADUL M M K, REISING D R, et al. An analysis of signal energy impacts and threats to deep learning based SEI [C]// Seoul: IEEE International Conference on Communications, 2022.
- [8] MUKHLIF A A, AL-KHATEEB B, MOHAMMED M A. Incorporating a novel dual transfer learning approach for medical images [J]. *Sensors*, 2023, 23(2): 570.
- [9] IBRAHIM N M, GABR D G, RAHMAN A, et al. Transfer learning approach to seed taxonomy: a wild plant case study [J]. *Big Data and Cognitive Computing*, 2023, 7(3): 128.
- [10] NACIR O, AMNA M, IMEN W, et al. YOLOv5 for traffic sign recognition and detection using transfer learning [C]// Tunis: IEEE International Conference on Electrical Sciences and Technologies in Maghreb, 2022.
- [11] LEE S, CHO S, IM S. DRANET: disentangling representation and adaptation networks for unsupervised cross-domain adaptation [C]// Nashville: IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021.
- [12] WANG R, WU Z, WENG Z, et al. Cross-domain contrastive learning for unsupervised domain adaptation [J]. *IEEE Transactions on Multimedia*, 2023, 25: 1665–1673.
- [13] HUANG J, GUAN D, XIAO A, et al. Category contrast for unsupervised domain adaptation in visual tasks [C]// New Orleans: IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022.
- [14] ZHOU W, DU D, ZHANG L, et al. Multi-granularity alignment domain adaptation for object detection [C]// New Orleans: IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022.
- [15] WANG Q, FINK O, VANGOOL L, et al. Continual test-time domain adaptation [C]// New Orleans: IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022.
- [16] LIU Y, ZHANG W, WANG J. Source-free domain adaptation for semantic segmentation [C]// Nashville: IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021.
- [17] DING N, XU Y, TANG Y, et al. Source-free domain adaptation via distribution estimation [C]// New Orleans: IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022.
- [18] JING M, LI J, ZHU L, et al. Balanced open set domain adaptation via centroid alignment [C]// Vancouver: AAAI Conference on Artificial Intelligence, 2021.
- [19] 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.
- [20] LI W, LIU J, HAN B, et al. Adjustment and alignment for unbiased open set domain adaptation [C]// Vancouver: IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023.
- [21] GU X, YU X, SUN J, et al. Adversarial reweighting for partial domain adaptation [J]. *Advances in Neural Information Processing Systems*, 2021, 34: 14860–14872.
- [22] YANG C, CHEUNG Y M, DING J, et al. Contrastive learning assisted-alignment for partial domain adaptation [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 34(10): 7621–7634.
- [23] CHOUDHURI S, ADENIYE S, SEN A. Distribution alignment using complement entropy objective and adaptive consensus-based label refinement for partial domain adaptation [J]. *Artificial Intelligence and Applications*, 2023, 1(1): 43–51.
- [24] YIN Y, YANG Z, HU H, et al. Universal multi-Source domain adaptation for image classification [J]. *Pattern Recognition*, 2022, 121: 108238.
- [25] CHANG W, SHI Y, TUAN H, et al. Unified optimal transport framework for universal domain adaptation [J]. *Advances in Neural Information Processing Systems*, 2022, 35: 29512–29524.
- [26] LI W, CHEN J, WANG Z, et al. IFL-GAN: improved federated learning generative adversarial network with maximum mean discrepancy model aggregation [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, 34: 10592–10515.
- [27] WANG W, LI H, DING Z, et al. Rethinking maximum mean discrepancy for visual domain adaptation [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 34(1): 264–277.
- [28] SIMON-GABRIEL C J, BARP A, SCHÖLKOPF B, et al. Metrizing weak convergence with maximum mean discrepancies [J]. *Journal of Machine Learning Research*, 2023, 24: 1–20.
- [29] MA Z, XU B, WANG L, et al. A unified weighted MMD for unsupervised domain adaptation [C]// Wuhan: 14th International Conference on Advanced Computational Intelligence, 2022.
- [30] PAN S J, TSANG I W, KWOK J T, et al. Domain adaptation via transfer component analysis [J]. *IEEE Transactions on Neural Networks*, 2010, 22(2): 199–210.
- [31] LONG M, WANG J, DING G, et al. Transfer feature learning with joint distribution adaptation [C]// Sydney: IEEE International Conference on Computer Vision, 2013.
- [32] LONG M, CAO Y, WANG J, et al. Learning transferable features with deep adaptation networks [C]// Lille: International Conference on Machine Learning, 2015.
- [33] SHI M K. Research on individual identification method of cross-receiver radiation source [D]. Zhengzhou: University of Strategic Support Forces Information Engineering, 2021.
史萌恺. 跨接收机辐射源个体识别方法研究 [D]. 郑州: 战略支援部队信息工程大学, 2021.
- [34] QIN J. Individual identification of communication emitters based on deep learning [D]. Beijing: Beijing University of Posts and Telecommunications, 2019.
秦嘉. 基于深度学习的通信辐射源个体识别 [D]. 北京: 北京邮电大学, 2019.
- [35] GUO L. Research on radiation source identification technology based on transfer learning [D]. Chengdu: University of Electronic Science and Technology of China, 2021.
郭梁. 基于迁移学习的辐射源识别技术研究 [D]. 成都: 电子科技大学, 2021.
- [36] SHAFIQ M, GU Z. Deep residual learning for image recognition: a survey [J]. *Applied Sciences*, 2022, 12(18): 8972.
- [37] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [C]// Proceedings of the 27th International Conference on Neural Information Processing Systems, 2014: 2672–2680.
- [38] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks [J]. *The Journal of Machine Learning Research*, 2016, 17(1): 2096–2030.
- [39] WANG J, ZHANG B, ZHANG J, et al. Specific emitter identification based on deep adversarial domain adaptation [C]// Shanghai: 4th International Conference on Information Communication and Signal Processing, 2021.

- [40] 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.
王聪, 但波, 张财生. 一种信道自适应的辐射源无监督训练与识别方法[J]. *兵器装备工程学报*, 2023, 44(4): 211–216.
- [41] HUANG K, YANG J, LIU H, et al. Deep adversarial neural network for specific emitter identification under varying frequency[EB/OL]. <https://doaj.org/article/998ab3fa0178484da67c0ca31be15d5a>.
- [42] BALDINI G, GENTILE C, GIULIANI R, et al. Comparison of techniques for radiometric identification based on deep convolutional neural networks[J]. *Electronics Letters*, 2019, 55(2): 90–92.
- [43] 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.
- [44] TANG P, XU Y, WEI G, et al. Specific emitter identification for IoT devices based on deep residual shrinkage networks[J]. *China Communications*, 2021, 18(12): 81–93.
- [45] LIU J F, YU H Y, DU J P, et al. Individual identification of dynamic noise emitters based on domain adaptation[J]. *Signal Processing*, 2021, 37(6): 1000–1007.
刘剑锋, 于宏毅, 杜剑平, 等. 基于领域自适应的动态噪声辐射源个体识别[J]. *信号处理*, 2021, 37(6): 1000–1007.
- [46] WANG T, YU L, WANG W, et al. Specific emitter identification based on the multi-discrepancy deep adaptation network[J]. *IET Radar, Sonar & Navigation*, 2022, 16(12): 2079–2088.
- [47] WANG J, CHEN Y, HAO S, et al. Balanced distribution adaptation for transfer learning[C]// New Orleans: IEEE International Conference on Data Mining, 2017.
- [48] ZHENG Y, YING W, HONG S, et al. A method for cross-receiver specific emitter identification based on CBAM-CNN-BDA[C]// Dali: IEEE 4th International Conference on Civil Aviation Safety and Information Technology, 2022.
- [49] LI K, LU J, ZUO H, et al. Multi-source contribution learning for domain adaptation[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 33(10): 5293–5307.
- [50] YAO X, ZHAO S, XU P, et al. Multi-source domain adaptation for object detection[C]// Nashville: IEEE/CVF International Conference on Computer Vision, 2021.
- [51] LI Y, YUAN L, CHEN Y, et al. Dynamic transfer for multi-source domain adaptation[C]// Nashville: IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021.
- [52] LI L, YU L, JIANG Z H, et al. Multi-source domain adaptive emitter individual identification method based on class feature alignment[J]. *Communication Technology*, 2023, 56(10): 1137–1145.
李林, 俞璐, 蒋曾辉, 等. 基于类特征对齐的多源域适应辐射源个体识别方法[J]. *通信技术*, 2023, 56(10): 1137–1145.
- [53] LI L. Individual identification of communication emitters based on multi-source domain adaptation[D]. Nanjing: Army University of Engineering, 2023.
李林. 基于多源域适应的通信辐射源个体识别[D]. 南京: 陆军工程大学, 2023.
- [54] AL-SHAWABKA A, RESTUCCIA F, D'ORO S, et al. Exposing the fingerprint: dissecting the impact of the wireless channel on radio fingerprinting[C]// IEEE INFOCOM 2020–IEEE Conference on Computer Communications, 2020: 646–655.
- [55] JAGANNATH A, JAGANNATH J, KUMAR P S P V. A comprehensive survey on radio frequency (RF) fingerprinting: traditional approaches, deep learning, and open challenges[J]. *Computer Networks*, 2022, 219: 109455.
- [56] SANKHE K, BELGIOVINE M, ZHOU F, et al. ORACLE: optimized radio classification through convolutional neural networks[C]// Paris: IEEE INFOCOM 2019–IEEE Conference on Computer Communications, 2019.
- [57] AL-SHAWABKA A, RESTUCCIA F, D'ORO S, et al. Massive-scale I/Q datasets for Wi-Fi radio fingerprinting[J]. *Computer Networks*, 2020, 182: 107566.
- [58] REUS-MUNS G, JAISINGHANI D, SANKHE K, et al. Trust in 5G open RANs through machine learning: RF fingerprinting on the POWDER PAWR platform[C]// Taipei: GLOBECOM 2020–2020 IEEE Global Communications Conference, 2020.
- [59] ELMAGHBUB A, HAMDAOUI B, WONG W K. ADL-ID: adversarial disentanglement learning for wireless device fingerprinting temporal domain adaptation[C]// Rome: IEEE International Conference on Communications, 2023.
- [60] CHEN C, XIE W, HUANG W, et al. Progressive feature alignment for unsupervised domain adaptation[C]// Long Beach: IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019.
- [61] MANSOUR Y, MOHRI M, ROSTAMIZADEH A. Domain adaptation with multiple sources[C]// 21st International Conference on Neural Information Processing Systems, 2008: 1041–1048.
- [62] YIN Y, YANG Z, HU H, et al. Universal multi-Source domain adaptation for image classification[J]. *Pattern Recognition*, 2022, 121: 108238.
- [63] REN C X, LIU Y H, ZHANG X W, et al. Multi-source unsupervised domain adaptation via pseudo target domain[J]. *IEEE Transactions on Image Processing*, 2022, 31: 2122–2135.
- [64] LI Y, WANG S, WANG B, et al. Transferable feature filtration network for multi-source domain adaptation[J]. *Knowledge-Based Systems*, 2023, 260: 110–113.
- [65] LI W, LIU J, HAN B, et al. Adjustment and alignment for unbiased open set domain adaptation[C]// Vancouver: IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023.

(责任编辑: 刘嘉文)