

## 基于熵值过滤和类质心优化的无监督域适应

田青, 卢章虎, 杨宏

引用本文

田青, 卢章虎, 杨宏. 基于熵值过滤和类质心优化的无监督域适应[J]. 计算机科学, 2024, 51(7): 345-353.

TIAN Qing, LU Zhanghu, YANG Hong. [Unsupervised Domain Adaptation Based on Entropy Filtering and Class Centroid Optimization](#) [J]. Computer Science, 2024, 51(7): 345-353.

---

## 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)

### [融入多影响力与偏好的图对比学习社交推荐算法](#)

Graph Contrastive Learning Incorporating Multi-influence and Preference for Social Recommendation  
计算机科学, 2024, 51(7): 146-155. <https://doi.org/10.11896/jsjcx.230400147>

### [基于时频融合特征的肺动脉高压心音分类模型](#)

Classification Model of Heart Sounds in Pulmonary Hypertension Based on Time-Frequency Fusion Features  
计算机科学, 2024, 51(6A): 230800091-7. <https://doi.org/10.11896/jsjcx.230800091>

### [基于跨语言迁移学习及联合训练的泰语语音合成](#)

Thai Speech Synthesis Based on Cross-language Transfer Learning and Joint Training  
计算机科学, 2024, 51(6A): 230500174-7. <https://doi.org/10.11896/jsjcx.230500174>

### [DRSTN:深度残差软阈值化网络](#)

DRSTN:Deep Residual Soft Thresholding Network  
计算机科学, 2024, 51(6A): 230400112-7. <https://doi.org/10.11896/jsjcx.230400112>

### [基于句信息增强词信息的方面级情感分类](#)

Aspect-based Sentiment Classification for Word Information Enhancement Based on Sentence Information  
计算机科学, 2024, 51(6): 299-308. <https://doi.org/10.11896/jsjcx.230600059>

# 基于熵值过滤和类质心优化的无监督域适应

田青<sup>1,3,4</sup> 卢章虎<sup>2</sup> 杨宏<sup>2</sup>

1 南京信息工程大学软件学院 南京 210044

2 南京信息工程大学计算机学院、网络空间安全学院 南京 210044

3 南京信息工程大学数字取证教育部工程研究中心 南京 210044

4 南京大学计算机软件新技术国家重点实验室 南京 210023

**摘要** 无监督域适应作为机器学习领域的新兴研究方向之一,其主要利用源域监督信息来辅助无标记目标域的学习。截至目前,已有较多无监督域适应方法被提出,但在关系挖掘方面仍存在一些不足之处。具体来说,现有方法通常对目标域样本采取一致性处理策略,而忽略了目标域样本在关系挖掘中的差异性,因此文中提出了熵值过滤和类质心优化方法。所提方法利用生成对抗网络架构对目标域样本进行标记,利用所获伪标签计算样本熵值,并与所设阈值进行比较,从而进一步划分目标域样本。对于简单样本,分配伪标签;对于困难样本,该方法结合对比学习思想,利用源域和简单本来学习更加鲁棒的分类器对困难样本分类,并进一步获得源和目标域的类质心。通过优化域间和实例对比对齐,来减小域间和域内的差异。最后,在3个标准数据集上与目前几种先进的领域自适应方法进行了对比实验,实验结果表明所提方法的性能均优于对比方法。

**关键词:** 迁移学习;无监督域适应;对抗学习;对比学习;类质心优化

中图分类号 TP181

## Unsupervised Domain Adaptation Based on Entropy Filtering and Class Centroid Optimization

TIAN Qing<sup>1,3,4</sup>, LU Zhanghu<sup>2</sup> and YANG Hong<sup>2</sup>

1 School of Software, Nanjing University of Information Science and Technology, Nanjing 210044, China

2 School of Computer Science, Nanjing University of Information Science and Technology, Nanjing 210044, China

3 Engineering Research Center of Digital Forensics, Ministry of Education, Nanjing University of Information Science and Technology, Nanjing 210044, China

4 State Key Laboratory for Novel Software Technology, Nanjing University, Nanjing 210023, China

**Abstract** As one of the emerging research directions in the field of machine learning, unsupervised domain adaptation mainly uses source domain supervision information to assist the learning of unlabeled target domains. Recently, many unsupervised domain adaptation methods have been proposed, but there are still some deficiencies in relation mining. Specifically, existing methods usually adopt a consistent processing strategy for target domain samples, while ignoring the discrepancy in target domain samples in relation mining. Therefore, this paper proposes a novel method called entropy filtering and class centroid optimization (EFCO). The proposed method utilizes a generative adversarial network architecture to label target domain samples. With the obtained pseudo-labels, the sample entropy value is calculated and compared with a predefined threshold to further categorize target domain samples. Simple samples are assigned pseudo-labels, while difficult samples are classified using the idea of contrastive learning. By combining source domain data and simple samples, a more robust classifier is learned to classify difficult samples, and class centroids of the source and target domains are obtained. Inter-domain and intra-domain discrepancies are minimized by optimizing inter-domain contrastive alignment and instance contrastive alignment. Finally, it is compared with several advanced domain adaptation methods on three standard data sets, and the results indicate that the performance of the proposed method outperforms the comparison methods.

**Keywords** Transfer learning, Unsupervised domain adaptation, Adversarial learning, Contrastive learning, Class centroid optimization

到稿日期:2023-05-22 返修日期:2023-10-25

基金项目:国家自然科学基金(62176128);南京大学计算机软件新技术国家重点实验室开放课题(KFKT2022B06);中央高校基本科研基金(NJ2022028);江苏省“青蓝工程”人才计划项目

This work was supported by the National Natural Science Foundation of China(62176128), Open Projects Program of State Key Laboratory for Novel Software Technology of Nanjing University(KFKT2022B06), Fundamental Research Funds for the Central Universities(NJ2022028) and Qing-Lan Project of Jiangsu Province of China.

通信作者:田青(tianqing@nuist.edu.cn)

## 1 引言

无监督域适应方法(Unsupervised Domain Adaptation, UDA)尝试将知识从标签丰富的源域转移到未标记的目标域<sup>[1-8]</sup>。许多现有域自适应方法<sup>[1,4-5]</sup>在不考虑样本类别的情况下将源域与目标域样本进行特征分布对齐。但这些样本中与分类任务无关的方法在对齐全局分布时无法生成有效的判别特征。最近,由于对比学习<sup>[9-10]</sup>在自我表征学习中的成功,一些最新的研究<sup>[11]</sup>已经转向基于实例的对比学习来减小跨域的差异。从具体实例来看,如图1所示,一些目标域样本与源域样本有许多相似因素,而有些目标域样本则与源域样本差异过大。为了描述的简单,将其分别称为分类简单样本和分类困难样本。以前的一些研究工作明确针对源域和目标域间的数据分布对齐,以此来挖掘域间的最相似特征。因此,在面对分类简单样本时模型表现较好。然而,由于分类困难样本和源域样本相似度较大,因此模型在处理分类困难样本时表现不佳。



图1 困难和简单样本的划分

Fig.1 Division of difficult and easy samples

为缓解上述难点,本文提出了一种基于熵值过滤和类质心优化的无监督域适应方法(Entropy Filtering and Class Centroid Optimization, EFCO),用于缓解目标域困难样本难以分类的问题。具体而言,EFCO首先依据目标域样本的熵值来对目标域样本进行区分,将熵值小于阈值的样本定义为分类简单样本,将熵值大于阈值的样本定义为分类困难样本。其次,对于划分为分类简单样本的目标域样本,采用源域训练好的分类器为其分配伪标签。最后,本文借鉴对比学习的思想来处理划分为分类困难的目标域样本,通过源域标签和目标域简单样本的标签来训练得到更加鲁棒的分类器,计算源域和目标域类中心,分别优化域间对比对齐和实例对比对齐,以减小域间和域内的差异。

首先域间对比对齐减小了源域和目标域中同一类质心之间的差异,同时增大了源域和目标域中不同类质心之间的距离。这确保了来自这两个域的相同类的集群比来自这两个域的其他类的集群在潜在空间中彼此更加接近。其次,受半监督设置中自我表征学习成功的启发<sup>[12-14]</sup>,使用实例对比对齐来减小域内差异。最后,EFCO使用图像增强方法生成未标记目标图像的增广样本,将来自目标域的分类困难样本和其增广样本的特征对齐,确保它们在潜在空间中彼此更接近。同一样本的两个变体之间的对齐确保分类器边界位于低密度

区域。增广样本变体间的特征表示相似,这有助于为目标域样本更好地聚类。综上所述,本文的贡献如下:

1)提出了一种基于熵值过滤和类质心优化的无监督域适应(EFCO)方法。在EFCO中,通过信息熵将目标域样本划分为分类简单样本和分类困难样本,并反过来利用分类简单样本优化模型促进对分类困难样本的分类任务。

2)针对分类困难样本,在类质心和实例级别上使用对齐来减小UDA中存在的域间和域内的差异。

3)通过大量的对比和消融实验对本文提出的EFCO方法进行了多方面的评估,验证了EFCO方法的有效性和优越性。

本文第2章回顾了UDA的相关工作;第3章详细阐述了所提EFCO方法;第4章展示了实验设置并给出了相应的结果分析;最后总结全文。

## 2 相关工作

### 2.1 类级别迁移

类级别迁移对齐旨在减小条件分布的差异。移动语义传递网络<sup>[15]</sup>将已标记的源质心与伪标记的目标质心进行对齐,以学习域不变的语义表示。SimNet<sup>[16]</sup>和可转移原型网络<sup>[17]</sup>通过计算每个类别的实例表示之间的相似性来学习类别实例表示。CWDAN<sup>[18]</sup>使用MMD度量来最小化域间的类内距离,而对比自适应网络(Contrastive Adaptation Network, CAN)<sup>[11]</sup>则基于最大平均差异(Maximum Mean Difference, MMD)度量明确地建模了类内域差异和类间域差异。MA-DA<sup>[4]</sup>训练多个类级域鉴别器来捕获多模式结构,从而实现不同数据分布的细粒度对齐。类似地,GSDA<sup>[19]</sup>实现了分层域对齐,包括类、组级和全局对齐。WCEL<sup>[20]</sup>利用图嵌入理论设计了两个图来保留类间样本的判别信息和类内样本的邻域关系。虽然这种方法通过探索类级自适应显著提高了性能,但不足之处在于,许多类级对齐方法包含了目标伪标签,而伪标签的生成大多只依赖于源分类器。这里需要注意的是,伪标签是一把双刃剑,因为错误预测的目标标签会误导类级分布对齐,导致性能下降。

### 2.2 伪标签生成策略

在执行实例层面的对齐过程中,需要对目标域样本进行标记,即伪标签。最近的域适应方法通常使用目标域的伪标签来学习语义特征。文献<sup>[15,21-22]</sup>利用伪标签来估计用于匹配源类中心的目标类中心。CAN<sup>[11]</sup>利用目标伪标签来估计对比域差异。iCAN<sup>[23]</sup>根据预测的分类分数来选择数据,以设计一个强大的伪标签损失。在给目标域样本分配伪标签时有一个常见的问题,即错误的伪标签。在理想情况下,研究者希望标注的样本标签是样本的真实标签,这样才不会造成模型迭代训练时出现链式错误。目前的实验结果表明,伪标签错误是普遍存在的。为了缓解这个问题,Zhu等<sup>[24]</sup>使用在源域中训练的分类器直接对目标域样本进行标注;Deng等<sup>[25]</sup>使用聚类方法对具有相似特征的样本进行分类;Wang

等<sup>[26]</sup>采用质心法根据样本到质心的距离进行分配标签; Wang 等<sup>[27]</sup>通过阈值来控制伪标签的置信度,以减少标记错误; Morerio 等<sup>[28]</sup>使用条件生成对抗网络来消除域迁移中产生的噪声,提高标签的鲁棒性; Litrico 等<sup>[29]</sup>基于伪标签的可靠性对分类损失重新加权,通过聚合邻近样本的知识来逐步提高伪标签的准确性; Chu 等<sup>[30]</sup>采用强弱自训练范式来对伪标签样本进行去噪,以避免错误标签。这些方法在一定程度上减少了伪标签错误,但是伪标签的正确性对后续样本分布的正则化影响很大。因此,本文方法采取了更严格的标记策略,即采用信息熵来筛选目标样本标记,并通过自训练的方式来训练分类器,以提高伪标签的准确性。

### 2.3 对比学习

对比学习 (Contrastive Learning, CL) 在自我表征学习<sup>[9-10,12,31]</sup>中取得了较好的实验精度,其目的是学习一个嵌入空间,其中的正对被拉近,而负对被相互推开。正对是通过同一图像的增广表示进行配对来绘制的,而负对则是从不同的图像中绘制的。现有的对比学习方法利用不同的策略来生成正样本和负样本。在自监督学习方法<sup>[10,12]</sup>中,正对是通过创建每个样本的不同的增广视图而产生的,而负对可以从不同的样本中随机选择。通过自监督对比学习学习到的实例判别表示可以被很好地迁移到下游任务中。然而,如果没有特定于任务的语义信息,就不能通过实例级的对比学习来学习具有类内紧凑性和类间辨别能力的表征。最近,监督对比学习<sup>[32]</sup>利用类别标签来组成正对和负对,并在全监督图像分类上取得了很好的性能。Ge 等<sup>[33]</sup>提出了一个混合存储的自定

进度对比学习框架,用于在每个域中具有多级监督的域自适应对象重识别。特征对齐是领域适应方法的关键,但这些都对比学习方法未对其进行考虑。Thota 等<sup>[34]</sup>只是在每个域上独立地进行对比学习,并最小化 MMD 以减小域的差距,没有考虑域对齐和类对齐。在语义分割中, Liu 等<sup>[35]</sup>使用 patch-wise 对比学习,通过跨域对齐相似的 patch 来减少域分歧。在域适应中,对比学习<sup>[11]</sup>已被应用于实例级别的对齐以学习域不可知表示,其使用来自同一个类别的样本作为正对,而来自不同类别的样本被计算为负对。Kang 等<sup>[11]</sup>修改了最大平均差异 (MMD)<sup>[36]</sup>损失作为对比损失。Huang 等<sup>[37]</sup>利用源域和目标域的样本构建语义感知字典,进行类别对比学习,但其没有充分考虑拉近源域与目标域间的距离。与文献<sup>[11,37]</sup>相比,本文提出了在 UDA 设置的类和实例级别(跨同一图像的扰动样本)中使用对比学习,以更好地学习数据的语义信息。

### 3 基于熵值过滤和类质心优化的无监督域适应

本章详细介绍了本文方法的整体框架,其主要由两部分组成:用于简单样本的生成对抗网络 (Generative Adversarial Network, GAN) 和用于困难样本的对比网络。当一个测试样本进入网络时,它将首先由 GAN 网络进行分类。如果分类置信度高于一个软阈值,则返回该结果,否则它将由对比网络进行进一步处理。在训练阶段,也可以利用简单的样本来进行对比。下文将详细描述 GAN 网络和对比网络的细节。为了更好地理解本文方法的思路,EFCCO 模型架构如图 2 所示。

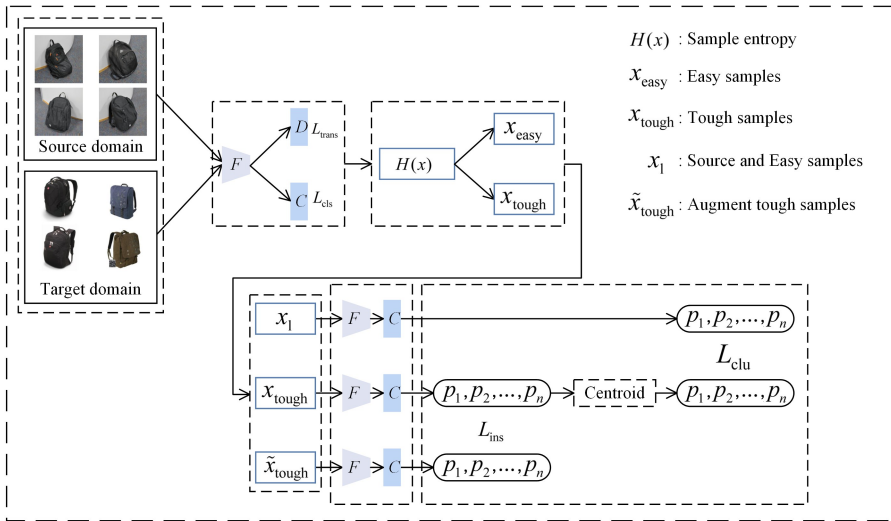


图2 EFCCO方法的整体架构

Fig. 2 Overall architecture of EFCCO

### 3.1 符号定义与问题假设

遵循常见的 UDA 场景设置,给定包含  $N_s$  个标记样本的源域  $\mathcal{D}_s = \{X_s, Y_s\} = \{x_s^i, y_s^i\}_{i=1}^{N_s}$ , 其中  $X_s \in \mathcal{X}_s, x_s^i \in \mathbb{R}^{d_s}, y_s^i \in \mathbb{R}^C$ , 以及包含  $N_t$  个未标记的目标域样本  $\mathcal{D}_T = \{X_T\} = \{x_t^i\}_{i=1}^{N_t}$ , 其中  $X_T \in \mathcal{X}_T, x_t^i \in \mathbb{R}^{d_T}$ , 其共享相同的标签空间  $Y = \{1, 2, \dots, K\}$ 。为了方便对模型进行详细描述,本文涉及的符号定义如表 1 所列。

表1 符号定义

Table 1 Symbol definition

Symbol	Definition	Symbol	Definition
$x_s^i, x_t^i$	源域/目标域样本	$x_{easy}, x_{tough}$	简单/困难样本
$N_s, N_t$	源域/目标域样本数	$y_{easy}, y_{tough}$	简单/困难样本伪标签
$y_s^i$	源域样本标签	$F$	特征生成器
$D$	域鉴别器	$C$	分类器
$K$	源域和目标域类数目	$H(\cdot)$	样本信息熵
$t$	当前迭代轮次	$T$	最大迭代轮次

### 3.2 生成对抗网络域适应框架

本文提出针对目标域简单样本和困难样本分别部署不同的处理策略。由于简单和困难是相对的概念,处理简单的样本也有助于模型识别困难的样本。在所提模型中,首先部署了一个通过源域样本训练的 GAN 网络来处理目标域样本;然后,分析 GAN 网络的输出,以确定目标域样本是否需要进一步的处理。

在无监督域自适应任务<sup>[38]</sup>中,有一个标记的源域和一个未标记的目标域。在具有监督分类损失的源域上训练一个深度模型,并对模型特定的层进行微调,以便将学习到的知识迁移到目标域。因此,GAN 网络的整体损失可以表示为:

$$L_{\text{GAN}} = L_{\text{cls}} + \lambda L_{\text{trans}} \quad (1)$$

其中,  $\lambda > 0$  是一个平衡参数,  $L_{\text{cls}}$  是源域上的监督损失,  $L_{\text{trans}}$  是用于迁移学习的对抗损失,采用交叉熵损失作为源域监督损失,即:

$$\min_{\theta_f, \theta_c} L_{\text{cls}}(\mathcal{Y}_S, \mathcal{Y}_S) = L_{\text{ce}}(C(F(x_i^s)), y_i^s) \quad (2)$$

其中,  $L_{\text{ce}}$  为标准交叉熵损失函数,  $\theta_f$  和  $\theta_c$  分别为特征生成器  $F$  和分类器  $C$  的参数。借鉴其他深度域自适应方法<sup>[2-3, 39]</sup>,本文采用了流行的对抗性训练方法,迁移损失可以表述为:

$$L_{\text{trans}} = -\frac{1}{N_s} \sum_{i=1}^{N_s} \log D(C(F(x_i^s))) - \frac{1}{N_t} \sum_{j=1}^{N_t} \log(1 - D(C(F(x_j^t)))) \quad (3)$$

其中,  $N_s$  和  $N_t$  分别代表源域和目标域的样本数量。

### 3.3 定义目标域困难样本

通过优化式(1),可以获得一个域适应网络,然后利用网络对目标域样本进行分类。然而,式(1)并没有考虑不同样本间的适应难度。本节利用式(1)训练的域适应网络计算样本分类置信度。如果一个样本有很高的置信度,则表示它是一个分类简单的样本并返回结果;否则,认为它是一个分类困难的样本,接下来对其进行进一步处理。定义  $\mathbf{p}$  是一个标签向量,它由域适应网络中的 Softmax 层计算的目标样本的所有可能的标签概率组成。通过学习熵的物理定义可知,熵越低,输出的置信度越高,因为熵越低,结果的确信性就越高。因此,本节将计算获得的目标域样本的熵与阈值  $\tau$  进行比较,如果熵低于阈值,则样本分类结束;否则,该目标域样本将被视为分类困难样本并转移到下一步进行学习。具体而言,可以将样本熵定义为:

$$H(x_i^t) = -\sum_{k=1}^K p_k \log p_k \quad (4)$$

其中,  $p_k$  为分类器输出类  $k$  的概率,  $K$  是源域和目标域类别数目。依据式(4)而言,目标域样本中的困难样本随着模型训练迭代向简单样本过渡。然而,针对目标样本的筛选方式是不安全的。对于这种利用信息熵来筛选目标样本的方式,如果简单样本筛选错误,这种错误的标记将随着模型迭代训练产生更糟糕的结果。因此,本文采用软阈值  $\tau$ ,而不是固定值来筛选目标域样本。具体来说,通过比率设置阈值,例如熵最低的 20% 样本被识别为简单样本。该比率可以通过对源域数据(或半监督域自适应中的目标域数据)的交叉验证来调整。由于源域和目标域在共享特征空间中对齐良好,因此在

源域上调整的比率对目标域也有效。利用式(4)对目标样本进行划分,具体方式如下:

$$\begin{cases} x_{\text{easy}} = H(x_i^t) < \tau, & j=1, 2, \dots, N_t \\ x_{\text{tough}} = H(x_j^t) > \tau, & j=1, 2, \dots, N_t \end{cases} \quad (5)$$

其中,  $\tau$  为所设置的阈值,  $N_t$  代表目标域的样本数量,  $N_{\text{easy}}$  和  $N_{\text{tough}}$  分别表示分类简单和困难的目标域样本。

### 3.4 困难样本分类

#### 3.4.1 监督训练

如果一个样本的熵值很低,则表示分类器对其分类的置信度很高,其很容易分类。容易分类也意味着对跨域适应没有分歧,而困难的样本在面对不同分类器时往往具有不同的分类结果。考虑到在 EFCO 模型中,简单样本的分类具有很高的置信度,假设模型对目标域简单样本有较高的标签置信度,则可以将其作为困难样本的分类参考。由于简单样本和困难样本来自同一个域,因此其具有相同的数据分布。如果充分利用目标域简单样本的标签信息,则可以理想化地将无监督域适应转化为半监督域适应。基于上述考虑, EFCO 将源域样本和简单样本合并构建为一个新的源域,新源域利用目标域的先验知识对模型进行训练,能够进一步拉近源域与目标域之间的域差异,从而提高模型的准确率。虽然伪标签带有一定的噪声会影响模型,但由于简单样本是通过阈值控制来筛选出的分类更为准确的目标域样本,因此将这种噪声降低至其可以接受的范围。新源域构建具体如下:

$$D_s^* = \{x_s \cup x_{\text{easy}}, y_s \cup y_{\text{easy}}\} = \{x_i^s, y_i^s\}_{i=1}^{N_s+N_{\text{easy}}} \quad (6)$$

其中,  $y_{\text{easy}}$  表示目标域简单样本伪标签,  $N_{\text{easy}}$  表示目标域简单样本数量。目标域简单样本通过源分类器分配伪标签,具体定义如下:

$$y_{\text{easy}}^i = \arg \max(C(F(x_{\text{easy}}^i))) \quad (7)$$

其中,  $C$  和  $F$  分别是源域训练的分类器和特征生成器的函数表示,  $x_{\text{easy}}^i$  表示分类为简单样本的目标域样本。依据式(6)重新划分的新源域,源域监督损失公式更新如下:

$$\min_{\theta_f, \theta_c} L_{\text{cls}}(\mathcal{Y}_t^*, \mathcal{Y}_t) = L_{\text{ce}}(C(F(x_i^t)), y_i^t) \quad (8)$$

#### 3.4.2 域间对比学习

不难发现,来自同一个类别的样本在跨域迁移的过程中必须聚集在共享特征空间中。但是,由于标签的可用性,这仅在源域中观察到。由于源域和目标域分布之间的域偏移影响,目标域的样本不会在迁移过程中形成集群。通过对齐源域和目标域每个类的质心,可以减小同一类别簇之间的差异。计算属于类  $k$  的源域样本的特征的平均值,源域质心的定义如下:

$$C_s^k = \frac{\sum_{i=1}^B \mathbf{1}_{\{y_i^s=k\}} C(F(x_i^s))}{\sum_{i=1}^B \mathbf{1}_{\{y_i^s=k\}}} \quad (9)$$

其中,  $B$  为每个训练批次的样本数量,  $\mathbf{1}_{\{y_i^s=k\}}$  表示判断  $y_i^s$  是否属于类  $k$ ,将每个类的源域质心存储在内存库  $C_s = [C_s^1, C_s^2, \dots, C_s^k]$  中,使用指数平均移动来更新这些源域质心值。具体表示如下:

$$C_s^k = s(C_s^k)_t + (1-s)(C_s^k)_{t-1} \quad (10)$$

其中,  $s$  表示一个动量项,  $(C_s^k)_t$  和  $(C_s^k)_{t-1}$  分别代表当前轮次和前一轮次中源域类  $k$  的质心。此外,为了进行域间对比对齐,还需要计算目标域样本类质心。如式(11)所示,将由新源域训练的分类器中获得的伪标签作为对应的未标记目标域困难样本的类标签。

$$y_{\text{tough}}^j = \arg \max(C(F(x_{\text{tough}}^j))) \quad (11)$$

与源域样本类似,通过式(9)计算目标域样本质心为  $C_t = [C_t^1, C_t^2, \dots, C_t^k]$ 。然后训练该模型以最大化来自源域和目标域中每个类  $k$  的聚类表示之间的相似性。 $C_s^k$  和  $C_t^k$  形成正对,而来自两个域的剩余簇质心形成负对。 $C_s^k$  和  $C_t^k$  两者被逐渐拉近,其余负对被推开。EFCO 通过改进的归一化温度尺度交叉熵(NT-Xent)对比损失<sup>[9,14,35]</sup>来实现域适应上的域间对比损失:

$$L_{\text{clu}}(C_s^i, C_t^j) = -\log \frac{h(C_s^i, C_t^j)}{h(C_s^i, C_t^j) + \sum_{r=1}^K \mathbf{1}_{\{r \neq i\}} h(C_s^i, C_r^j)} \quad (12)$$

其中,  $q \in \{s, t\}$ ,  $h(x, y) = \exp\left(\frac{x^T y}{\|x\|_2 \|y\|_2}\right) / \Omega$  是用来度量余弦相似度的指数,  $C_s^i$  是式(11)求得源域第  $i$  类的质心,  $C_t^j$  是目标域第  $j$  类的质心,  $C_r^j$  是将源域和目标域混合后求得第  $r$  类的质心,  $\Omega$  表示温度超参数。

### 3.4.3 实例对比对齐

最近关于对比学习的方法<sup>[9,12]</sup>在单域设置中显示出了较好的分类精度。为了在实例级别执行对比度对齐,本节首先生成目标域分类困难样本的增广样本,即  $\tilde{x}_{\text{tough}}^j = \Phi(x_{\text{tough}}^j)$ , 其中  $\Phi(\cdot)$  是增广函数。接下来,使用式(13)中定义的损失,来确保同一样本的这两个变体在潜在空间中彼此更接近,而同一批次的其他样本被推开。这一想法源于理想分类器中的聚类假设,该假设指出决策边界应位于低密度区域,以确保分类器对同一样本的不同增广变量的预测一致。

$$L_{\text{ins}}(\tilde{x}_{\text{tough}}^j, x_{\text{tough}}^j) = -\log \frac{h(C(F(\tilde{x}_{\text{tough}}^j)), C(F(x_{\text{tough}}^j)))}{\Gamma} \\ \Gamma = \sum_{i=1}^B h(C(F(\tilde{x}_{\text{tough}}^i)), C(F(x_{\text{tough}}^i))) + \sum_{i=1}^B \mathbf{1}_{\{i \neq j\}} h(C(F(\tilde{x}_{\text{tough}}^i)), C(F(x_{\text{tough}}^i))) \quad (13)$$

其中,  $\tilde{x}_{\text{tough}}^j$  是增广的目标域样本。EFCO 框架的域间对比度学习和实例对比度学习对于提高分类精度都是必需的。实例对比度对齐确保未标记的目标样本是一致的,并且处于高密度区域。但是,它不能确保源样本和未标记目标样本之间的对齐。域间对比度对齐减小了目标域困难样本和源域之间的差异,但靠近决策边界的目标域困难样本可能会被推向错误的类,从而导致负迁移。因此,结合这两个组件可以使目标域困难样本更好地向源域对齐,从而提升框架的性能。

### 3.5 总体目标函数

将上述监督损失项、域间对比对齐和实例对比对齐联合考虑,构建针对目标域困难样本分类的 EFCO 总体优化目标,具体表达式如下:

$$L_{\text{total}} = L_{\text{cls}} + \alpha L_{\text{clu}} + \beta L_{\text{ins}} \quad (14)$$

其中,  $\alpha$  和  $\beta$  是超参数。为了详细阐述 EFCO 模型的优化细节,算法 1 总结了 EFCO 的完整步骤。

#### 算法 1 EFCO 优化算法

输入:  $(X_S, X_T, Y_S, T, \alpha, \beta)$

输出:  $(C)$

1. 初始化  $\text{iter}=0$ ;
2. 通过优化式(1)训练域适应 GAN 网络;
3. 划分目标域困难样本,并返回目标域简单样本的伪标签;
4. repeat
5. 根据式(8)更新模型分类器  $C$ ;
6. 根据式(10)更新源域和目标域质心  $C_s, C_t$ ;
7. 根据式(12)计算域间对比损失  $L_{\text{clu}}$ ;
8. 根据式(13)计算实例对比损失  $L_{\text{ins}}$ ;
9. 根据式(14)更新模型参数;
10.  $\text{iter}=\text{iter}+1$ ;
11. until 迭代轮数  $> T$ .

## 4 实验与结果分析

本章在 3 个公开的基准数据集上用图像分类任务评估了所提的 EFCO 算法。首先,介绍了相关的数据集、实验设置以及对比方法。其次,对 EFCO 模型与其他相关方法的对比结果进行了分析,并进行了特征可视化及消融实验。最后,对所提算法的参数进行了交叉验证。

### 4.1 数据集及实验设置

#### 4.1.1 数据集

本文选择 MNIST<sup>[40]</sup>, USPS<sup>[41]</sup>, SVHN<sup>[42]</sup>, Office-31<sup>[43]</sup> 和 Office-Home<sup>[44]</sup> 等标准跨域数据集来验证所提 EFCO 方法的有效性。

#### 4.1.2 实验设置

为了充分验证本文方法的有效性,将其与以下几种域适应方法进行了比较: DANN<sup>[45]</sup>, ADDA<sup>[46]</sup>, CDAN<sup>[3]</sup>, DAN<sup>[47]</sup>, MCD<sup>[48]</sup>, DWL<sup>[49]</sup>, TAT<sup>[50]</sup>, JAN<sup>[51]</sup>, LDC<sup>[52]</sup>, GoGAN<sup>[53]</sup>, CyCADA<sup>[39]</sup>, CAT<sup>[25]</sup>, SAFN<sup>[54]</sup>, DSAN<sup>[24]</sup>, ETD<sup>[55]</sup>, CGDM<sup>[56]</sup>, CSDA<sup>[19]</sup>, SCAL<sup>[57]</sup>。根据 UDA 的标准协议,所有标记的源域样本和未标记的目标域样本都参与训练阶段。对于手写数字集上的域自适应任务,本节遵循 MCD<sup>[48]</sup> 中的实验设置。在实验过程中,使用学习率权重衰减为 0.0005 的 Adam 来优化网络权重参数,学习率设为 0.001,样本批量大小设为 256。将目标域样本的分类准确率作为实验的评估标准。对于图像分类任务数据集,使用 ResNet-50<sup>[58]</sup> 作为网络的基础架构,使用模型训练样本批量大小为 32,学习速率为 0.001,权重衰减为  $5 \times 10^{-4}$ ,动量为 0.9,通过随机梯度下降来优化目标函数。

### 4.2 实验结果及分析

本节进行了大量实验来评估所提模型的有效性,所有比较方法的结果均来自相关文献。在 3 个数据集上的实验结果如表 2—表 4 所列,其中最优的结果用粗体表示,次好的结果用下划线表示。通过对实验结果的理论分析,EFCO 在大多数任务中取得了最好的效果,其平均准确率优于经典的 UDA 方法,如 DAN 和 CDAN。

表2 EFCO框架在数字数据集上的准确率

Table 2 Accuracy of EFCO framework on digital dataset

Method	Accuracy (%)			
	M→U	U→M	S→M	Avg
ResNet-50	76.7	63.4	67.1	69.1
DAN	80.3	77.8	73.5	77.2
DANN	90.8	93.9	83.1	89.2
CDAN	93.9	96.9	88.5	93.1
CyCADA	95.6	96.5	90.4	94.2
CAT	90.6	80.9	<b>98.1</b>	89.9
MCD	94.2	94.1	96.2	94.8
ETD	96.4	96.3	<u>97.9</u>	<u>96.9</u>
DSAN	<b>96.9</b>	95.3	90.1	94.1
DWL	96.2	96.7	97.3	96.9
CGDM	96.0	<u>97.0</u>	97.6	96.8
Ours	<u>96.5</u>	<b>97.7</b>	97.6	<b>97.1</b>

表3 EFCO框架在Office-31数据集上的准确率

Table 3 Accuracy of EFCO framework on Office-31 dataset

Method	Accuracy (%)						
	A→W	D→W	W→D	A→D	D→A	W→A	Avg
ResNet-50	68.4	96.7	99.3	68.9	62.5	60.7	76.1
DAN	80.5	97.1	99.6	78.6	63.6	62.8	80.4
DANN	82	96.9	99.1	79.7	68.2	67.4	82.2
ADDA	86.3	96.3	98.5	77.9	69.6	68.9	82.9
CDAN	<u>93.1</u>	98	<b>100.0</b>	89.8	70.1	68.0	86.6
CAT	91.1	98.6	99.6	90.6	70.4	66.5	86.1
SAFN	88.8	98.4	99.8	87.7	69.8	69.7	85.7
ETD	92.1	<b>100.0</b>	<b>100.0</b>	88.0	71.0	67.8	86.2
DWL	87.2	99.1	99.6	86.3	71.5	69.8	85.5
CGDM	90.1	99.3	<b>100.0</b>	89.0	70.0	70.8	86.5
SCAL	<b>93.5</b>	98.5	<b>100.0</b>	<b>93.5</b>	<u>72.4</u>	<u>74.0</u>	<u>88.6</u>
Ours	<u>93.1</u>	<u>99.7</u>	<b>100.0</b>	<u>91.8</u>	<b>74.3</b>	<b>74.6</b>	<b>88.9</b>

表4 EFCO框架在Office-Home数据集上的准确率

Table 4 Accuracy of EFCO framework on Office-Home dataset

Method	Accuracy (%)												
	Ar→Cl	Ar→Pr	Ar→Rw	Cl→Ar	Cl→Pr	Cl→Rw	Pr→Ar	Pr→Cl	Pr→Rw	Rw→Ar	Rw→Cl	Rw→Pr	Avg
ResNet-50	34.9	50.0	58.0	37.4	41.9	46.2	38.5	31.2	60.4	53.9	41.2	59.9	46.1
DAN	43.6	57.0	67.9	45.8	56.5	60.4	44.0	43.6	67.7	63.1	51.5	74.3	56.3
DANN	45.6	59.3	70.1	47.0	58.5	60.9	46.1	43.7	68.5	63.2	51.8	76.8	57.6
JAN	45.9	61.2	68.9	50.4	59.7	61.0	45.8	43.4	70.3	63.9	52.4	76.8	58.3
CDAN+E	50.7	70.6	76.0	57.6	70.0	70.0	57.4	50.9	77.3	70.9	56.7	81.6	65.8
TAT	51.6	69.5	75.4	59.4	69.5	68.6	59.5	50.5	76.8	70.9	56.6	81.6	65.8
ETD	51.3	71.9	<b>85.7</b>	57.6	69.2	73.7	57.8	51.2	79.3	70.2	57.5	82.1	67.3
GSDA	<b>61.3</b>	<b>76.1</b>	<u>79.4</u>	<b>65.4</b>	<u>73.3</u>	<b>74.3</b>	<b>65.0</b>	<u>53.2</u>	<u>80.0</u>	72.2	<b>60.6</b>	<u>83.1</u>	<b>70.3</b>
SCAL	55.3	72.7	78.7	63.1	71.7	73.5	61.4	51.6	79.9	<u>72.5</u>	57.8	81.0	68.3
Ours	<u>60.4</u>	<u>73.7</u>	78.7	<u>65.2</u>	<b>73.8</b>	72.9	<u>64.7</u>	<b>56.7</b>	<b>81.3</b>	<b>73.2</b>	<u>59.3</u>	<b>83.5</b>	<u>70.2</u>

#### 4.2.1 在数字数据集上的实验结果

表2列出了该模型在MNIST,USPS和SVHN这3个数据集上域适应任务的实验结果。从实验结果分析可以得出,EFCO在3个域适应任务上都取得了较好的实验精度,平均准确率达到了97.1%的最优结果。EFCO模型在MNIST→USPS和USPS→MNIST上的域适应任务实验精度分别达到了96.5%和97.7%,其分类准确率优于以往的工作。最近,基于GAN网络的域适应方法在数字识别任务上取得了显著成果。CoGAN和MCD都是基于对抗网络架构的域适应方法,然而,CoGAN和MCD处理样本的基本动机是不同的。CoGAN通过分布匹配来减小域差距,MCD通过最小化分类差异来减轻域偏移的影响。本文方法通过GAN网络架构来划分目标域样本,并利用对比学习的思想来减小域间和域内差异。

#### 4.2.2 在Office-31数据集上的实验结果

表3列出了该模型在Office-31数据集上的6个域适应任务的实验结果及其平均值。由实验结果观察到,EFCO模型在3个域适应任务上取得了最好的结果,平均准确率达到88.8%,优于之前的比较方法。对于域位移大、域适应困难的D→A和W→A任务,EFCO模型仍然可以达到74.3%和74.6%的分类精度。

#### 4.2.3 在Office-Home数据集上的实验结果

表4列出了EFCO模型在Office-Home数据集上的实验

精度及平均值。通过实验分析可以得出,所提出EFCO方法在所有域适应任务上都取得了较好的实验精度,其平均准确率达到70.2%。更重要的是,当域差异较大时,EFCO模型在Ar→Rw,Cl→Rw和Pr→Rw等复杂传输任务上也取得了较好的实验精度,这进一步证明了模型的优越性。

### 4.3 实验参数分析

本节从所提方法的收敛性和参数敏感性方面进一步分析了模型的优缺点。

#### 4.3.1 收敛性分析

手写数字数据集上的域适应任务M→U,Office-31数据集上的域适应任务W→A和Office-Home数据集上的域适应任务Rw→Pr的实验结果如图3(a)所示。可以看出,随着模型迭代优化的进行,EFCO模型的准确率逐渐上升,并在第70次迭代附近趋于稳定。

#### 4.3.2 参数敏感性分析

本节分析了EFCO方法中超参数的值对实验精度的影响,具体结果如图3(b)—图3(d)所示。从实验结果观察到,当 $\alpha=0.05$ , $\beta=0.1$ 时,模型达到最好的实验精度。此外,还研究了参数 $\tau$ 的值对模型分类精度的影响,它是划分目标域样本的阈值。选取不同的阈值 $\tau$ 进行模型训练,从图3(d)中观察到,当 $\tau=0.6$ 时,模型的性能最好,阈值 $\tau$ 最终取值即为0.6。

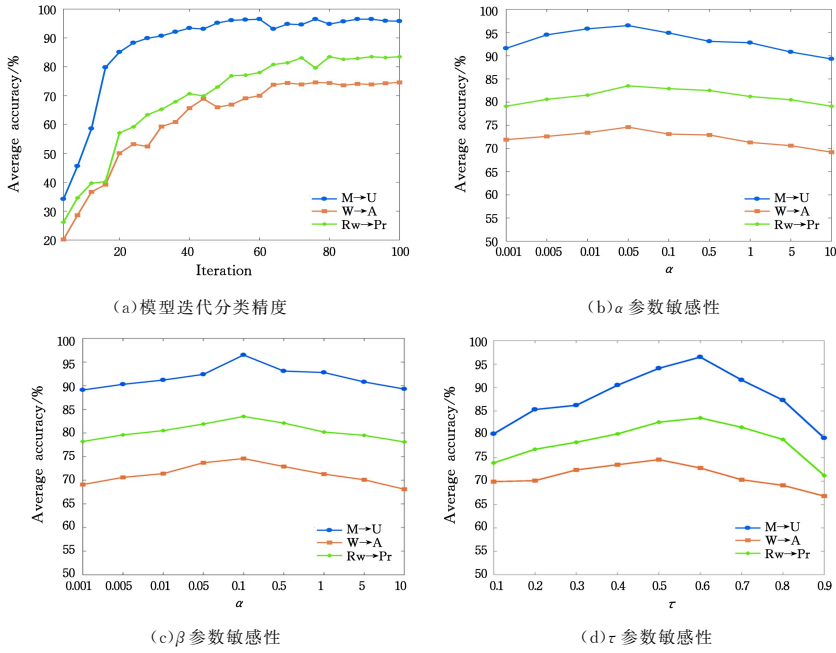


图3 模型迭代分类精度及参数敏感性

Fig. 3 Model iterative classification accuracy and parameter sensitivity

#### 4.4 噪声对比实验

为了评估所提模型(EFCO)的鲁棒性,本节通过对目标域困难样本增广,加入不同程度的噪声的对比实验,来进行模型的鲁棒性分析。本文分别在目标域图片中加入了标准差 $\sigma$ 为0.1,0.2和0.3的高斯噪声。在域适应任务 $M \rightarrow U$ , $W \rightarrow A$ 和 $R_w \rightarrow Pr$ 得出的实验结果如图4所示。可以看出,随着噪声的增加,模型的准确度只是略微下降,可见噪声对模型的影响并不显著,验证了所提模型的鲁棒性。




图4 噪声对比实验

Fig. 4 Noise contrast experiment

#### 4.5 消融实验

为了评估所提模型(EFCO)中每个模块的有效性,本节进行了消融实验,实验结果如表5、表6所列。

表5 EFCO框架在Office-31数据集上域适应任务 $D \rightarrow A$ 消融实验的准确性

Table 5 Accuracy of EFCO framework in domain adaptation task  $D \rightarrow A$  ablation experiment on Office-31 dataset

GAN 网络框架	对比学习(CL) 框架		Accuracy/%
	$L_{clu}$	$L_{ins}$	
✓			70.6
✓	✓		72.9
✓	✓	✓	74.3

表6 EFCO框架在数字数据集上域适应任务 $U \rightarrow M$ 消融实验的准确性

Table 6 Accuracy of EFCO framework on domain adaptation task  $U \rightarrow M$  ablation experiment on digital dataset

GAN 网络框架	对比学习(CL) 框架		Accuracy/%
	$L_{clu}$	$L_{ins}$	
✓			95.5
✓	✓		96.2
✓	✓	✓	97.7

针对在Office-31数据集上的域适应任务 $D \rightarrow A$ 和在数字数据集上的域适应任务 $U \rightarrow M$ 进行消融实验,验证了本文模型中的每个部分对性能的提升都很重要。值得注意的是,对比学习框架中的域间对比对齐和实例对比对齐损失都对模型性能提升起着重要作用,消融实验的结果证明了本文动机的合理性。


**结束语** 本文提出了一种基于熵值过滤和类质心优化的无监督域适应模型。首先,EFCO通过源域训练的GAN网络对目标域样本进行区分,将熵值小于阈值的样本定义为分类简单样本,将熵值大于阈值的样本定义为分类困难样本。其次,对于划分为分类简单样本的目标域样本,采用源域训练好的分类器对其分配伪标签。最后,对于划分为分类困难样本的目标域样本,通过源域标签和目标域简单样本的标签来训练得到更加鲁棒的分类器,计算源域和目标域的各类中心,分别优化域间对比对齐和实例对比对齐,以减小域间和域内的差异。针对目标样本分类难度不同的情况,采取不同的处理方式有助于提高模型的判别能力。在未来工作中,我们将考虑更加完善的样本划分策略,尽可能地促进两类样本的学习,并且面向更具挑战性的多目标域适应场景展开相关研究。

#### 参考文献

[1] SUN B, SAENKO K. Deep coral: Correlation alignment for deep

- domain adaptation[C]//Proceedings of European Conference on Computer Vision. Springer, 2016: 443-450.
- [2] TIAN Q, SUN H, MA C, et al. Heterogeneous Domain Adaptation With Structure and Classification Space Alignment[J]. IEEE Transactions on Cybernetics, 2022, 52(10): 10328-10338.
- [3] LONG M, CAO Z, WANG J, et al. Conditional adversarial domain adaptation[J]. Advances in Neural Information Processing Systems, 2018, 31: 1647-1657.
- [4] PEI Z, CAO Z, LONG M, et al. Multi-Adversarial domain adaptation[C]//Proceedings of AAAI Conference on Artificial Intelligence. AAAI Press, 2018: 3934-3941.
- [5] GANIN Y, LEMPITSKY V. Unsupervised domain adaptation by backpropagation[C]//Proceedings of International Conference on Machine Learning. PMLR, 2015: 1180-1189.
- [6] TIAN Q, ZHU Y, SUN H, CHEN S, et al. Unsupervised Domain Adaptation Through Dynamically Aligning Both the Feature and Label Spaces[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2022, 32(12): 8562-8573.
- [7] LONG M, ZHU H, WANG J, et al. Unsupervised domain adaptation with residual transfer networks[J]. Advances in Neural Information Processing Systems, 2016, 29: 136-144.
- [8] TIAN Q, PENG S, MA T. Source-free Unsupervised Domain Adaptation with Trusted Pseudo Samples[J]. ACM Transactions on Intelligent Systems and Technology, 2023, 14(2): 2157-6904.
- [9] OORD A, LI Y, VINYALS O. Representation learning with contrastive predictive coding[J]. arXiv:1807.03748, 2018.
- [10] HE K, FAN H, WU Y, et al. Momentum contrast for unsupervised visual representation learning[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2020: 9726-9735.
- [11] KANG G, JIANG L, YANG Y, et al. Contrastive adaptation network for unsupervised domain adaptation[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2019: 4893-4902.
- [12] CHEN T, KORNBLITH S, NOROUZI M, et al. A simple framework for contrastive learning of visual representations [C]//Proceedings of International Conference on Machine Learning. PMLR, 2020: 1597-1607.
- [13] GRILL J B, STRUB F, ALTICHE F, et al. Bootstrap your own latent-a new approach to self-supervised learning[J]. Advances in Neural Information Processing Systems, 2020, 33: 21271-21284.
- [14] SINGH A, CHAKRABORTY O, VARSHNEY A, et al. Semi-supervised action recognition with temporal contrastive learning [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2021: 10389-10399.
- [15] XIE S, ZHENG Z, CHEN L, et al. Learning semantic representations for unsupervised domain adaptation[C]//Proceedings of International Conference on Machine Learning. PMLR, 2018: 5423-5432.
- [16] PINHEIRO P O. Unsupervised domain adaptation with similarity learning[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2018: 8004-8013.
- [17] PAN Y, YAO T, LI Y, et al. Transferrable prototypical networks for unsupervised domain adaptation[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2019: 2239-2247.
- [18] YAN H, LI Z, WANG Q, et al. Weighted and class-specific maximum mean discrepancy for unsupervised domain adaptation [J]. IEEE Transactions on Multimedia, 2019, 22(9): 2420-2433.
- [19] HU L, KAN M, SHAN S, et al. Unsupervised domain adaptation with hierarchical gradient synchronization[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2020: 4043-4052.
- [20] LU Y, ZHU Q, ZHANG B, et al. Weighted correlation embedding learning for domain adaptation[J]. IEEE Transactions on Image Processing, 2022, 31: 5303-5316.
- [21] CHEN C, XIE W, HUANG W, et al. Progressive feature alignment for unsupervised domain adaptation[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2019: 627-636.
- [22] WANG X, LI L, YE W, et al. Transferable attention for domain adaptation[C]//Proceedings of AAAI Conference on Artificial Intelligence. AAAI Press, 2019: 5345-5352.
- [26] ZHANG W, OUYANG W, LI W, et al. Collaborative and adversarial network for unsupervised domain adaptation[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2018: 3801-3809.
- [24] 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.
- [25] DENG Z, LUO Y, ZHU J. Cluster alignment with a teacher for unsupervised domain adaptation[C]//Proceedings of IEEE International Conference on Computer Vision. IEEE, 2019: 9944-9953.
- [26] WANG Q, BRECKON T. Unsupervised domain adaptation via structured prediction based selective pseudo-labeling[C]//Proceedings of AAAI Conference on Artificial Intelligence. AAAI Press, 2020: 6243-6250.
- [27] WANG M, DENG W. Cycle label-consistent networks for unsupervised domain adaptation [J]. Neurocomputing, 2021, 422: 186-199.
- [28] MORERIO P, VOLPI R, RAGONESI R, et al. Generative pseudo-label refinement for unsupervised domain adaptation[C]//Proceedings of IEEE Winter Conference on Applications of Computer Vision. IEEE, 2020: 3130-3139.
- [29] LITRICO M, DEL BUE A, MORERIO P. Guiding Pseudo-Labels With Uncertainty Estimation for Source-Free Unsupervised Domain Adaptation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2023: 7640-7650.
- [30] CHU T, LIU Y, DENG J, et al. Denoised Maximum Classifier Discrepancy for Source-Free Unsupervised Domain Adaptation [C]//Proceedings of the AAAI Conference on Artificial Intelligence. AAAI Press, 2022: 472-480.
- [31] TIAN Y, KRISHNAN D, ISOLA P. Contrastive multiview co-

- ding[C]//Proceedings of European Conference on Computer Vision. Springer,2020:776-794.
- [32] KHOSLA P,TETERWAK P,WANG C,et al. Supervised contrastive learning[J]. Advances in Neural Information Processing Systems,2020,33:18661-18673.
- [33] GE Y X,ZHU F,CHEN D,et al. Self-paced contrastive learning with hybrid memory for domain adaptive object re-id[J]. Advances in Neural Information Processing Systems, 2020, 33: 11309-11321.
- [34] THOTA M,LEONTIDIS G. Contrastive domain adaptation [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. 2021:2209-2218.
- [35] LIU W,FERSTL D,SCHULTER S,et al. Domain adaptation for semantic segmentation via patch-wise contrastive learning [J]. arXiv:2104.11056,2021.
- [36] GRETTON A,BORGWARDT K M,RASCH M J,et al. A kernel two-sample test[J]. Journal of Machine Learning Research, 2012,13(1):723-773.
- [37] HUANG J,GUAN D,XIAO A,et al. Category contrast for unsupervised domain adaptation in visual tasks[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE,2022:1203-1214.
- [38] PAN S,YANG Q. A survey on transfer learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10):1345-1359.
- [39] HOFFMAN J,TZENG E,PARK T,et al. Cycada:Cycle-consistent adversarial domain adaptation[C]//Proceedings of International Conference on Machine Learning. PMLR, 2018:1989-1998.
- [40] LECUN Y,BOTTOU L,BENGIO Y,et al. Gradient-based learning applied to document recognition [J]. IEEE, 1998, 86(11):2278-2324.
- [41] HULL J. A database for handwritten text recognition research [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,1994,16(5):550-554.
- [42] NETZER Y,WANG T,COATES A,et al. Reading digits in natural images with unsupervised feature learning[J]. NIPS Workshop on Deep Learning & Unsupervised Feature Learning. 2011.
- [43] SAENLO K,KULIS B,FRITZ M,et al. Adapting visual category models to new domains[C]//Proceedings of European Conference on Computer Vision. Springer,2010:213-226.
- [44] VENKATESWARA H,EUSBIO J,CHAKRABORTY S,et al. Deep hashing network for unsupervised domain adaptation[C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society,2017:5018-5027.
- [45] 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.
- [46] TZENG E,HOFFMAN J,SAENKO K,et al. Adversarial discriminative domain adaptation[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society,2017:7167-7176.
- [47] LONG M,CAO Y,WANG J,et al. Learning transferable features with deep adaptation networks[C]//Proceedings of International Conference on Machine Learning. PMLR,2015:97-105.
- [48] SAITO K,WATANABE K,USHIKU Y,et al. Maximum classifier discrepancy for unsupervised domain adaptation[C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society,2018:3723-3732.
- [49] XIAO N,ZHANG L. Dynamic weighted learning for unsupervised domain adaptation[C]// Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2021: 15242-15251.
- [50] LIU H, LONG M, WANG J, et al. Transferable adversarial training: A general approach to adapting deep classifiers[C]// Proceedings of International Conference on Machine Learning. PMLR,2019:4013-4022.
- [51] LONG M,ZHU H,WANG J,et al. Deep transfer learning with joint adaptation networks [C] // Proceedings of International Conference on Machine Learning. PMLR,2017:2208-2217.
- [52] LI S,SONG S,WU C. Layer-wise domain correction for unsupervised domain adaptation[J]. Frontiers of Information Technology Electronic Engineering,2018,19(1):91-103.
- [53] LIU M,TUZEL O. Coupled generative adversarial networks [J]. Advances in Neural Information Processing Systems,2016, 29:469-477.
- [54] XU R,LI G,YANG J,et al. Larger norm more transferable: An adaptive feature norm approach for unsupervised domain adaptation[C] // Proceedings of IEEE International Conference on Computer Vision. IEEE,2019:1426-1435.
- [55] LI M,ZHAI Y,LUO Y,et al. Enhanced transport distance for unsupervised domain adaptation[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2020:13936-13944.
- [56] DU Z,LI J,SU H,et al. Cross-domain gradient discrepancy minimization for unsupervised domain adaptation[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE,2021:3937-3946.
- [57] WANG H,TIAN J,LI S,et al. Structure-conditioned adversarial learning for unsupervised domain adaptation[J]. Neurocomputing,2022,497:216-226.
- [58] HE K,ZHANG X,REN S,et al. Deep residual learning for image recognition [C] // Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society,2016:770-778.



**TIAN Qing**, born in 1984, Ph.D, professor. His main research interests include machine learning and pattern recognition.