

doi: 10.12052/gdutxb.230172

一种基于邻居环境感知的主动领域自适应算法

陈鑫瑀, 朱 鉴, 陈炳丰, 蔡瑞初

(广东工业大学 计算机学院, 广东 广州 510006)

摘要: 主动领域自适应 (Active Domain Adaptation, ADA) 目的是在领域自适应的背景下利用尽可能少的目标域查询预训练来训练一个有效模型。然而, 由于领域漂移的存在, 现有的算法选择的实例可能是信息量低、冗余或离群的。为了解决这个问题, 本文提出了一种新的方法用于主动领域自适应, 即基于邻居环境感知的样本选择算法 (Neighbor Environment Perception Sample Selection, NEPS)。NEPS以一种邻居环境感知的方式来探索目标样本的信息量, 以选择在领域转移下可能最有价值的实例。具体而言, 在计算样本信息量时, 测量所提出的邻居环境感知信息得分 (Neighbor Awareness Informativeness Score, NAIS) 的同时利用从单个数据点以及从其附近的邻居所获得的信息, 从而确保所选样本具有较高的单点及环境信息量。同时, 通过计算候选样本与已标记样本的相似度分数来对样本进行排序挑选, 以保证所选样本的多样性。此外, 还充分利用了所有已标记样本以及目标领域的大量未标记数据信息, 从而提高模型的性能。经验证, 本文方法具有较强的样本选择能力, 在各种基准数据集上的分类效果都优于现有的模型。

关键词: 主动领域自适应; 信息性; 多样性; 邻居环境感知

中图分类号: TP181

文献标志码: A

文章编号: 1007-7162(2024)06-0080-11

Active Domain Adaptation Based on Neighbor Environment Perception Sample Selection

Chen Xin-yu, Zhu Jian, Chen Bing-feng, Cai Rui-chu

(School of Computer Science and Technology, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: Active domain adaptation (ADA) aims to train an effective model under the context of domain adaptation with as few queried instances as possible. However, existing algorithms tend to select instances that are either uninformative, redundant, or outliers due to domain shift. To address this issue, a novel approach called neighbor environment perception sample selection (NEPS) for active domain adaptation is proposed. NEPS explores the target sample informativeness in a neighbor environment-aware manner to select instances that are potentially most valuable under domain shift. Specifically, from informativeness perspective, NEPS aims to acquire knowledge not only from individual data points but also from their neighboring samples. This is achieved by measuring neighbor awareness informativeness score (NAIS), which ensures the selected samples have both high individual informativeness score and environment informativeness score. Additionally, NEPS ranks and selects samples based on their similarity scores with labeled samples to ensure diversity among the chosen instances. Furthermore, NEPS makes effective use of all labeled samples as well as a large amount of unlabeled data from the target domain to enhance the model's performance. Experimental results demonstrate that NEPS exhibits strong sample selection capability and outperforms existing models in terms of classification performance on various benchmark datasets.

Key words: active domain adaptation; informativeness; diversity; neighbor environment perception

收稿日期: 2023-10-29

基金项目: 国家自然科学基金资助重点项目(62237001); 国家重点研发计划项目(2021ZD0111501); 国家自然科学基金优秀青年基金资助项目(6212200101); 国家自然科学基金资助面上项目(62272298, 62176066, 61976052); 广州市科技计划项目(202002030110, 202007040005)

作者简介: 陈鑫瑀(2001-), 女, 硕士研究生, 主要研究方向为迁移学习、主动学习, E-mail: 1060614445@qq.com

通信作者: 朱鉴(1982-), 男, 副教授, 硕士生导师, 主要研究方向为机器学习、计算机视觉, E-mail: dr.zhuj@gmail.com

深度神经网络在解决各种机器学习问题上显示了较大优越性,但仍存在一些基本限制。具体而言,对于每个新的应用领域,标记大量数据需要耗费大量时间和人力资源。此外,其通常假设训练和测试数据是从同一分布中抽取的,但这并不总是适用于现实世界的情景。训练和测试领域之间的分布变化可能会导致模型性能严重下降。领域自适应是机器学习和模式识别领域中的一个重要研究方向。其主要目标是解决在面对新的领域或数据时传统模型性能下降的问题。随着现实世界中数据的不断变化和增加,传统的机器学习模型往往难以适应这种变化,因此领域自适应的研究变得尤为重要。

领域自适应根据不同的场景又分为无监督领域自适应、半监督领域自适应和few-shot领域自适应等,其旨在提高模型对新领域数据的泛化能力。无监督领域自适应是指在目标领域缺乏标签信息的情况下进行领域适应。在这种情况下,无监督领域自适应的任务是通过挖掘数据本身的分布特点和相似性来实现领域适应,而不依赖于标签信息。半监督领域自适应则是在目标领域只有部分标记数据可用的情况下进行领域适应。这种情况下,可以借助少量的标记数据来辅助领域适应,从而提高模型对目标领域的泛化能力。另外,还有一种领域自适应方法被称为few-shot领域自适应。在这种场景下,目标领域的标记样本非常有限。few-shot领域自适应的目标是利用极少量标记样本和大量无标记样本,使模型能够迅速适应新的领域并具有良好的泛化能力。这些方法都在不同场景下发挥着重要作用,帮助模型更好地适应新的领域和数据,提高模型的泛化能力和应用效果。

近年,无监督领域自适应(Unsupervised Domain Adaptation, UDA)取得了大量成果^[1-4],其中大多数方法通过创建域不变特征表示来对齐源域和目标域。例如,Tzeng等^[5]利用最大平均差异核来最小化源域和目标域之间的差距。Ganin等^[1]和Hoffman等^[6]采用对抗学习来学习两个域之间的共享潜在表示。然而,无监督领域自适应方法的性能仍远落后于完全监督方法^[7]。根据Zhao等^[8]提出的泛化上限,当缺少目标域的标签信息时,在没有进一步假设的情况下,泛化上限将无法控制。换句话说,只有获得部分目标域中样本的标签信息后才能控制泛化上限,从而得到可控制的结果。因此,一些半监督领域自适应的方法^[9-10]和few-shot领域自适应^[11-12]的方法被提出,其通过获得小部分目标域数据的标签信息来提高模型的表

现。另一方面,在实践中对目标域中的少量数据收集标签通常是可行的。由于来自目标域的样本通常具有不相等的信息价值,如何从目标域中选择最有价值的样本进行标注已成为一个越来越重要的问题。

主动学习(Active Learning, AL)是机器学习中的一种重要学习范式,其核心思想是从未标记数据中选择最有用的样本进行人工标注。在过去的几十年里,关于主动学习领域中的许多采样准则已被提出^[13-15],主要可以分为两类:基于信息性和基于代表性。第一类旨在通过最小化统计模型的不确定性来找到对分类器最具信息量的样本,其中通常根据熵^[14]或最小置信度^[15]等准则计算的查询分数来进行样本选择。例如,Wang等^[14]通过熵来测量样本的不确定性以选择候选样本。Gal等^[16]将不确定性的测量与贝叶斯深度神经网络相结合。第二类旨在选择最具代表性的样本,这些样本代表数据中的特定模式,通常通过核心集合^[17]或聚类^[18]等方法选择代表性高的样本,例如,Sener等^[17]通过求解K中心问题来选择样本,Zhdanov^[18]采用聚类来选择不同的样本。最近,一些方法^[19-20]尝试将以上两种准则结合起来作为采样方案,以改善选择结果。例如,Shui等^[20]利用对抗性训练技术,通过结合批评函数来选择具有高信息性和代表性的实例。

然而传统的主动学习采样策略是基于标记和未标记数据来自同一分布的假设所设计的,这在领域自适应场景下并不适用。为了解决这个问题,研究人员开发了一系列主动领域自适应方法,将主动学习和领域自适应相结合。主动领域自适应在各个领域都有广泛的应用场景。以医学影像分析为例,医学影像数据可能来自不同的医院、设备或不同时间段,这导致了数据分布存在差异的问题。因此对于医学图像的分类或者诊断模型,需要针对目标域的数据进行重新训练,以达到更好的性能。而对医学图像进行标记通常需要有经验的医师介入,因此标记成本很高。为解决这一问题,主动领域自适应尝试在目标域中选择重要的未标记样本进行手动标记,并使用尽可能少的标记本来训练有效的分类器。这种方法不仅能够减少标记成本,同时还能提高模型的效果,达到在使用尽量少目标域标注预算的同时提升模型性能的目的。

为了在目标域中选出价值较高的候选样本,研究人员提出了多种策略。例如,Rai等^[21]从目标域中通过解决凸优化问题来选择候选样本。Prabhu等^[22]使用不确定性加权聚类,在存在域偏移的情况下选择距

离质心最近的样本。Fu等^[23]采用不确定性和领域相似性的委员会方案,在域偏移下实现候选样本的选择。Xie等^[24]在域偏移下,利用能量模型来帮助选择具有自由能量的关键样本。

本文主要发现当前主动领域自适应算法存在以下3个问题。(1) 它们大多使用单个点的查询分数来选择实例,这可能会导致选择离群值或次优样本。首先,仅通过自身的查询分数选择一个点可能会选择一个离群样本,因为根据现有的选择标准,如不确定性,离群值的信息量得分往往相对较高。其次,如果选择点的环境整体上不具有高信息量,则它不是最佳选择,更好的选择应该是被选择样本周围的邻居环境同样具有高信息量。(2) 很少有研究考虑被选中的样本之间的关系,这可能会导致模型选择具有相似特征的样本,从而导致查询冗余的样本。因此,如何确保所选样本的多样性也是至关重要的。(3) 目前很少主动领域自适应方法充分利用目标域样本的信息来提高模型的性能。

为了解决上述问题,本文提出了一种新的主动领域自适应方法,称为基于邻居环境感知的样本选择算法NEPS (Neighbor Environment Perception Sample Selection),它以邻居环境感知的方式探索目标样本的信息性同时保证样本的多样性,其改善了在具有领域漂移的情况下的样本选择结果。

主要贡献点包括:(1) 提出了基于邻居环境感知的主动领域自适应方法NEPS,该方法能有效地同时利用个体点的知识和它们周围的邻居信息来选择高信息量的样本。(2) 设计了基于相似度的多样性样本选择算法,以确保所选样本的多样性。(3) 算法充分利用标注的小部分目标域标记数据,并且将目标领域无标记数据赋予伪标签加入训练。通过充分利用所有已标记样本以及目标领域的大量未标记数据信息进一步提高模型的性能。

1 方法论

1.1 定义和符号

在随后的章节中,使用 $g(x)$ 作为特征提取器, f 对提取出的特征进行最终分类。 G_d 为领域鉴别器, $G_d(g(x))$ 将样本分类为源域和目标域。 f , g 和 G_d 分别由 θ_f 、 θ_g 和 θ_d 进行参数化。

本文中 D_S 和 D_T 分别代表源域和目标域的数据, D_{LT} 代表有标签的目标域数据, D_{UT} 代表没有标签的目标域数据,在初始训练阶段, D_{LT} 为空,且 $D_{UT} = D_T$ 。

在主动领域自适应的每个查询循环中,首先使

用 D_S 和 D_{LT} 作为源,使用 D_{UT} 作为目标执行领域自适应过程。然后样本选择算法从 D_{UT} 中主动选择 N 个样本进行标注添加到 D_{LT} 中,这个过程循环 R 次。

在主动领域自适应中,有2个不同的步骤,即样本选择和领域自适应,将分别在下面描述。

1.2 基于邻居环境感知样本选择算法

在样本选择阶段,主动领域自适应算法的目标是注释目标域中最有价值的样本。此前的一些方法由于没有考虑领域漂移而经常选到一些冗余或离群的样本。为此,本文设计了新的策略来衡量样本的价值,通过邻居环境感知的方式来计算样本的信息性,以确保所选样本的有效性。

样本的信息性通常通过不确定度得分来衡量。然而,在源域和目标域之间存在领域漂移的情况下,样本的不确定性可能会被误判。因此,除了不确定性,本文还考虑使用另一个指标“接近度”来衡量样本的信息性。目标域中的样本可以分为两种类型,一种是较接近源域数据的样本,这种样本在模型预训练后大部分都可以很好地被分类正确,而还有一种就是较偏向目标域的数据,这样的数据与源域的距离较远,使用预训练后的模型对其分类的效果较差,这样的样本被认为具有更大的信息量。因此,在某种意义上,具有高不确定性和高目标域接近性的样本信息量更大。

此外,在先前的一些工作中仅关注单个点的知识,这可能导致次优的选择。因此,在样本选择中,需要考虑样本所在邻居环境中单个点以及其相邻点的知识。本文既考虑单个样本的信息性,也考虑它所属的邻居环境包含的信息。

1.2.1 信息度量指标设计

(1) 不确定性:本算法基于熵来测量实例的不确定性得分(Uncertainty Score, US),熵值是信息理论中用来衡量随机变量不确定性的概念,其值越大表示样本所包含的信息越丰富^[14]。其方程式可以写成

$$US(x) = - \sum_{i=1}^C P_{\theta}(y_i | x) \times \log P_{\theta}(y_i | x) \quad (1)$$

式中: C 代表样本类别数, y_i 代表样本 x 的所有可能标签。熵值越大,表示样本的分布越均匀,不确定性越高。通过选择US值较高的样本,可以选择具有高不确定性的样本。

(2) 目标域接近度:本算法优先选择目标域中与源域样本最不相似的样本进行标注。这是因为目标域中与源域样本差异较大的样本往往携带着更多的

信息,通过对这些样本进行标注,可以更好地增强模型在目标域上的泛化能力。

直观地说,样本越接近目标域,它包含的信息就越多,选择这些样本进行标注,给模型带来提升就越多。相反,样本越接近源域,其包含的信息越少,对模型性能的改善也越小。因此,本算法将样本和目标域之间的接近度作为一个衡量指标,对样本进行度量。接下来,将描述如何测量接近度分数(Closeness Score, CS)。数学上,接近度可以表示为

$$CS^*(x) = \frac{p_T(g(x))}{p_S(g(x)) + p_T(g(x))} \quad (2)$$

式中: $p_S(\cdot)$ 和 $p_T(\cdot)$ 分别是源域和目标域的边缘概率分布。由于这两个分布是未知的,因此使用上述公式无法计算得到 $CS^*(x)$ 。

遵循Goodfellow等^[25]的证明结果,最佳的域分类器 G_d^* 为

$$G_d^*(g(x)) = \frac{p_S(g(x))}{p_S(g(x)) + p_T(g(x))} \quad (3)$$

从上面的等式可以看出 $G_d^*(g(x))$ 表示样本与源域的接近程度。根据式(2)和(3),可以得到

$$CS^*(x) = 1 - G_d^*(g(x)) \quad (4)$$

这样,通过 $G_d^*(g(x))$ 便可以测量样本接近目标域的程度。其中,具有较大的 $CS^*(x)$ 的样本更接近目标域,因此被视为信息量大的样本。

1.2.2 邻居环境感知分数

为了在预算有限的情况下为模型找到最有价值的样本,对于某样本,本算法不仅考虑了其单点的信息性得分,还同时考虑了该点所属邻居环境的信息性分数。这些分数的计算方法如下。

(1) 单点的信息性得分:用上面提到的2个信息量衡量指标,即样本的不确定分数US以及样本的目标域接近度分数CS来计算某一个样本的价值。其中单点信息分数(Individual Informativeness Score, IIS)可由式(5)计算得到。

$$IIS(x) = US(x) + \alpha CS(x) = -\sum_{i=1}^C P_\theta(y_i | x) \times \log P_\theta(y_i | x) + \alpha [1 - G_d(g(x))] \quad (5)$$

式中: α 用于控制不确定分数和目标域接近度得分之间的平衡。

(2) 样本邻居环境的信息性得分:使用邻居信息量得分(Neighboring Informativeness Score, NIS)来描述关于单个样本 x 所属的邻居环境的信息量。

首先,将距离样本 x 最近的 K 个邻居定义为其邻

居环境,并用 Q_j 表示其第 j 个邻居。接着,使用特征提取器 g 将每个邻居 Q_j 的特征表示映射为一个向量,并计算样本 x 与每个邻居 Q_j 之间的相似性,表示为 $\text{Sim}(g(x), g(Q_j))$ 。然后,通过式(6)计算NIS(x)的值。

$$NIS(x) = \frac{1}{K} \sum_{j=1}^K [IIS(Q_j) \times \text{Sim}(g(x), g(Q_j))] \quad (6)$$

式中: $\text{Sim}(\cdot)$ 为测量2个样本之间距离的方法,这里通过余弦相似度计算。该式通过对单个样本 x 的邻居环境中每个邻居的IIS值和其与样本 x 的相似性进行加权平均来计算NIS得分,这个得分反映了关于样本 x 所在邻居环境的信息量。

由式(6)可以得到NIS与以下两项成正比:(1) 样本与其周围邻居之间的距离;(2) 周围邻居的信息量分数。NIS的值越大说明样本处于信息量高且紧密的环境中,也就是表明样本的信息量高。

通过结合IIS和NIS可以计算样本的邻居环境感知分数。

$$NAIS(x) = \beta \times IIS(x) + (1 - \beta) \times NIS(x) \quad (7)$$

式中: β 用于控制单点信息和环境信息得分之间的平衡, $\beta \in [0, 1]$ 。

1.2.3 多样性

由于直接基于NAIS选择的样本可能会导致模型选择具有相似特征的样本,进而引发查询冗余样本的情况。在这种情况下,模型的性能提升可能受到限制。相反,通过选择多样的样本,可以降低整体数据集的熵,从而减少整体的不确定性。另一方面,可以获得关于不同特征或类别之间的更多信息^[17],这些信息有助于提升模型性能。

基于此,本文设计了多样性样本选择算法(Diverse Sample Selection Algorithm, DSSA),基于已选样本的信息来选择具有多样性的样本。

首先,基于NAIS值选择前 $\gamma\%$ 信息量高的样本,然后分别计算这 $\gamma\%$ 样本与已选标注集合中样本的相似度分数(Set Similarity Score, SSS),以选择与已选样本最不相似的样本,增加所选样本的多样性。集合相似度分数SSS计算式为

$$SSS(x) = \frac{1}{N_s} \sum_{i=1}^{N_s} \text{Sim}(g(x), g(x_i)), x_i \in X_s \quad (8)$$

式中: X_s 代表已标注集合, N_s 代表已选集合中样本的个数。样本将根据SSS升序排列,具有较低分数的样本即为与已选标注样本集合最不相似的样本,其将被优先选择成为标注候选样本。整个样本选择过程如图1所示。

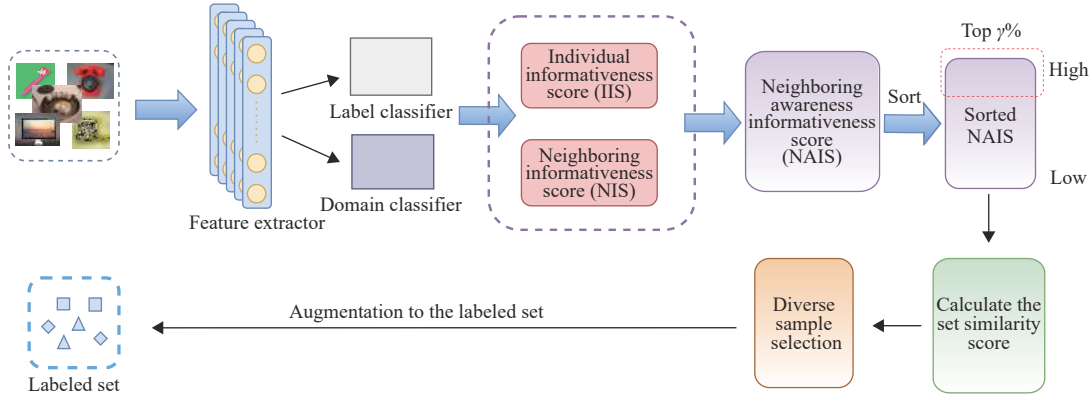


图1 NEPS方法的样本选择过程

Fig.1 Sample selection process of the proposed NEPS method

1.3 对抗性主动领域自适应

本算法采用加权对抗对齐方法来减少源域和目标域之间的域偏移。特征提取器 g 与域分类器 G_d 通过类似GAN^[25]的过程进行训练,用来学习提取不变特征。

$$L_S(g, f) = E_{(x_s, y_s) \sim D_S} l(f(g(x_s)), y_s) \quad (9)$$

$$L_{adv}(g, G_d) = E_{x_s \sim D_S \cup D_{LT}} \log G_d(g(x_s)) + E_{x_t \sim D_{UT}} \log(1 - G_d(g(x_t))) \quad (10)$$

式中: L_S 代表在源域数据上进行分类的交叉熵损失, L_{adv} 用来对齐源域和目标域, l 代表交叉熵损失函数。

在样本选择阶段之后,将注释后的样本加入训练,由于注释预算远小于目标域中的样本数量,因此,在本算法中,对目标域有标签样本进行数据增强并加入训练过程,对于样本 $x_t \in D_{LT}$,对其进行 M 次数据增强。

$$\hat{x}_{t,m} = \text{Augment}(x_t), m \in (1, \dots, M) \quad (11)$$

$$L_{LT}(g, f) = E_{(x_t, y_t) \sim D_{LT}} \sum_{m=1}^M l(f(g(\hat{x}_{t,m})), y_t) \quad (12)$$

式中: L_{LT} 代表具有真实标签的目标域样本的分类损失,而对于大量未标记的目标数据,根据模型预测对其附上伪标签,然后加入训练。

$$L_{UT}(g, f) = E_{(x_t, \bar{y}_t) \sim D_{UT}} l(f(g(x_t)), \bar{y}_t) \quad (13)$$

总损失函数定义为

$$L_c = L_S + L_{LT} + \phi \times L_{UT} \quad (14)$$

$$\min_{\theta_f, \theta_g, \theta_d} \max_{\theta_c} L_c + L_{adv} \quad (15)$$

式中: ϕ 是控制权重的超参数。值得注意的是,由于伪

标签可能不正确,为了防止模型过度拟合具有错误标签的样本,将较小的权重 ϕ 分配给来自使用伪标签样本的分类损失。通过这种方式,该模型更加关注具有真实标签的目标域数据,从而提高模型的性能。

算法1用伪代码描述了所提出的NEPS方法的总体工作流程。

算法1 基于邻居环境感知的样本选择算法

1) 输入: D_S, D_{LT}, D_{UT} , 每一轮的查询预算 N , 总共查询轮数 R , 每一轮的迭代次数 I 。

2) 参数: 类别分类器参数 θ_f , 特征提取器参数 θ_g , 领域鉴别器参数 θ_d 。

3) 输出: 优化后的 $\theta_f^*, \theta_g^*, \theta_d^*$ 。

4) 初始化: 初始化参数 $\theta_f, \theta_g, \theta_d$, 设置 $r=0$ 。

5) D_S, D_{LT}, D_{UT} 通过最小化式(9)和式(10)的损失函数来进行模型训练,直至达到收敛状态。

(a) 根据图1所示的样本选择算法选出目标域的 N 个候选样本集合 X_t , 并对其进行人工标注;

(b) 更新 D_{LT} 和 D_{UT} , $D_{LT} = D_{LT} \cup X_t$, $D_{UT} = D_{UT} / X_t$;

(c) 根据模型预测计算 D_{UT} 中样本的伪标签;

(d) D_S, D_{LT}, D_{UT} 根据式(15)进行迭代训练 I 次;

(e) $r=r+1$ 。

6) 直至 $r=R$ 。

7) 输出: $\theta_f^*, \theta_g^*, \theta_d^*$ 。

2 实验结果及分析

2.1 实验设置

2.1.1 数据集

本文在4个广泛用于迁移学习的数据集上进行实验,证明了所提出的算法的有效性。(1) Office-Home^[26]数据集,其包含来自4个不同领域的15 588张图像,涵盖了65个类别,包括艺术(Ar)、剪贴画(CI)、

产品(Pr)和真实世界(Rw)。(2) Office-31^[27]数据集包含3个不同的领域,包括亚马逊(A)、数码相机(D)和网络摄像头(W),总共有4 110张来自31个不同类别的图像。(3) Image-CLEF 2014^[28]是ImageCLEF 2014领域适应挑战的基准数据集,包含3个领域: Caltech-256(C)、ILSVRC-2012(I)和PascalVOC-2012(P)。每个领域包含12个类别,每个类别由50张图像组成。(4) CIFAR-10^[29]数据集只包含1个领域,有10个不同的类别,每个类别由6 000张图像组成。

2.1.2 实现细节

本文在具备完全标记的源域数据和未标记的目标域数据的情况下开始实验。在不同的实验设置下,本文使用ResNet-50作为特征提取器和标签分类器,并使用学习率为0.001、动量为0.9的SGD优化器进行训练。在初始阶段,模型进行30个epoch的训练。在每个主动学习轮次中,NEPS会标注目标数据的1%样本。在每轮样本选择后,NEPS使用新获取的目标数据对模型进行3个epoch的训练。查询过程在全部预算用完之前一直循环进行。最后,所有数据将共同进行20个epoch的训练。所有数据集的批大小均设置为16。超参数 α 、 β 、 γ 、 M 和 ϕ 的值分别设置为0.1、0.6、5、4和0.3。

2.2 消融实验

为验证文中所设计的信息性计算准则的有效性,本算法在Image-CLEF数据集上使用5%的查询预算,对计算信息性分数的2个组成部分(即IIS和NIS)进行了消融实验,结果如表1所示。其中,本算法分别尝试了NEPS w/o IIS和NEPS w/o NIS,它们相对于Random和基于Entropy的选择方法都有较大的提升,这表明在计算信息性时考虑目标域接近度的重要性。

表1 计算信息性得分项消融实验的分类准确率

Table 1 Classification accuracy for ablation experiments on informativeness scores %

算法	C \Rightarrow I	C \Rightarrow P	I \Rightarrow C	I \Rightarrow P	P \Rightarrow C	P \Rightarrow I	Avg.
Random	91.0	77.2	95.5	77.7	92.0	88.3	86.9
Entropy ^[4]	91.2	78.0	96.2	78.9	93.2	92.5	88.3
NEPS w/o IIS	93.4	78.9	97.4	80.4	96.8	93.4	90.1
NEPS w/o NIS	93.2	78.7	97.8	80.5	97.0	92.7	90.0
NEPS	93.6	80.1	98.5	80.6	97.2	94.3	90.7

进一步分析实验结果,可以看出NEPS w/o IIS和NEPS w/o NIS两者在所有迁移任务中表现相似,而NEPS进一步将平均准确率提升,并在大多数任务中

实现最佳性能。这也说明了结合考虑单个点的知识和其邻居信息的有效性。另外,通过观察NEPS与Random算法的对比结果可以发现,本文所提算法通过主动选择信息量高的样本,显著提升了模型的性能,这也表明了本文所采用的高信息量策略在提升模型后续学习性能方面具有积极意义。

本文进一步对确保所选样本具有多样性的方案DSSA (Diverse Sample Selection Algorithm)进行了消融研究,结果如表2所示。从结果中可以看出NEPS几乎在所有迁移任务上的表现都优于NEPS w/o DSSA,这证明了文中所提出的冗余样本排除方案的有效性,同时也说明本文所采用的多样性选择方法对于后续的学习过程具有积极意义。上述消融实验的结果证实了本文提出模型的合理性。

表2 冗余样本排除算法DSSA消融实验的分类准确率

Table 2 Classification accuracy for ablation experiments for the redundant sample exclusion algorithm DSSA %

算法	C \Rightarrow I	C \Rightarrow P	I \Rightarrow C	I \Rightarrow P	P \Rightarrow C	P \Rightarrow I	Avg.
Random	91.0	77.2	95.5	77.7	92.0	88.3	86.9
Entropy ^[4]	91.2	78.0	96.2	78.9	93.2	92.5	88.3
NEPS w/o DSSA	92.9	78.2	98.4	79.8	96.8	94.2	90.1
NEPS	93.6	80.1	98.5	80.6	97.2	94.3	90.7

2.3 对比现有先进模型

在本节中,将NEPS与几种先进的ADA方法进行了比较,包括AADA^[30]、Ac-DA^[31]、CLUE^[22]、DBAL^[32]、S3VAADA^[33]、TQS^[23]、EADA^[24]和TL-ADA^[34]。

AADA^[30]使用鉴别器进行样本选择和领域对齐。Ac-DA^[31]使用瓦瑟斯坦距离对齐源域和目标域,并用批评函数选择候选样本。CLUE^[22]利用不确定性加权聚类来选择要注释的实例。DBAL^[32]采用了基于局部差异的主动学习方法来选择实例进行注释。S3VAADA^[33]则使用基于集合的信息性标准来选择候选样本进行标记。TQS^[23]通过采用具有不确定性和领域相似性的委员会方案实现领域漂移下的候选样本选择。Xie等^[24]使用一种称为EADA的基于能量的方法来选择主动领域自适应中的关键样本。TL-ADA^[34]方法则引入基于领域类型及标签信息的序贯学习方法来主动选择候选样本。本文通过运行公开的代码或者自行研究复现了大多数方法,并试图重现原始论文中报告的结果,实验结果如表3~5所示,各种方法的查询预算为5%。

根据表3~5的结果,在仅有5%的查询预算下,

NEPS几乎在所有的迁移任务中优于其他ADA方法。具体而言,本文算法相对于EADA(即最先进的

ADA方法)在不同数据集上的性能改进约为0.3~1.1个百分点。

表3 Office-Home数据集上的分类准确率比较
Table 3 Classification accuracy on Office-Home dataset for various active methods

算法	Ar \Rightarrow Cl	Ar \Rightarrow Pr	Ar \Rightarrow Rw	Cl \Rightarrow Ar	Cl \Rightarrow Pr	Cl \Rightarrow Rw	Pr \Rightarrow Ar	Pr \Rightarrow Cl	Pr \Rightarrow Rw	Rw \Rightarrow Ar	Rw \Rightarrow Cl	Rw \Rightarrow Pr	Avg.
AADA	56.6	78.1	79.0	58.5	73.7	71.0	60.1	53.1	77.0	70.6	57.0	84.5	68.3
Ac-DA	57.2	75.9	76.9	61.3	76.4	73.4	59.4	56.7	77.8	74.1	62.4	84.7	69.7
CLUE	58.0	79.3	80.9	68.8	77.5	76.7	66.3	57.9	81.4	75.6	60.8	86.3	72.5
DBAL	58.7	77.3	79.2	61.7	73.8	73.3	62.6	54.5	78.1	72.4	59.9	84.3	69.6
S3VAADA	57.3	73.9	76.6	60.3	76.5	71.1	57.6	56.0	78.7	71.4	63.1	83.3	68.8
TQS	58.6	81.1	81.5	61.1	76.1	73.3	61.2	54.7	79.7	73.4	58.9	86.1	70.5
EADA	63.6	84.4	83.5	70.7	83.7	80.5	73.0	63.5	85.2	78.4	65.4	88.6	76.7
TL-ADA	63.7	83.9	82.5	69.7	82.7	81.4	70.3	61.2	84.6	77.4	63.4	85.9	75.6
NEPS	63.9	85.1	85.3	72.9	84.2	82.3	74.5	63.0	85.3	78.0	65.5	88.5	77.4

表4 Image-CLEF数据集上的分类准确率比较
Table 4 Classification accuracy on Image-CLEF dataset for various active methods

算法	C \Rightarrow I	C \Rightarrow P	I \Rightarrow C	I \Rightarrow P	P \Rightarrow C	P \Rightarrow I	Avg.
AADA	91.5	79.2	95.3	78.1	92.8	90.3	87.9
Ac-DA	90.5	75.2	93.1	77.4	91.8	90.2	86.4
CLUE	91.3	76.1	94.6	78.6	91.8	90.1	87.1
DBAL	91.0	76.5	94.1	78.4	92.1	90.2	87.0
S3VAADA	92.4	76.3	96.8	79.1	94.0	91.3	88.3
TQS	92.0	76.3	97.0	78.6	93.8	90.2	88.0
EADA	93.3	78.5	97.5	80.2	96.2	92.0	89.6
TL-ADA	92.5	77.6	96.8	79.3	94.7	91.2	88.7
NEPS	93.6	80.1	98.5	80.6	97.2	94.3	90.7

表5 Office-31数据集上的分类准确率比较
Table 5 Classification accuracy on Office-31 dataset for various methods

算法	A \Rightarrow D	A \Rightarrow W	D \Rightarrow A	D \Rightarrow W	W \Rightarrow A	W \Rightarrow D	Avg.
AADA	89.2	87.3	78.2	99.5	78.7	100.0	88.8
Ac-DA	88.0	87.5	77.4	98.4	79.2	98.9	88.2
CLUE	88.1	91.4	76.1	100.0	76.1	98.6	88.4
DBAL	88.2	88.9	75.2	99.4	77.0	100.0	88.1
S3VAADA	93.0	93.7	75.9	99.4	78.2	100.0	90.0
TQS	92.2	92.8	80.4	100.0	80.6	100.0	91.0
EADA	97.7	96.6	82.1	100.0	82.8	100.0	93.2
TL-ADA	96.6	96.8	79.9	99.8	81.7	99.8	92.2
NEPS	97.3	97.0	83.1	100.0	84.0	99.8	93.5

图2展示了本文方法与其他主动领域自适应方法在Office-Home数据集的Cl \Rightarrow Ar迁移任务中使用不同查询预算的结果。从图中可以看出,随着预算的增长,模型性能越来越好,其中NEPS的表现总是优于其他模型。当预算达到5%时,与最先进的EADA相比,NEPS的性能提高了2.2个百分点。

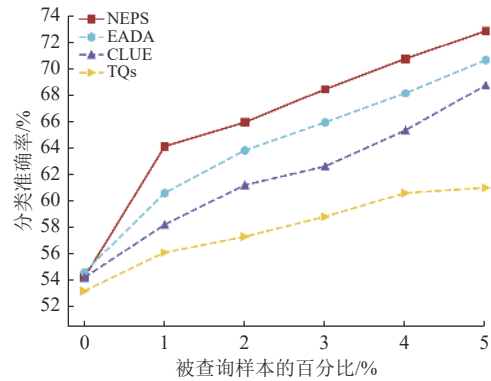


图2 在Office-Home数据集的Cl \Rightarrow Ar任务中,在不同的标注预算下NEPS与其他方法的结果对比

Fig.2 The comparison between our method NEPS and other ADA methods on the Cl \Rightarrow Ar task of the Office-Home dataset, by using increasing percentages of labeling budget

此外,本文还在传统的主动学习背景下,在没有领域适应的情况下,对CIFAR-10数据集进行了测试,并将其与一些基于AL的方法进行了比较,包括Random、BvSB^[35]、Coreset^[17]、WAAL^[20]和CDAL^[36]。每一轮查询后的结果如表6所示,从中可以看出NEPS与基于AL的先进方法相比具有一定竞争力。值得注意的是,当只使用10%的标注预算时,NEPS明显优于其他方法,然而随着预算的增加,这种优势逐渐减小,这表明本文方法具有强大的样本选择能力,因为它在最开始的几轮中已经选择了信息量较高的样本,即价值较高的样本。

最后,为了展示NEPS方法选择样本的特征,本文使用t-SNE^[37]展示了模型所挑选样本的分布。图3展示了在Office-Home数据集中,NEPS选择标注的候选样本分布,红色点表示被选择的样本。

从图中可以看出,NEPS选择的样本均分布在具

有不明显分离边界的簇中,并且散布在各个不同的簇中,证明了被挑选的样本的信息性和多样性。

表6 使用不同标注预算在CIFAR-10数据集上与传统AL设置下的其他方法进行比较

Table 6 Comparison with other methods under traditional AL setting on the CIFAR-10 dataset, while using different labeling budgets %

算法	10%	15%	20%	25%	30%
Random	68.0	72.4	75.1	76.3	78.0
BvSB	68.7	72.7	74.9	76.7	78.5
Core-set	69.0	72.8	74.7	77.0	78.7
WAAL	68.9	73.0	75.4	76.9	78.4
CDAL	61.7	72.6	75.2	78.0	80.4
NEPS	71.6	74.4	76.8	78.5	81.1




图3 在Office-Home数据集的 $R_w \Rightarrow C_I$ 任务中,NEPS分类结果的t-SNE可视化展示

Fig.3 Visualization of the classification results with t-SNE of sampling using NEPAS on the task of $R_w \Rightarrow C_I$ in Office-Home dataset.

2.4 参数设置及收敛性分析

为了进一步分析本文所提算法的稳定性,下面将从算法对超参数的敏感程度以及算法训练过程中的收敛情况两方面对算法进行分析。该部分实验在Image-CLEF数据集的 $C \Rightarrow P$ 任务以及Office-31数据集的 $W \Rightarrow A$ 任务上进行。

本文针对NEPS算法中所使用的参数 α 、 β 、 γ 进行了敏感度分析,观察其对模型性能的影响。在固定其他参数不变的情况下,参数 α 从0.001变化到10时,NEPS在目标领域上的分类准确率的变化情况如图4所示。 α 是用于控制样本不确定性和目标域接近度的平衡参数,可以观察到,当 α 从0.001变化到10时,算法在目标领域上的分类准确率呈现先升高后降低的趋势,当 α 在[0.05, 0.5]范围内时,算法的分类准确率达到到了最优水平。因此,选择合适的参数 α 可以提高NEPS算法在目标领域上的分类准确率。在本文对 α 取值为0.1。




图4 参数 α 的敏感度曲线

Fig.4 Sensitivity curve of parameter α

参数 β 用于平衡单个数据点的信息得分和样本邻居环境的信息得分,在NEPS算法中起到重要作用。固定其他参数不变,观察参数 β 从0.0到1.0变化时,本文所提算法在目标域上的分类准确率变化情况如图5所示。可以观察到,在 β 接近于0或接近于1时,分类表现都有所降低。然而,在范围[0.3, 0.7]内,模型取得了较优的分类准确率。这一结果表明参数 β 的选择对于模型性能较为重要,适当的 β 值有助于提高算法的分类准确率。本文对 β 取值为0.6。

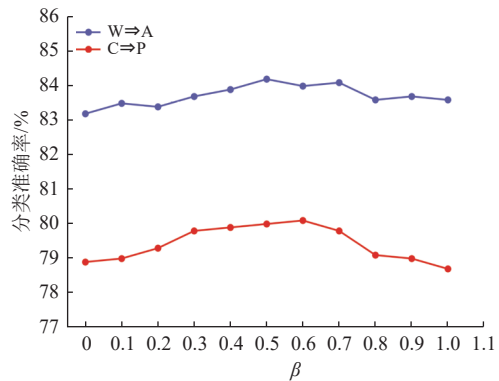


图5 参数 β 的敏感度曲线

Fig.5 Sensitivity curve of parameter β

参数 γ 是用于初步筛选具有高NAIS值样本的阈值。固定其他参数不变,观察参数 γ 从1到20变化时,算法在目标域上分类准确率的变化情况,具体如图6所示。当 $\gamma=1$ 时,模型的效果较差。这是因为当 $\gamma=1$ 时,模型仅依靠样本的信息性来选择样本,而忽略了样本的多样性。相反,当 γ 值达到15后,模型的效果开始下降。这是由于此时模型过度偏向选择多样性高的样本,而忽略了样本的信息性。经过实验研究,本文发现当 γ 取值为5~10范围内时,模型能够更好地平衡样本的信息性和多样性,从而达到更好的效果。其中本文对 γ 取值为5。




图6 参数 γ 的敏感度曲线
Fig.6 Sensitivity curve of parameter γ

此外,为了研究NEPS算法训练过程中的收敛情况,本文对目标域上的分类准确率随着训练轮数从0增加到100时的变化进行了详细分析,具体结果可参见图7。其中,前30轮为模型的预训练过程,30~45轮为模型通过主动学习查询样本以更新模型知识的过程,45轮之后则是模型迭代训练直至收敛的过程。值得注意的是,在20~30轮的训练后,模型的准确率不再显著提升,进入了收敛状态。这是因为前30轮被用作模型的预训练阶段,此时尚未进行样本查询以更新模型知识。随着迭代次数达到30~45轮,模型开始通过主动学习查询样本的方式更新模型知识,从而使分类准确率逐渐提升。在第45轮之后,模型查询预算用尽,开始进行迭代训练直至收敛。值得一提的是,后续的迭代过程中,模型的性能波动较小,在第65轮之后即接近收敛状态,这表明所提出的算法具有良好的稳定性和较快的收敛速度。




图7 准确率收敛曲线
Fig.7 Accuracy convergence curve

2.5 算法时间复杂度

表7显示了NEPS和其他方法在Office-Home数据集 $Ar \Rightarrow Cl$ 任务上平均情况下的复杂度和每轮主动学习查询时间。表中 M 、 N 分别表示源实例数量和目标

实例数量, D 表示特征维度, B 是标记预算, T 表示聚类轮数。

表7 查询复杂度和查询时间的比较结果

Table 7 The comparison results on query complexity and query time

算法	Query Complexity	Query Time/s (Office-Home, $Ar \Rightarrow Cl$)
AADA	$O(N \log N)$	0.03
Ac-DA	$O(N \log N)$	0.03
CLUE	$O(DN(N+TB))$	0.5
DBAL	$O(DN(M+N))$	0.4
S3VAADA	$O(N^2)$	0.1
TQS	$O(N \log N)$	0.04
EADA	$O(N \log N)$	0.02
TL-ADA	$O(N \log N)$	0.03
NEPS	$O(DN^2)$	0.4

其中NEPS和CLUE在达到最佳准确率时由于需要进行CPU聚类步骤而运行较慢。NEPS可以通过使用GPU加速或者在聚类之前对数据进行预过滤来进一步优化。

3 结论

本文针对当前主动领域自适应中存在的问题,提出了一种简单而有效的主动领域自适应方法,称为邻居环境感知样本选择。首先,开发了一种新颖的信息性计算准则,使用邻居环境感知分数来评估样本的信息量。其同时考虑样本的个体信息和其周围的邻居样本信息,确保选取的样本具有高度信息性。其次,本算法通过衡量样本与已选样本集合的相似度,来确保所选样本的多样性。最后,为进一步提高模型的性能,本算法通过数据增强充分利用少量的已标记目标域样本,使用伪标签对剩余的未标记目标数据进行注释并将其加入训练过程。通过在多个数据集上进行实验,证明了本文所提方法的有效性。

本算法主要适用于源域和目标域之间存在数据分布差异,但类别或任务相似,并且在目标数据集上有少量标签可用的情况。本文算法虽然相较于其他主动领域自适应算法有一定的改进,但仍有不足之处。例如,本文算法主要依赖于样本的信息,因此在样本噪声较多的情况下,算法性能可能会受到影响。为了解决这个问题,在未来的工作中将探索如何利用样本特征空间中的分布信息来提升算法鲁棒性。最后,本文只研究了图像分类的任务,在未来希望将NEPS方法应用于其他任务,如语义分割和目标检测等。

参考文献:

- [1] 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.
- [2] 杨国庆, 郭本华, 钱淑渠, 等. 基于伪标签的无监督领域自适应分类方法[J]. *计算机应用研究*, 2022, 39(5): 1357-1361.
YANG G Q, GUO B H, QIAN S Q, *et al.* Pseudo label based unsupervised domain adaptation classification method [J]. *Application Research of Computers*, 2022, 39(5): 1357-1361.
- [3] 李晶晶, 孟利超, 张可, 等. 领域自适应研究综述[J]. *计算机工程*, 2021, 47(6): 1-13.
LI J J, MENG L C, ZHANG K, *et al.* Review of studies on domain adaptation [J]. *Computer Engineering*, 2021, 47(6): 1-13.
- [4] CHEN X K, SHAO H D, XIAO Y M, *et al.* Collaborative fault diagnosis of rotating machinery via dual adversarial guided unsupervised multi-domain adaptation network [J]. *Mechanical Systems and Signal Processing*, 2023, 198: 110427.
- [5] TZENG E, HOFFMAN J, ZHANG N, *et al.* Deep domain confusion: maximizing for domain invariance [EB/OL]. arXiv: 1412.3474 (2014-12-10)[2024-03-13]. <https://doi.org/10.48550/arXiv.1412.3474>.
- [6] HOFFMAN J, TZENG E, PARK T, *et al.* Cycada: cycle-consistent adversarial domain adaptation [C]//International Conference on Machine Learning (ICML). Stockholm: ACM, 2018: 1989-1998.
- [7] TSAI Y H, HUNG W C, SCHULTER S, *et al.* Learning to adapt structured output space for semantic segmentation [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Salt Lake City: IEEE, 2018: 7472-7481.
- [8] ZHAO H, DES COMBES R T, ZHANG K, *et al.* On learning invariant representations for domain adaptation [C]//International Conference on Machine Learning (ICML). California: ACM, 2019: 7523-7532.
- [9] 包震伟, 刘丹, 米金鹏. 弱监督与少样本学习场景下视频行为识别综述[J]. *计算机应用研究*, 2023, 40(6): 1629-1635.
BAO Z W, LIU D, MI J P. Review of video action recognition under weak supervision and few-shot learning [J]. *Application Research of Computers*, 2023, 40(6): 1629-1635.
- [10] SAITO K, KIM D, SCLAROFF S, *et al.* Semi-supervised domain adaptation via minimax entropy [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). Seoul: IEEE, 2019: 8050-8058.
- [11] 潘雪玲, 李国和, 郑艺峰. 面向深度网络的小样本学习综述[J]. *计算机应用研究*, 2023, 40(10): 2881-2888.
PAN X L, LI G H, ZHENG Y F. Survey on few-shot learning for deep network [J]. *Application Research of Computers*, 2023, 40(10): 2881-2888.
- [12] TESHIMA T, SATO I, SUGIYAMA M. Few-shot domain adaptation by causal mechanism transfer [C]//International Conference on Machine Learning (ICML). Vienna: ACM, 2020: 9458-9469.
- [13] 王月, 杨春宇, 郭鑫平, 等. 深度子领域迁移学习: 一种细粒度主动迁移视角[J]. *南京理工大学学报*, 2023, 47(1): 90-102.
WANG Y, YANG C Y, GUO X P, *et al.* Deep subdomain transfer learning: a fine-grained active transfer perspective [J]. *Journal of Nanjing University of Science And Technology*, 2023, 47(1): 90-102.
- [14] WANG D, SHANG Y. A new active labeling method for deep learning [C]//International Joint Conference on Neural Networks (IJCNN). Beijing: IEEE, 2014: 112-119.
- [15] LEWIS D D, CATLETT J. Heterogeneous uncertainty sampling for supervised learning [C]//Machine learning proceedings 1994. New Jersey: Morgan Kaufmann, 1994: 148-156.
- [16] GAL Y, ISLAM R, GHAHRAMANI Z. Deep bayesian active learning with image data [C]//International Conference on Machine Learning (ICML). Sydney: ACM, 2017: 1183-1192.
- [17] SENER O, SAVARESE S. Active learning for convolutional neural networks: a core-set approach [EB/OL]. arXiv: 1708.00489 (2018-06-01)[2024-03-13]. <https://doi.org/10.48550/arXiv.1708.00489>.
- [18] ZHDANOV F. Diverse mini-batch active learning [EB/OL]. arXiv: 1901.05954 (2019-01-17)[2024-03-13]. <https://doi.org/10.48550/arXiv.1901.05954>.
- [19] ASH J T, ZHANG C, KRISHNAMURTHY A, *et al.* Deep batch active learning by diverse, uncertain gradient lower bounds [EB/OL]. arXiv: 1906.03671 (2020-02-24)[2024-03-13]. <https://doi.org/10.48550/arXiv.1906.03671>.
- [20] SHUI C J, ZHOU F, GAGNE C, *et al.* Deep active learning: unified and principled method for query and training [C]//International Conference on Artificial Intelligence and Statistics (ICAIS). Hohhot: LNCS, 2020: 1308-1318.
- [21] RAI P, SAHA A, DAUME III H, *et al.* Domain adaptation meets active learning [C]//Proceedings of the NAACL HLT 2010 Workshop on Active Learning for Natural Language Processing. California: ACL, 2010: 27-32.
- [22] PRABHU V, CHANDRASEKARAN A, SAENKO K, *et al.* Active domain adaptation via clustering uncertainty-weighted embeddings [C]// Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). Montreal: IEEE, 2021: 8505-8514.
- [23] FU B, CAO Z J, WANG J M, *et al.* Transferable query selection for active domain adaptation [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Re-

- cognition (CVPR) . Kuala Lumpur: IEEE, 2021: 7272-7281.
- [24] XIE B H, YUAN L H, LI S, *et al.* Active learning for domain adaptation: an energy-based approach [C]//Proceedings of the AAAI Conference on Artificial Intelligence. Vancouver: AAAI, 2022: 8708-8716.
- [25] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, *et al.* Generative adversarial nets [C]//Advances in Neural Information Processing Systems (NIPS) . Montreal: MIT Press, 2014.
- [26] VENKATESWARA H, EUSEBIO J, CHAKRABORTY S, *et al.* Deep hashing network for unsupervised domain adaptation [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR) . Hawaii: IEEE, 2017: 5018-5027.
- [27] SAENKO K, KULIS B, FRITZ M, *et al.* Adapting visual category models to new domains [C]//European Conference on Computer Vision (ECCV) . Hersonissos: Springer, 2010, 213-226.
- [28] BARBARA C. The imageclef-da challenge 2014 [EB/OL]. (2014-09-18)[2024-03-13]. <https://www.imageclef.org/2014/>.
- [29] KRIZHEVSKY A, HINTON G. Learning multiple layers of features from tiny images [EB/OL]. (2009-04-08) [2024-03-13]. <http://www.cs.utoronto.ca/~kriz/learning-features-2009-TR>.
- [30] SU J C, TSAI Y H, SOHN K, *et al.* Active adversarial domain adaptation [C]//Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision (WACV) . Colorado: IEEE, 2020: 739-748.
- [31] ZHOU F, SHUI C J, YANG S C, *et al.* Discriminative active learning for domain adaptation [J]. Knowledge Based Systems, 2021, 222: 106986.
- [32] DE MATHELIN A, DEHEEGER F, MOUGEOT M, *et al.* Discrepancy-based active learning for domain adaptation [EB/OL]. arXiv: 2103.03757 (2022-09-14)[2024-03-13]. <https://doi.org/10.48550/arXiv.2103.03757>.
- [33] RANGWANI H, JAIN A, AITHAL S K, *et al.* S³VAADA: submodular subset selection for virtual adversarial active domain adaptation [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV) . Montreal: IEEE, 2021: 7516-7525.
- [34] HAN K, KIM Y, HAN D, *et al.* TL-ADA: transferable Loss-based active domain adaptation [J]. Neural Networks, 2023, 161: 670-681.
- [35] JOSHI A J, PORIKLI F, PAPANIKOLOPOULOS N. Multi-class active learning for image classification [C]//2009 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) . Miami: IEEE, 2009: 2372-2379.
- [36] AGARWAL S, ARORA H, ANAND S, *et al.* Contextual diversity for active learning [C]//European Conference on Computer Vision (ECCV) . Glasgow: Springer, 2020: 137-153.
- [37] VAN DER MAATEN L, HINTON G. Visualizing data using tsne [J]. Journal of Machine Learning Research, 2008, 9(11): 2579-2605.

(责任编辑: 张玮欣 英文审核: 熊荣斌)