文章编号：2095-4980(2026)01-0098-09

一种用于特定辐射源识别的无监督域适应方法

吴　琼，李志刚，史继博，王　谦，查浩然*

(哈尔滨工程大学 信息与通信工程学院，黑龙江 哈尔滨 150001)

摘　要：移动通信技术的快速发展产生了丰富的无标记辐射源信号，为充分利用无标记数据，本文提出独立性准则无监督域适应(ICUDA)方法，用于特定辐射源识别。将独立性准则用于衡量源域和目标域之间的相似性，并与改进的卷积神经网络相结合，将知识从源域迁移到目标域，以帮助仅包含未标记数据的目标域提高分类性能。在基于实验室环境下采集的SDR数据集构建的7种迁移场景下，与基线方法及3种无监督域适应方法相比，本文所提方法在目标域均获得最好的分类性能，平均识别准确率为84.2%，证明所提方法可以在目标域上提取具有良好类间分离性、类内紧凑性的特征，有效减少目标域对高质量标记数据的依赖。

关键词：辐射源个体识别；无监督域适应；相似性度量；希尔伯特-施密特独立性准则

中图分类号：TN911.7　　**文献标志码：**A　　**DOI：**10.11805/TKYDA2024572

An unsupervised domain adaptation method for specific emitter identification

WU Qiong，LI Zhigang，SHI Jibo，WANG Qian，ZHA Haoran*

(College of Information and Communication Engineering，Harbin Engineering University，Harbin Heilongjiang 150001，China)

Abstract: The rapid development of mobile communication technology has generated abundant unlabeled radio source signals. To fully utilize unlabeled data, this paper proposes an Independence Criterion-based Unsupervised Domain Adaptation(ICUDA) method for specific emitter identification. The independence criterion is employed to measure the similarity between the source domain and the target domain, and combined with an improved convolutional neural network to transfer knowledge from the source domain to the target domain, thereby helping improve the classification performance of the target domain that contains only unlabeled data. Under seven transfer scenarios constructed based on Software-Defined Radio(SDR) dataset collected in a laboratory environment, compared with baseline methods and three unsupervised domain adaptation methods, the proposed method achieves the best classification performance in the target domain across all scenarios, with an average recognition accuracy of 84.2%, demonstrating that the proposed method can extract features with good inter-class separability and intra-class compactness on the target domain, effectively reducing the target domain's dependence on high-quality labeled data.

Keywords: Specific Emitter Identification(SEI)；Unsupervised Domain Adaptation(UDA)；similarity measure；Hilbert-Schmidt Independence Criterion(HSIC)

移动通信技术的蓬勃发展使万物互联成为数字经济和智能生活的核心[1]。随着各种设备的互联互通，海量电磁数据的生成和共享，智能物联网为社会、产业、医疗等领域提供了前所未有的机会与挑战。

为了确保无线通信的可靠性，特定辐射源个体识别技术因其采用物理层的指纹特征[2]而被认为是最具优势的

收稿日期：2024-10-25；**修回日期：**2025-01-22

基金项目：国家自然科学基金资助项目(62201172)；国家重点研发计划基金资助项目(2022YFE0136800)

***通信作者：**查浩然　email:zhahaoran@hrbeu.edu.cn

引用格式：吴琼,李志刚,史继博,等. 一种用于特定辐射源识别的无监督域适应方法[J]. 太赫兹科学与电子信息学报, 2026,24(1):98-106. DOI:10.11805/TKYDA2024572.

Citation format: WU Qiong,LI Zhigang,SHI Jibo,et al. An unsupervised domain adaptation method for specific emitter identification[J]. Journal of Terahertz Science and Elcetronic Information Technology, 2026,24(1):98-106. DOI:10.11805/TKYDA2024572.

入侵防御技术，并因此被广泛研究[3]。辐射源个体识别是以辐射源所发射的电磁波独有的射频指纹(Radio Frequency Fingerprint，RFF)特征为依据进行个体识别的。由于生产工艺的限制，辐射源所用的电子器件存在个体差异[4]。这种硬件上的差异会反映在其产生的电磁信号中，使不同辐射源均具有独一无二且难以篡改的射频指纹特征。传统的特定辐射源识别技术从信号产生的机理出发[5]，人工设计特征提取方法，包括变换域信息[6]、调制域信息[7]、信号图像信息[8]等特征。但这种方法易受到人为因素的影响，其表征辐射源个体信息的能力存在一定的局限性。

近年来，深度神经网络在各个领域的应用越来越广泛[9−13]，其对非线性特征的强大提取能力给特定辐射源识别领域带来了新的特征提取方法。深度学习有效挖掘深层射频特征，实现高效、快速的特征提取，提高个体辐射源识别的准确性。深度学习模型取得的高性能需要满足2个前提条件：a) 要求训练数据和测试数据具有一致的特征空间和分布；b) 网络需要丰富且准确的有标注数据才能训练出稳定的模型。因此，辐射源个体识别领域常常面临大数据与少标注的矛盾。随着现代通信、移动互联网等技术的快速发展，电磁空间中各种体制辐射源个体爆炸式增长，辐射源信号复杂多样。通过数据采集设备获取的大量无线信号常常是无标记的，而当前采用人工标注的数据标注方式使高质量的数据标注耗时且昂贵，导致辐射源个体识别领域高质量标记数据稀缺。迁移学习通过将已学习的知识迁移到新的领域，从而在数据较为有限的情况下提高目标域模型的性能。领域自适应(Domain Adaptation，DA)作为一种迁移学习技术，为解决特定辐射源个体识别的挑战提供了新的思路。领域自适应要解决的核心问题是源域和目标域分布差异的度量。相关对齐(Correlation Alignment，CORAL)[14]通过最小化源和目标域间的协方差矩阵对齐不同领域的分布，实现简单，但其仅关注二阶统计特性，难以捕捉更高阶的统计特性。高阶矩匹配(Higher−order Moment Matching，HoMM)[15]是对CORAL的高阶扩展，但使用时需提前指定所用阶数。最大均值差异(Maximum Mean Discrepancy，MMD)[16]是在再生核希尔伯特空间中，通过计算不同分布间对应数据点的均值向量间距离来度量它们之间的差异，要求数据分布具有凸核，且较容易陷入局部极小值。与其他分布距离度量相比，希尔伯特−施密特独立性准则(Hilbert−Schmidt Independence Criterion，HSIC)具有计算简单、收敛速率快、有限样本偏差小的优点[17]。因此，本文提出一种基于独立性准则的无监督域适应方法(ICUDA)，在目标域无标记样本的条件下实现高效准确的辐射源个体识别。

1　相关工作

1.1　深度学习

在辐射源个体识别领域，深度学习的主要思想是建立一个复杂的神经网络模型，利用丰富的具有高质量的标签样本学习网络模型中的参数，以达到较高的识别性能。针对通用神经网络在低信噪比环境下时域识别精确度较低的问题，PENG等[18]通过引入通道注意机制，使所提神经网络可以在不同的通道中提取有用特征，并抑制无用特征的影响，提高网络的识别性能。针对两路I/Q信号可能存在相位信息缺失，AGADAKOS等[19]使用深度复值神经网络直接对原始窄带I/Q信号进行辐射源个体识别，并通过ADS−B数据集和WiFi数据集证明，所提框架对具有截然不同的调制类型的两种信号均有较高的识别准确率，但复值神经网络存在训练难的问题。DU等[20]提出一种可变网络架构搜索机制，通过结合电磁信号时序特性和“块单元”结构，利用基于控制器的循环神经网络(Recurrent Neural Network，RNN)实现模型自动设计，旨在提升神经网络在不同环境下的辐射源个体识别鲁棒性。

在辐射源个体识别领域中，深度学习网络取得良好性能的前提是需要高质量的标记数据。但在实际应用中，获得的数据往往都是未标记的数据，高质量标记数据稀缺[21]。迁移学习被视为能有效解决上述问题的方法。

1.2　迁移学习

迁移学习涉及3个主要问题：何时迁移、迁移什么、如何迁移。何时迁移寻求的是在什么情况下应该完成迁移技术，源域与目标域相关性越强，迁移学习所能达到的性能越好；迁移什么决定了哪些部分的知识可以跨域或跨任务进行迁移；如何迁移致力于寻找将知识从源域迁移至目标域的方法或手段。迁移学习的目的是找到帮助提升目标域或目标任务性能的知识，并将它们成功地应用到目标域或目标任务中。

迁移学习方法[22]可以分4类：基于样本的迁移学习方法、基于特征表示的迁移学习方法、基于模型参数的迁移学习方法和基于关系知识的迁移学习方法。其中，基于特征表示和基于模型参数的方法应用更为广泛，这两种方法的核心是让源域和目标域共享部分参数或超参数。ZHANG等[23]验证了目标域网络模型参数在随机、微调和冻结3种迁移方式下，卷积神经网络和RNN迁移的有效性，为后续预训练−微调的迁移方法提供了理论支撑。

基于特征的迁移学习方法旨在通过特征变换，在特征空间中找寻公共特征表示数据，以达到最小化源域和

目标域样本分布之间差异的目的。特征变换与源域和目标域之间的距离度量有直接关系，因此，依据距离度量的性质将特征变换分为隐式和显式两类。

隐式特征变换是指分布距离的度量由模型自己学习得到而不是预先定义。针对通过源域和目标域样本转换到公共子空间进行学习的目标距离度量多为线性度量的情况，LUO 等[24]提出了通用且灵活的异构迁移距离度量学习框架。该框架可以采用任何(线性/非线性)迁移距离度量学习算法先学习源度量，再将预学习得到的源度量表示为一组知识片段，进而辅助目标域的距离度量学习。

显示特征变换是指采用预先定义好的显示分布距离度量。域适应网络(Deep Adaptation Networks，DAN)[25]是基于特征表示的迁移学习的一种代表性网络，旨在学习两个不同域之间的映射并对这两个域进行准确的分类。在该网络中，所有特定于任务的层的隐藏表示都嵌入到再生内核希尔伯特空间中，其中跨域分布的平均嵌入可以显式匹配。ZHU 等[26]提出了一种深度子域适应网络(Deep Subdomain Adaptation Network，DSAN)的方法实现准确对齐相关子域的分布。该方法基于局部最大平均差异，跨不同域对齐特定域层激活的相关子域分布来学习传输网络，实现了网络的快速收敛。为解决域适应过程中无法区分具有不同相似性的样本导致的域匹配不准确的问题，PENG 等[27]使用余弦相异度来测量特征空间中两点之间的距离，提出了一种基于相似性的适应网络。本文使用 HSIC 来衡量跨域样本间的相似性，并基于此构建了跨域样本的相似性度量函数。

2 基于独立性准则的无监督域适应方法

领域主要由数据和生成这些数据的概率分布构成。样本数据所处的特征空间和标签空间分别表示为 $\mathcal{X}$、$\mathcal{Y}$，则一个领域可以被表示为 $\mathcal{D}=\{\mathcal{X},\mathcal{Y},P(x,y)\}$。领域自适应的主要目的是将知识从源域传递到目标域。

本文研究了在无监督域适应(Unsupervised Domain Adaptation，UDA)情况下的辐射源个体识别问题，即源域通常含有丰富的高质量标记数据，而目标域通常仅含有大量未标记的数据。给定一个含有丰富的高质量标记数据的源域 $\mathcal{D}_{\mathrm{S}}=\{x_i,y_i\}_{i=1}^{N_{\mathrm{s}}}$ 和仅含有大量未标记数据的目标域 $\mathcal{D}_{\mathrm{T}}=\{x_j\}_{j=1}^{N_{\mathrm{t}}}$，其中 $x\in\mathcal{X}$，$y\in\mathcal{Y}$，且假设标签空间是有限的，即 $\mathcal{Y}=\{0,1,2,\cdots,L\}$。在源域和目标域的特征和类别空间均相同，仅概率分布不同的场景下，利用源域知识帮助目标域学习一个目标域上的预测函数 $f:x_{\mathrm{t}}\mapsto y_{\mathrm{t}}$，使 f 在目标域上拥有最小的预测误差：

$$f^{*}=\arg\min_{f} E_{(x,y)\in\mathcal{D}_{\mathrm{T}}}\ell\left(f(x),y\right) \tag{1}$$

式中 ℓ 为分类损失。

为能更好地适应无监督领域自适应的情形，本文提出的基于独立性准则的无监督域适应网络由特征提取器、分类器和相似性度量 3 个部分组成，整体结构如图 1 所示。

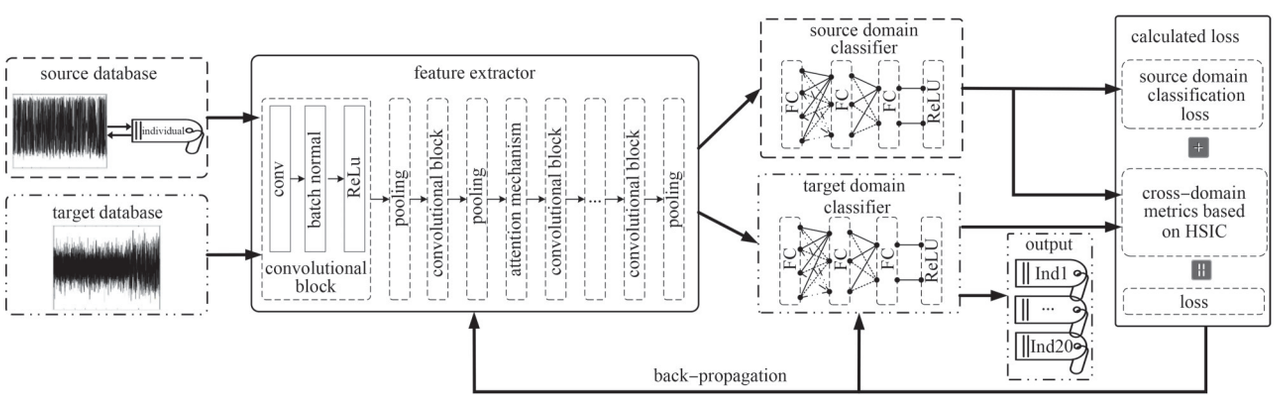

Fig.1 Overall structure of unsupervised domain adaptation network based on independence criterion

图 1 基于独立性准则的无监督域适应网络整体结构

2.1 相似性度量

本方法解决的核心问题是源域和目标域分布差异的度量。受 MA 等[28]的启发，ICUDA 利用 HSIC 衡量源域和目标域间的相似性。HSIC 是一种基于再生核希尔伯特空间中互协方差算子的希尔伯特–施密特范数，通常用于衡量不同分布之间依赖性的度量标准：

$$HS(P_{XY},\mathcal{H},\mathcal{G})=\left\|\boldsymbol{C}_{XY}\right\|^2=E_{XYX'Y'}\left[\kappa_X(X,X')\kappa_{Y'}(Y,Y')\right]+E_{XX'}\left[\kappa_X(X,X')\right]E_{Y'}\left[\kappa_Y(Y,Y')\right]-2E_{XY}\left\{E_{X'}\left[\kappa_X(X,X')\right]E_{Y'}\left[\kappa_Y(Y,Y')\right]\right\} \tag{2}$$

式中：P_{XY}为X、Y的联合概率分布；$\mathcal{H},\mathcal{G}$分别为X、Y的Hilbert空间；E为期望；$\boldsymbol{C}_{XY}$为X、Y的协方差矩阵；κ_X、κ_Y为X、Y的核函数；X'、Y'为与X和Y同分布的随机变量。

如果输入x在高维特征空间中的映射为$\Psi(x)$，则核函数的定义如下：

$$\kappa(x,z)=\Psi(x)^{\mathrm{T}}\Psi(z) \tag{3}$$

常见的核函数有线性核函数、多项式核函数和高斯核函数等。本文采用高斯核函数，即

$$\kappa(x_1,x_2)=\exp\left(-\frac{\|x_1-x_2\|_2^2}{\sigma^2}\right) \tag{4}$$

式中σ为尺度参数。

与互信息不同的是，HSIC不需要估计2个变量的概率密度，而是直接转化为采样的形式。由此得到HSIC的经验公式为：

$$\begin{cases}HS(\mathcal{D},\mathcal{H},\mathcal{G})=(m-1)^{-2}\mathrm{tr}(\kappa_X\boldsymbol{H}\kappa_Y\boldsymbol{H})\\ \text{s.t.}\quad \boldsymbol{H}=\boldsymbol{I}_m-\dfrac{1}{m}\boldsymbol{I}_m\boldsymbol{I}_m^{\mathrm{T}}\in\mathbb{R}^{m\times m}\end{cases} \tag{5}$$

式中：$\mathcal{D}\triangleq\left\{\left(x_i,y_i\right)\right\}_{i=1}^{m}$为来自$P_{XY}$的$m$个独立的样本对；$\mathrm{tr}(\cdot)$为矩阵的迹；$\kappa_X$、$\kappa_Y\in\mathbb{R}^{m\times m}$且$\kappa_{X_{i,j}}=\kappa(x_i,x_j)$；$\kappa_{Y_{i,j}}=\kappa(y_i,y_j)$；$\boldsymbol{H}$为单位矩阵。当自变量$X$、$Y$独立，即$P(X,Y)=P(X)P(Y)$时，$HS=0$。

理论上，HSIC准则可以发现任意变量间的依赖关系，但在实际应用中，由于HSIC使用的核函数为高斯函数，通常涉及尺度参数σ的选择。σ的大小决定了高斯核变化的敏感度，即σ越大，同样距离下高斯核函数的结果越大。实际应用中，如果尺度参数选择过小，会使任意数据映射到Hilbert空间后线性可分，进而导致过拟合；如果尺度参数σ选择过大，会使数据映射到一个低维空间，进而导致欠拟合。因此，对于有限数据，HSIC更强调尺度参数σ的选择[28]。在网络训练过程中，样本数据来自两个分布不同的域，且随批次的不同而不同，因此尺度参数σ需要动态变化。本文依据每批次的样本数据的方差选择尺度参数σ。

2.2 损失函数

将相似性度量引入到目标函数中，则本文的目标函数由式(1)得到：

$$f^*=\arg\min_{f\in\mathcal{H}}\frac{1}{N_{\mathrm{s}}}\sum_{i=1}^{N_{\mathrm{s}}}\ell\left(f\left(x_i\right),y_i\right)+\lambda D\left(\mathcal{D}_{\mathrm{S}},\mathcal{D}_{\mathrm{T}}\right) \tag{6}$$

式中：N_{s}为源域样本数；$\left(x_i,y_i\right)$为有标签的源域样本；λ为迁移损失权重；$D(\cdot,\cdot)$为源域和目标域的分布距离度量函数。

ICUDA采用多分类交叉熵损失函数进行分类损失的衡量，即

$$\ell_{\mathrm{c}}=\frac{1}{N}\sum_{i}^{N}\ell_i=-\frac{1}{N}\sum_{i}^{N}\sum_{c=1}^{M}y_{ic}\log\left(p_{ic}\right) \tag{7}$$

式中：N为每个批次的样本数量；M为类别数；y_{ic}为第i个数据样本属于类别c的标签指示量；$p_{ic}=\mathrm{Soft\,max}\left(\hat{y}_{ic}\right)$为第$i$个数据样本属于类别$c$的预测概率，$\hat{y}_{ic}$为第$i$个样本经过特征提取器和分类器后的预测输出。

基于希尔伯特–施密特独立性准则构造的跨域样本分布距离度量函数为：

$$\ell_{\mathrm{HSIC}}=\exp\left(-\beta\cdot HS\right)=\exp\left(-\beta(m-1)^{-2}\mathrm{tr}(\kappa_X\boldsymbol{H}\kappa_Y\boldsymbol{H})\right) \tag{8}$$

式中β为超参数。

则式(6)的最终形式为：

$$\begin{cases}f^*=\arg\min_{f\in\mathcal{H}}\dfrac{1}{N_{\mathrm{s}}}\sum_{i=1}^{N_{\mathrm{s}}}\sum_{c=1}^{M}y_{ic}\log\left(p_{ic}\right)+\lambda\exp\left(-\beta(m-1)^{-2}\mathrm{tr}(\kappa_X\boldsymbol{H}\kappa_Y\boldsymbol{H})\right)\\ \text{s.t.}\quad \boldsymbol{H}=\boldsymbol{I}_m-\dfrac{1}{m}\boldsymbol{I}_m\boldsymbol{I}_m^{\mathrm{T}}\in\mathbb{R}^{m\times m}\end{cases} \tag{9}$$

ICUDA方法的更新算法如下所示。当网络通过训练获得最优参数时，ICUDA可学习具有良好类间分离性和域不变性的特征。

算法 ICUDA的更新算法

输入：源域训练数据 $\mathcal{D}_{\mathrm{s}}=\left\{x_i,y_i\right\}_{i=1}^{N_{\mathrm{s}}}$；目标域训练数据 $\mathcal{D}_{\mathrm{T}}=\left\{x_j\right\}_{j=1}^{N_{\mathrm{t}}}$；目标域测试数据 $\mathcal{D}_{\mathrm{T,t}}=\left\{x_j,y_j\right\}_{j=1}^{N_{\mathrm{T,t}}}$

1) 设置 $stop=0,best\_A_{\mathrm{accuracy}}=0$；

2) 循环

3) for i=1:1:batch

4) 利用特征提取器 G_{f} 分别获得源域和目标域的训练数据的浅层特征 $\boldsymbol{g}_{\mathrm{S}}$、$\boldsymbol{g}_{\mathrm{T}}$；

5) 利用分类器 G_{y} 获得源域深度特征 $\boldsymbol{G}_{\mathrm{s}}$ 和预测标签 $\hat{y}_{ic}=G_{\mathrm{y}}\left(\boldsymbol{G}_{\mathrm{s}};\theta_{\mathrm{y}}\right)$；

6) 利用分类器 G_{y} 获得目标域训练数据的深度特征 $\boldsymbol{G}_{\mathrm{T}}$；

8) 根据式(7)计算源域的分类损失 ℓ_{c}；

9) 根据式(8)计算源域和目标域间的分布差异 ℓ_{HSIC}；

10) 根据式(9)计算总的损失 ℓ；

11) 计算梯度信息并更新特征提取器和分类器的参数；

12) end for

13) 利用目标域测试数据 $\mathcal{D}_{\mathrm{T,t}}$ 计算识别准确率(其中T_{P}、T_{N}、F_{N}、F_{P}分别为真正例、真负例、假负例、假正例)：

$$A_{\mathrm{accuracy}}=\frac{T_{\mathrm{P}}+T_{\mathrm{N}}}{T_{\mathrm{P}}+F_{\mathrm{N}}+F_{\mathrm{P}}+T_{\mathrm{N}}}\times 100\%$$

14) 如果 $A_{\mathrm{accuracy}}\leqslant best\_A_{\mathrm{accuracy}}$，则 $stop++1$；否则 $best\_A_{\mathrm{accuracy}}=A_{\mathrm{accuracy}},stop=0$；

15) 如果 $stop>early\_stop$，则算法收敛，输出此时最高准确率为 $best\_A_{\mathrm{accuracy}}$；

16) 否则，算法未收敛，更新迭代次数 $e=e+1$；

17)直到收敛。

3 仿真实验

3.1 数据集介绍

本文采用实验室环境下采集的软件定义无线电(Software-Defined Radio，SDR)信号进行实验，发射端共有20台PLUTO SDR设备，接收端与发射端相距2 m。SDR信号载波频率为926 MHz，信号带宽为6.48 MHz。SDR数据集包含20个不同类别的I/Q信号，共9 638条信号样本。为了模拟实际环境中存在的不同噪声干扰，分别向数据集中加入了高斯白噪声以获得有噪信号。

3.2 仿真结果与分析

ICUDA模型采用Pytorch开源框架，仿真实验在一台搭载12th Gen Inter(R) Core(TM) i7-12700H处理器、NVIDIA RTX 3070 Ti显卡的电脑上进行。ICUDA方法训练epoch为100次，在训练过程中初始学习率设置为0.01，每批次大小为128，β设置为10，λ设置为1。实验设置早停机制以防止过拟合，早停轮次为30个epoch。

仿真实验中，首先验证ICUDA的分类性能，并与基线、DAN[25]、无监督领域自适应方法(Domain-Adversarial Neural Networks，DANN)[29]、多表示迁移网络(Multi-Representation Adaptation Network，MRAN)[30]的性能进行比较。其中，基线方法是指在源域数据集上已完成训练的网络直接迁移到目标域数据集上的方法；其次，比较了HSIC、MMD、CORAL、HoMM四种不同的数据分布距离度量函数对网络分类性能的影响。

3.2.1 ICUDA网络的分类性能

实验将数据集划分为训练集和测试集，训练集包含8 567条数据，测试集包含1 071条数据。高信噪比信号的数据集为源域数据集。实验共设置7个不同信噪比的源域数据集，其信噪比分别为8 dB、10 dB、12 dB、14 dB、16 dB、18 dB和20 dB，均为有标记数据集；目标域数据集的信噪比为0 dB，为无标记数据集。实验设置7个迁移的场景：7个源域数据集分别向目标域数据集迁移。表1展示了不同方法在7种迁移场景下的识别准确率。基线网络在有标签的7个有噪源域数据集上的识别准确率均高于91%，但在无标签的0 dB目标域数据集上的平均准确率仅有5.56%，性能大幅下降，表明不同信噪比下网络性能会出现较大起伏。其原因是相同的辐射源个体在不同信噪比下的信号存在显著差异。由表1可知，7种迁移场景下，与基线方法相比，ICUDA在目标域

数据集上的平均识别准确率为84.2%，比基线方法提高了78.64个百分点，比次优的MRAN方法提高了11.83个百分点。每种迁移场景下，ICUDA的识别准确率均在79%以上，甚至在8 dB源域向目标域的迁移场景下准确率为92.06%，相比于比较的其他迁移方法，ICUDA的迁移效果更好，也更稳定。本文所采用的网络可以挖掘出跨域样本间的相似性，将知识从源域迁移到目标域，从而在目标域仅含无标记样本的情况下提高辐射源个体的识别准确性。

表1 不同迁移场景下的目标域识别准确率(单位：%)

Table1 Target domain recognition accuracy under different transfer scenarios(unit:%)

method	20 dB→0 dB	18 dB→0 dB	16 dB→0 dB	14 dB→0 dB	12 dB→0 dB	10 dB→0 dB	8 dB→0 dB	average
baseline	4.67	6.16	6.72	4.10	4.11	5.60	7.38	5.56
DAN	26.05	22.78	23.34	25.49	23.9	24.46	25.86	24.55
DANN	58.82	59.29	56.86	55.46	53.31	61.72	60.04	57.93
MRAN	74.98	80.11	64.43	68.16	76.6	70.12	72.18	72.37
ICUDA	**80.47**	**80.58**	**79.93**	**80.27**	**87.21**	**88.89**	**92.06**	**84.20**

图2展示了不同迁移场景下ICUDA方法的混淆矩阵，从图中可以看出，部分子类别的识别准确率较高，可以达到95%以上；部分子类别的识别准确率较低，存在子类别间的混淆，但整体识别准确率仍可达到80%。这表明本文所提方法能够从源域获得具有较好类间可分离性的通用特征，帮助目标域提高模型性能。此外，部分子类别在两域间信噪比相距较小时的识别准确性高，而在相距较大时识别准确性低，说明其对不同域间的相似性更敏感。随着源域信噪比的降低，ICUDA的识别准确率均呈现上升趋势。信噪比相差越小的两域之间的相似性越大。相似性越强的数据集之间的可迁移性越好，源域中的知识越能帮助目标域模型性能的提升。

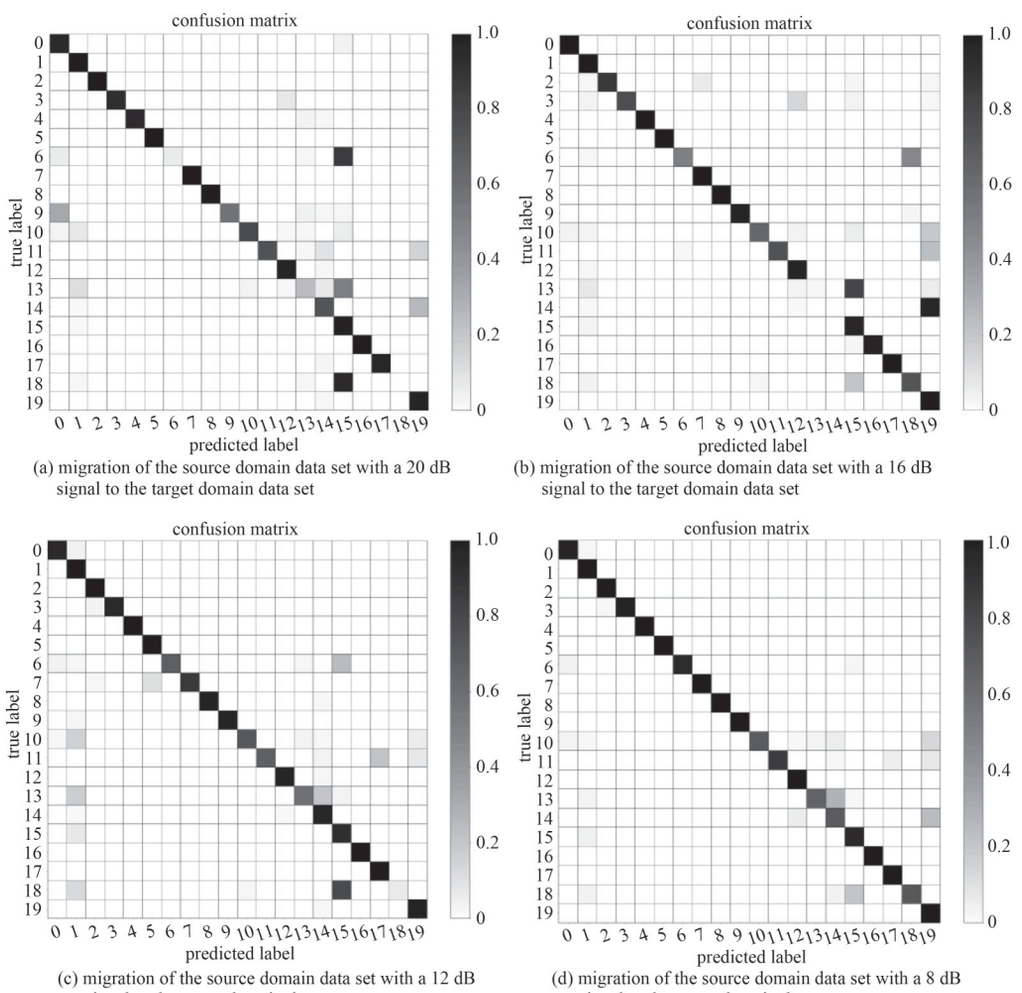

(a) migration of the source domain data set with a 20 dB signal to the target domain data set

(b) migration of the source domain data set with a 16 dB signal to the target domain data set

(c) migration of the source domain data set with a 12 dB signal to the target domain data set

(d) migration of the source domain data set with a 8 dB signal to the target domain data set

Fig.2 Confusion matrix of the target domain in ICUDA under four transfer scenarios

图2 ICUDA在4种迁移场景下目标域的混淆矩阵

利用t–分布随机邻域嵌入(t–distributed Stochastic Neighbor Embedding，t–SNE)对8 dB源域向目标域迁移场景下的4种无监督域适应方法所提取的特征进行降维，并将二维特征显示在图3中。其中，DANN和DAN方法的所有特征都被合并，使各个类别之间决策边界的形成变得复杂，从而损害了模型的分类性能。MRAN能明确部分子类的决策边界，但其他类别特征仍存在较高相似性。ICUDA学习到的特征空间证明，该方法可以借助源域，学习到类间可分离性明确、类内聚集性良好的特征，明确各类别之间的决策边界，提高模型的分类性能。

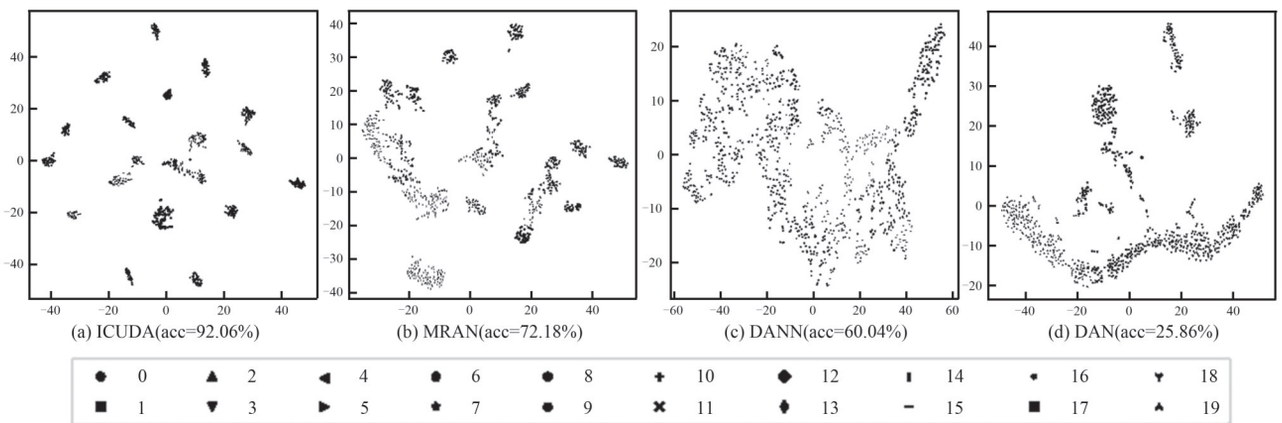

Fig.3 Display of target domain features of different unsupervised domain adaptation methods in an 8 dB source to target domain transfer scenario

图3 8 dB源域向目标域迁移场景下不同无监督域适应方法的目标域特征显示

3.2.2 消融实验

1) 相似性度量函数对目标域分类性能的影响

在本实验中，仅改变所提网络相似性度量中的度量函数，探究不同分布距离度量函数对模型分类性能的影响。实验比较了HSIC、MMD、CORAL和HoMM四种距离度量函数对目标域模型分类性能的影响，结果如图4所示。在仅改变相似性度量函数的情况下，在不同的迁移场景中，本文所采用距离度量函数HSIC获得了最好的分类性能。这表明，相比于其他度量方法，HSIC能更好地衡量不同域间样本的相似性，帮助学习两域之间的相似性特征，将知识从源域迁移至目标域，提高模型的分类性能。

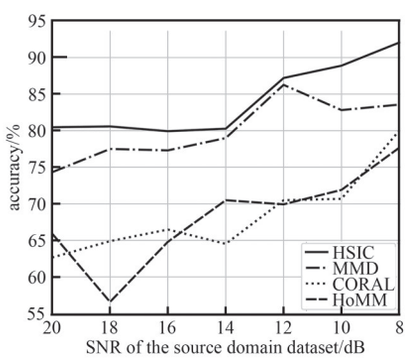

Fig.4 Accuracy curves for the target domain under different transfer scenarios

图4 不同迁移场景下的目标域的准确率曲线

2) 注意力机制目标域分类性能的影响

本实验通过是否添加注意力机制模块探究其对目标域分类性能的影响，实验结果如表2所示。ICUDA方法在平均分类性能上比未添加卷积块注意力模块(Convolutional Block Attention Module，CBAM)(w/o CBMA)提高2.15个百分点。对比不同的迁移场景，CBAM在源域和目标域的信噪比相差更小的场景下对分类性能的提升更明显。这表明在两域样本间相似性不明显的场景下，相似性度量函数HSIC对模型性能的提升占主导地位，充分挖掘不同域间样本相似性更能帮助知识从源域迁移到目标域。而在两域样本间相似性较明显的场景下，注意力机制CBAM辅助HSIC帮助知识更好地从源域迁移到目标域以提升模型的分类性能。

表2 不同迁移场景下是否添加注意力机制模块的目标域识别准确率(单位:%)

Table2 Target domain recognition accuracy of whether to add attention mechanism module under different transfer scenarios(unit:%)

method	20 dB→0 dB	18 dB→0 dB	16 dB→0 dB	14 dB→0 dB	12 dB→0 dB	10 dB→0 dB	8 dB→0 dB	average
ICUDA	80.47	80.58	79.93	80.27	87.21	88.89	92.06	84.20
w/o CBMA	79.83	79.93	77.96	80.86	84.78	83.94	87.02	82.05

4 结论

本文提出了基于独立性准则的域适应(ICUDA)方法用以实现无监督域适应，并在实验室环境中采集的SDR数据集上进行了实验验证。在7种迁移场景中，ICUDA在目标域数据集上的平均识别准确率为84.2%，比基线方法提高了78.64个百分点，比次优的MRAN方法提高了11.83个百分点，提高了无监督目标域辐射源个体识别的准

确性。但本文仅考虑了相同类别下的迁移，忽略了类别数不同的潜在影响。在未来工作中，将重点研究相关方面，不断优化迁移方法，以解决异构场景下的SEI识别问题。

参考文献：

[1] LIN Yun,TU Ya,DOU Zheng,et al. Contour stella image and deep learning for signal recognition in the physical layer[J]. IEEE Transactions on Cognitive Communications and Networking, 2021,7(1):34-46. DOI:10.1109/TCCN.2020.3024610.

[2] SHI Jibo,ZHANG Han,WANG Sen,et al. FEDRFID:federated learning for radio frequency fingerprint identification of WIFI signals[C]// GLOBECOM 2022-2022 IEEE Global Communications Conference. Rio de Janeiro,Brazil:IEEE, 2022:154-159. DOI:10.1109/GLOBECOM48099.2022.10001439.

[3] ZHANG Yibin,ZHANG Qianyun,ZHAO Haitao,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. DOI:10.1109/TIFS.2024.3353594.

[4] WANG Meiyu, LIN Yun, JIANG Hang, et al. TESPDA-SEI: tensor embedding substructure preserving domain adaptation for specific emitter identification[J]. Physical Communication, 2023(57):101973.

[5] 王艺卉,闫文君,徐从安,等. 面向ADS-B信号辐射源个体识别的轻量化模型设计[J]. 太赫兹科学与电子信息学报, 2023,21(9):1100-1108. (WANG Yihui,YAN Wenjun,XU Congan,et al. Design of lightweight model for specific emitter identification of ADS-B signal[J]. Journal of Terahertz Science and Electronic Information Technology, 2023,21(9):1100-1108.) DOI:10.11805/TKYDA2023077.

[6] LIAO Yilin,LI Haozhe,CAO Yizhi,et al. Fast Fourier transform with multihead attention for specific emitter identification[J]. IEEE Transactions on Instrumentation and Measurement, 2024(73):1-12. DOI:10.1109/TIM.2023.3338706.

[7] PENG Linning, ZHANG Junqing, LIU Ming, et al. Deep learning based RF fingerprint identification using differential constellation trace figure[J]. IEEE Transactions on Vehicular Technology, 2020, 69(1): 1091-1095. DOI: 10.1109/TVT. 2019. 2950670.

[8] TAMURA H, YANAGISAWA K, SHIRANE A, et al. Wireless devices identification with light-weight convolutional neural network operating on quadrant IQ transition image[C]// 2020 the 18th IEEE International New Circuits and Systems Conference (NEWCAS). Montreal,QC,Canada:IEEE, 2020:106-109. DOI:10.1109/NEWCAS49341.2020.9159777.

[9] LIN Yun, WANG Meiyu, ZHOU Xianglong, et al. Dynamic spectrum interaction of UAV flight formation communication with priority:a deep reinforcement learning approach[J]. IEEE Transactions on Cognitive Communications and Networking, 2020,6(3):892-903. DOI:10.1109/TCCN.2020.2973376.

[10] LIN Yun,ZHAO Haojun,MA Xuefei,et al. Adversarial attacks in modulation recognition with convolutional neural networks[J]. IEEE Transactions on Reliability, 2021,70(1):389-401. DOI:10.1109/TR.2020.3032744.

[11] TU Ya,LIN Yun,HOU Changbo,et al. Complex-Valued networks for automatic modulation classification[J]. IEEE Transactions on Vehicular Technology, 2020,69(9):10085-10089. DOI:10.1109/TVT.2020.3005707.

[12] TU Ya,LIN Yun,WANG Jin,et al. Semi-supervised learning with generative adversarial networks on digital signal modulation classification[J]. Computers, Materials & Continua, 2018,55(2):243-254. DOI:10.3970/cmc.2018.01755.

[13] LIN Yun,TU Ya,DOU Zheng. An improved neural network pruning technology for automatic modulation classification in edge devices[J]. IEEE Transactions on Vehicular Technology, 2020,69(5):5703-5706. DOI:10.1109/TVT.2020.2983143.

[14] SUN B C, SAENKO K. Deep CORAL: correlation alignment for deep domain adaptation[C]// Computer Vision-ECCV 2016 Workshops. Cham:Springer, 2016:443-450. DOI:10.1007/978-3-319-49409-8_35.

[15] CHEN Chao,FU Zhihang,CHEN Zhihong,et al. HOMM:higher-order moment matching for unsupervised domain adaptation[C]// Proceedings of the AAAI conference on artificial intelligence. Menlo Park,CA:AAAI, 2020:3422-3429.

[16] 孙俏,凌卫新. 基于域间相似度序数的迁移学习源领域的选择[J]. 科学技术与工程, 2020,20(20):8245-8251. (SUN Qiao, LING Weixin. Source domain selection in transfer learning based on domain similarity rank[J]. Science Technology and Engineering, 2020,20(20):8245-8251.)

[17] 胡振威,汪廷华,周慧颖. 基于核统计独立性准则的特征选择研究综述[J]. 计算机工程与应用, 2022,58(22):54-64. (HU Zhenwei,WANG Tinghua,ZHOU Huiying. Review of feature selection methods based on kernel statistical independence criteria[J]. Computer Engineering and Applications, 2022,58(22):54-64.) DOI:10.3778/j.issn.1002-8331.2203-0527.

[18] PENG Yinan,ZHOU Yuan. Specific emitter identification via squeeze-and-excitation neural network in frequency domain[C]// 2021 the 40th Chinese Control Conference(CCC). Shanghai, China: IEEE, 2021: 8310-8314. DOI: 10.23919/CCC52363.2021.9549470.

[19] AGADAKOS I, AGADAKOS N, POLAKIS J, et al. Chameleons' oblivion: complex-valued deep neural networks for protocol-Agnostic RF device fingerprinting[C]// 2020 IEEE European Symposium on Security and Privacy(EuroS&P). Genoa, Italy: IEEE, 2020:322-338. DOI:10.1109/EuroSP48549.2020.00028.

[20] DU Mingyang, HE Xikai, CAI Xiaohao, et al. Balanced neural architecture search and its application in specific emitter identification[J]. IEEE Transactions on Signal Processing, 2021(69):5051-5065. DOI:10.1109/TSP.2021.3107633.

[21] WANG Meiyu, LIN Yun, LIU Chang, et al. TESPOSDA-SEI: tensor embedding substructure preserving open set domain adaptation for specific emitter identification[J]. Wireless Networks, 2023,29(7):2935-2951. DOI:10.1007/s11276-023-03317-5.

[22] WANG Meiyu, LIN Yun, TIAN Qiao, et al. Transfer learning promotes 6G wireless communications: recent advances and future challenges[J]. IEEE Transactions on Reliability, 2021,70(2):790-807. DOI:10.1109/TR.2021.3062045.

[23] ZHANG Yinghua, ZHANG Yu, YANG Qiang. Parameter transfer unit for deep neural networks[C]// Advances in Knowledge Discovery and Data Mining. Macau, China: Springer International Publishing, 2019: 82-95. DOI: 10.1007/978-3-030-16145-3_7.

[24] LUO Yong, WEN Yonggang, LIU Tongliang, et al. Transferring knowledge fragments for learning distance metric from a heterogeneous domain[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 41(4): 1013-1026. DOI: 10.1109/TPAMI.2018.2824309.

[25] LONG Mingsheng, CAO Yue, CAO Zhangjie, et al. Transferable representation learning with deep adaptation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019,41(12):3071-3085. DOI:10.1109/TPAMI.2018.2868685.

[26] ZHU Yongchun, ZHUANG Fuzhen, WANG Jindong, et al. Deep subdomain adaptation network for image classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021,32(4):1713-1722. DOI:10.1109/TNNLS.2020.2988928.

[27] PENG Meixin, LI Zhanshan, JUAN Xin. Similarity-based domain adaptation network[J]. Neurocomputing, 2022(493): 462-473. DOI:10.1016/j.neucom.2021.12.089.

[28] MA W D K, LEWIS J P, KLEIJN W B. The HSIC bottleneck: deep learning without back-propagation[C]// Proceedings of the AAAI conference on artificial intelligence. Menlo Park, CA: AAAI, 2020:5085-5092. DOI:10.1609/aaai.v34i04.5950.

[29] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks[J]. Journal of Machine Learning Research, 2016,17(1):2030-2096. DOI:10.5555/2946645.2946704.

[30] ZHU Yongchun, ZHUANG Fuzhen, WANG Jindong, et al. Multi-representation adaptation network for cross-domain image classification[J]. Neural Networks: the Official Journal of the International Neural Network Society, 2019(119): 214-221. DOI: 10.1016/j.neunet.2019.07.010.

作者简介：

吴　琼(1997-)，女，在读硕士研究生，主要研究方向为迁移学习、辐射源个体识别. email: wuqiong2016@hrbeu.edu.cn.

史继博(1997-)，男，在读博士研究生，主要研究方向为联邦学习、信号识别、资源管理.

查浩然(1996-)，男，在读博士研究生，主要研究方向为信号处理与模式识别.

李志刚(1979-)，男，博士，副教授，主要研究方向为宽带信号检测、处理与识别.

王　谦(2000-)，男，在读硕士研究生，主要研究方向为数字信号处理、信号识别.