

一种基于损失预测的双主动域适应算法研究

刘贵松^{1),2),3)} 郑余²⁾ 解修蕊²⁾ 黄鹂¹⁾ 丁浩伦²⁾

¹⁾(西南财经大学 计算机与人工智能学院, 成都 611130)

²⁾(电子科技大学 计算机科学与工程学院, 成都 611731)

³⁾(电子科技大学 中山学院, 广东 中山 528400)

摘 要 近年来深度学习在图像分类任务上取得了显著效果,但通常要求大量人工标记数据,模型训练成本很高。因此,领域自适应等小样本学习方法成为当前研究热点。通常,域适应方法利用源域的经验知识也仅能一定程度降低对目标域标记数据的依赖,因此可以引入主动学习方法对样本价值进行评估并做筛选,从而进一步降低标记成本。本文将典型样本价值估计模型引入域适应学习,结合特征迁移思路,提出了双主动域适应学习算法 D_AcT (Dual active domain adaptation)。该算法同时对源域与目标域数据进行价值度量,并挑选最具训练价值的样本,在保证模型精度的前提下,大幅度减少了模型对标签数据的需求。具体而言,首先利用极大极小熵和核心集采样方法,用主动学习价值评估模型挑选目标域样本,得到单主动域适应算法 S_AcT (Single active domain adaptation)。随后利用损失预测策略,将价值评估策略适配至源域,进一步提升迁移学习知识复用有效性,降低模型训练成本。本文在常用的四个图像迁移数据集进行了测试,将所提两个算法和传统主动迁移学习及半监督迁移学习算法进行了实验对比。结果表明双主动域适应方法所需标记源域数据可减少 50%以上,且准确率较传统方法最大提升了 4%。系列实验验证了本文所提方法的可行性和有效性。

关键词 小样本学习; 图像分类; 主动学习; 迁移学习; 双主动域适应
中图法分类号 TP18

A dual active domain adaptation algorithm based on loss prediction strategy

Guisong Liu¹⁾²⁾³⁾ Yu Zheng²⁾ Xiurui Xie²⁾ Li Huang¹⁾ Haolun Ding²⁾

¹⁾(School of computing and artificial intelligence, Southwestern University of Finance and Economics, Chengdu, 611130)

²⁾(School of Computer Science and Engineering, University of Electronic Science and Technology of China, Chengdu, 611731)

³⁾(Zhongshan Institute, University of Electronic Science and Technology of China, Zhongshan, Guangdong, 528400)

Abstract Deep learning has made remarkable achievements in image classification tasks and various applications in recent years. However, most of the deep learning models require a large amount of labeled data in the training process because of deep structures and numerous parameters. This results in a high labeling cost in deep learning model training. To address this issue, various few-shot learning strategies have been proposed and attracted much attention recently. In which, the domain adaptation and active learning are two of the most widely studied methods. The concept of domain adaptation is to use the empirical knowledge in source domains to reduce the label requirement in target domains, while the active learning reduces labeling cost by evaluating the valuable unlabeled samples for the current model to avoid redundant labeling. Although there are a lot of

本课题得到国家自然科学基金(No. 61806040)、广东省自然科学基金(No. 2021A1515011866)、中山市科技局基金项目(No. 420S36)资助。刘贵松,博士,教授,主要研究领域为人工智能、深度学习、图像处理。E-mail: gliu@swufe.edu.cn。郑余,硕士,主要研究领域为深度学习、主动学习与迁移学习。E-mail: zhengyu_dlm@163.com。解修蕊(通信作者),博士,副研究员,主要研究领域为人工智能、小样本学习、类脑计算。E-mail: xiexiurui@uestc.edu.cn。黄鹂,博士,讲师,主要研究领域为人工智能、深度学习、自然语言处理。E-mail: lihuang@std.uestc.edu.cn。丁浩伦,硕士,主要研究领域为深度学习、图像处理。E-mail: 348078890@qq.com。

achievements in both of domain adaptation and active learning fields that demonstrate their effect in reducing deep learning training cost, but most of the existing methods are only focus on one field. To further reduce the labeling cost and leverage the advantage of both knowledge reusing and sample evaluating, we propose a Dual Active Domain Adaptation (D_AcT) algorithm in this paper. It is motivated by the phenomenon that not all source domain samples are useful in the knowledge transfer learning. In the D_AcT algorithm, the domain adaptation learning is combined with a typical sample value estimation model to filter the redundant or even opposite-effect samples. The algorithm simultaneously measures the value of the source and target data to select the most valuable samples for training, which further reduce the labeling cost. Specifically, we first propose a Single Active Domain Adaptation (S_AcT) algorithm to select the target domain samples. It uses active learning strategy that combines the Minimax Entropy (MME) and the core set model. The Minimax Entropy is used to train feature extractors by minimizing a cross entropy loss on source and target domain samples. The core set model is constructed based on the feature selection diversity. Then, the D_AcT algorithm is proposed by using a loss prediction module. It minimizes the difference between the predicted and actual loss to further enhance the effectiveness of source knowledge reusing and reduce the model training cost. To evaluate the performance of the proposed methods, we conduct comprehensive experiments that compare our method with the existing active transfer learning and semi-supervised transfer learning algorithms. The proposed methods are tested on four commonly used transfer learning image datasets including the Office31, the Mixed National Institute of Standards and Technology database (MNIST), the Street View House Number (SVHN) and the SubDomainNet. The experimental results show that the S_AcT method improves the accuracy up to 3.8% compared with the conventional active transfer learning methods and up to 1.6% compared with semi-supervised transfer learning method. The proposed D_AcT method reduces the source domain labels by more than 50% and improve the accuracy by up to 4% compared with the existing active transfer learning methods, which demonstrates the superiority and effectiveness of the proposed methods.

Key words few-shot learning; image classification; active learning; transfer learning; dual active domain adaptation

1 引言

大数据技术飞速发展, 图像分类任务中海量样本的获取变得非常容易。但这些样本绝大多数未经标记, 无法直接用于全监督模型的训练。标记样本代价极高, 需要大量人力成本, 并且标记的精确性也缺乏保障。因此, 如何在样本有限的情况下提升图像分类的准确率是一个值得研究的问题。

迁移学习是解决样本标记不足问题的常用方法之一, 其核心原理是由源域学习知识, 再迁移到不同但相关的目标域中。其中, 源域是指有大量样本标记和丰富知识的领域, 具备可迁移性。目标域是指最终要学习知识, 赋予标记的对象。在迁移学习研究中, 域适应 DA (Domain Adaptation)^{[1]-[4]}是最为热门的方向之一, 即源域和目标域共享一致类别, 但是特征分布有所不同。DA 方法主要包括无

监督域适应 UDA (Unsupervised Domain Adaptation)^{[5]-[9]} 和半监督域适应 SSDA (Semi-supervised Domain Adaptation)^{[10]-[13]} 两类。UDA 方法一般通过优化源域和目标域之间的差异性来对齐特征空间。多数 UDA 方法虽然取得了良好的泛化性能, 但没有考虑来自目标域的样本信息, 所以性能上往往落后于有监督的 DA 方法^{[14],[15]}。与 UDA 相比, SSDA 可利用小部分目标域标记样本信息, 满足小样本学习的条件。但 SSDA 方法通常对目标域提供的标记样本要求较高, 比如需要训练集的每个类别都提供一定数量的标记样本, 不太符合实际应用需求。

主动学习方法也是降低模型对标签高度依赖的方法之一。它通过有效评价样本训练价值, 选择价值高的样本来降低标签的需求, 其基本过程参见图 1。首先, 通过设计一种算法在未标记样本中查

询价值高的样本并由专家进行标记,再利用标记样本训练分类器从而提高模型精度。目前主动学习通常分为基于池的查询获取和查询合成两种方法^[16]。查询获取方法^{[17]-[19]}基于设计的查询规则来选择价值高的样本数据。其中,多样性^{[20]-[23]}和不确定性^{[24]-[29]}是最为常用的两种查询规则。前者是指查询所挑选出的样本能提供全面信息又兼具一定的差异性,后者是指在当前分类器下最不能确定其分类的样本。衡量不确定度的方式主要包括最小可信度^[30],间隔法^[31]和熵方法^[32]。查询合成方法则是合成有利于模型训练的样本数据,以此提升模型性能,代表方法如生成式对抗网络 GAN (Generative Adversarial Networks)^[33]等。虽然主动学习方法在一定程度上已经减少了标记数量,但要达到高准确率目标,对标记样本的需求仍然较大,这并不符合小样本学习的条件。

主动迁移学习结合了主动学习和迁移学习两者的优点,在解决标记样本不足问题上,相比单一策略更加有效。一方面,主动学习可以借助迁移学习源域中大量的已知标记训练分类器,克服对标记样本的高需求问题;另一方面,迁移学习可以通过主动学习来为目标域挑选高价值未知样本进行标记,克服域适应方法缺乏目标域样本信息或对标记样本的高要求问题。然而,目前的主动迁移学习算法^{[34]-[39]}在小样本条件下还处于研究初始阶段,由于源域和目标域数据分布差异导致的性能提升和负迁移问题^{[40],[41]}仍有待解决。




图1 主动学习主要过程

本文提出了一种同时将源域与目标域数据进行价值度量的双主动域适应学习算法以解决上述问题。首先利用极大极小熵 MME (Minimax Entropy) 和核心集采样等策略,将主动学习价值评估模型引入域适应目标域,得到单主动域适应策略。随后利用损失预测策略,将价值评估策略适配到迁移学习源域中,进一步对源域样本进行筛选以

提升迁移学习知识复用有效性,降低模型训练代价,解决负迁移问题。其中, MME 作为一种 SSDA 方法,通过标记的源域样本和目标域样本构造标准交叉熵,来训练特征提取器和分类器进行正确地分类。同时,通过最小化目标将未知标记目标域样本特征聚集在估计原型(一个由源域变化到目标域的分类特征代表)附近,以此来获取目标域的判别性特征,参见图 2。核心集采样作为一种利用特征选取多种分类的多样性主动学习方法,在本质思想上与 MME 一致,如图 3 所示,所以基于两者的单主动域适应可完成对目标域样本的挑选。损失预测策略则以挑选的目标域样本为基础,训练一个接近目标域的分类模型,通过此分类模型筛选出损失预测损失值较小的源域样本,即分布接近目标域的源域样本,以解决负迁移问题。

然而,原 MME 方法是基于直推式学习进行的,即学习过程中考虑的未标记样本恰是待预测样本,仅能在已有的未标记样本上获得最佳性能。这种基于理想情况下的算法泛化性较差。为解决此问题,本文将直推式半监督推广为纯半监督,即学习过程中使用到的未标记样本不仅是待预测样本。




图2 聚集在估计原型附近的未知标记样




图3 多样性主动学习

本文的主要贡献如下:

(1) 提出一种单主动域适应方法,结合迁移学习和主动学习优势,实现样本价值估计策略在目标域数据集上的有效应用。

(2) 在(1)基础上,提出在源域和目标域上同时进行样本价值估计的双主动域适应算法,在保持甚

至提升性能基础上降低源域样本需求量,且在一定程度上消除了负迁移影响。

(3) 将原 MME 方法的直推式学习推广为纯半监督学习,使算法具有更强的泛化性。

2 相关工作

目前,主动迁移学习在国内外的研究相对较少。国际方面,2011年,Rai等人^[35]提出了一种主动域适应 ALDA (Active Learning Domain Adapted) 方法,该方法可训练三个模型:源分类器,域自适应分类器和域分隔器,使目标域实现了利用源域不同但相关知识来进行主动学习并在文本和图像分类中十分有效。2019年,Jong-Chyi Su等人^[38]提出了一种域适应和通过对抗性训练的主动学习的统一架构 AADA (Active Adversarial Domain Adaptation),该工作提出的主动学习的鉴别器不仅有助于样品的选择,还可以对抗性地训练识别模型从而减少域差距。2020年,Prabhu V等人^[39]提出了一种基于聚类不确定加权嵌入的主动域自适应算法 ADA-CLUE (Active Domain Adaptation via Clustering Uncertainty-weighted Embeddings),实现了基于主动学习的标记目标域与源域样本的域对齐。国内方面,2008年,任江涛等人^[34]第一次提出迁移学习和主动学习的结合。该方法提出在源域数据上学习一个分类器,并在一个带标签的目标域数据的初始池上学习另一个分类器。两个分类器都可以预测未标记实例的标签,并根据预测的可靠性查询实例以进行主动标注。2016年,林轩田等人^[36]提出了主动学习经验可以迁移的概念,有效完成了跨数据集传递主动学习经验的任务。2018年,黄圣君等人^[37]提出一种针对深度神经网络的主动学习方法,将预训练好的模型迁移到目标域中,再利用少量高价值性目标域样本数据对模型进行微调,达到降低模型训练成本的目的。但当前的主动迁移学习算法在小样本条件下还处于初始研究阶段,准确率还有待提升并且负迁移问题尚未解决。而本文提出的双主动域适应算法相比传统主动迁移学习算法,在进一步提升准确率的基础上,又实现了源域的有效筛选,一定程度上缓解了负迁移问题。

在域适应方面,2018年龙明盛^[8]等人以及 Rui Shu等人^[9]均提出了有效的 UDA 方法,虽然这些 UDA 方法在未知目标域条件下,泛化性已有明显提升,但性能还是明显低于有监督的域适应方法。2019年,Saito K等人^[10]指出这些 UDA 方法在人为

提供目标域标记样本后,准确率反而会降低。由此可见,传统 UDA 方法和服务于提供标记样本的主动学习方法结合难以达到预期效果。相比 UDA 方法,SSDA 方法考虑了小部分目标域标记样本,因此与主动学习方法的结合是可行的。此外,包括 Saito K等人^[10]以及2020年Prabhu V等人^[39]研究表明,近几年在 SSDA 中,模型熵的最小最大化被证明是一种较为有效方法^[42]。MME^[10]方法则是其中的显著代表,而且 MME 对于目标域提供的标记样本要求是 x -shot (每个类提供 x 个标记样本),这对标记样本的要求非常严格。而本文提出的主动域适应方法可通过主动学习对样本进行自由筛选,灵活地提供每个类别的训练标记样本量,更符合实际应用的需求。

在主动学习方面,近几年提出的方法大部分是基于池的查询获取主动学习方法。2017年至2019年,Ozan Sener等人^[20]以及Samarth Sinha等人^[22]提出了以多样性为采样策略的主动学习方法。Yarin Gal等人^[24]以及Melanie Ducoffe等人^[25]提出了以不确定为采样策略的主动学习方法。此外,Yoo D等人^[17]提出了一种无关于当前任务的主动学习算法用来预测具有高损耗的数据,以此来选出能为当前模型提供更高信息损失的核心集。考虑到与 MME 的融合,所以本文采用 Ozan Sener 等人提出的核心集采样主动学习算法^[20]。这是一种基于特征选取多种分类的多样性主动学习方法,与 MME 非常契合。结合了 MME 的主动域适应算法,可以借助迁移学习源域中大量的已知标记训练分类器,克服传统主动学习对标记样本的高需求问题。

目前的主动迁移学习算法解决小样本条件下的图像分类任务尚有不足,为此,本文提出在源域和目标域上同时进行样本价值估计的双主动域适应算法,以提高源域历史知识的有效迁移,在降低训练成本的基础上,进一步消除负迁移影响。

3 主动域适应算法

本文提出的算法包括单主动域适应算法 S_AcT (Single active domain adaptation) 和双主动域适应算法 D_AcT (Dual active domain adaptation),整体框架如图 4 所示。单主动域适应算法应用于目标域样本的主动挑选,双主动域适应算法在单主动基础上,增加了源域样本上的主动学习模块,同时对两个域的样本进行主动挑选。

本节首先介绍单主动域适应算法 S_AcT,该算

法在目标域上基于核心集采样进行样本价值评估^[20]，结合 MME^[10]迁移思路，实现主动学习和迁移学习算法的有效融合。




图 4 主动域适应算法框架图

随后，在 S_AcT 的基础上提出了双主动域适应算法 D_AcT。算法初始阶段，首先随机挑选部分源域数据训练分类器，再通过 S_AcT 中的单主动策略挑选目标域样本，之后利用损失预测模块，挑选有

价值的源域样本完成一轮循环训练。下一轮循环中，先后交替进行目标域和源域样本的主动挑选，进一步降低训练成本并提高历史知识的有效利用。

3.1 符号说明

本文标号定义如下：源域记为 S ，经由源域主动学习挑选的源域样本集记为 $N(N \in S)$ 。目标域记为 T ，经由目标域主动学习挑选的目标域样本集记为 $T_l(T_l \subseteq T)$ ，未被挑选的目标域样本集记为 T_u ，目标域测试集记作 T_v 。每次最多从目标域中挑选出的样本数量记为 B_l ，从源域中挑选出的样本数量记录为 B_s 。样本数据和标签记录分别为 x 和 y ，标签预测过程记为 (x, y) ，标签分类记作 $y \in (k_1, \dots, k_c)$ ，共 c 个分类。

3.2 单主动域适应算法

算法过程如图 5 所示。首先，在 MME 的域适应模块中获取受目标域影响的特征提取器 F ；然后，以多样性为采样策略的主动学习^[20]依据该特征来选取有代表性的目标域样本并进行标记，将标记好的目标域样本和源域样本输入域适应模块，以此形成循环并完成目标域的有效数据价值评估。




图 5 单主动域适应框架图

有标记的源域样本集与少量有标记的目标域样本集经过多层卷积池化操作后，构造图 5 所示的标准交叉熵 $1(L)$ ，如公式(1)所示。随后，进行熵的最小化处理并以此更新特征提取器 F 。更新后的 F 经过多轮目标域样本训练，可为后续目标域上主动学习提取有效特征。

$$L = \sum_{(x,y) \in L_{ab}} \sum_{i=1}^c (y=i|x) \log P(y=i|x), \quad (1)$$

其中 $L_{ab} = S \cup T_l$ 表示已知标记的源域和目标域样本数总和， c 表示标签的分类总数， $P(y=i|x)$ 表示样本 x 预测为第 i 类的概率。

基于 MME 对于目标域提供的标记样本要求，本文采

用最符合 x -shot 多样性采样策略的主动学习方法。此外，为利用公式(1)提供的特征提取器 F ，算法采用在特征上覆盖多种类别的核心集采样主动学习方法，对应图 5 的主动学习模块。对目标域上的已知标记样本 T_l 与未知样本 T_u 进行特征提取，然后根据特征之间的欧式距离 Δ ，从 T_u 中选取与当前标记集合 T_l 距离最大的未知目标域样本 b ，直至其数量 $|b|$ 达到 B_l 为止，如公式(2)所示。

$$b = \arg \max_{i \in T_u} \min_{j \in T_l} \Delta(X_i, X_j). \quad (2)$$

其中 X_i 和 X_j 为样本 i 和 j 的特征。

完成一轮目标域样本的挑选以及标记后，输入域适应模块进行下一次迭代，并不断更新特征提取器和分类器。随着目标域标记样本不断增多，特征提取器与目标域的相关性也不断增加，主动学习的效果也不断增强。域适应过程除了优化熵 $1(L)$ 外，还需进行图 5 所示的熵 $2(H)$ 最大化操作以更新估计原型，如公式(3)所示，使估计原型向目标域移动，移动过程如图 6。

$$H = - \sum_{(x,y) \in T_u} \sum_{i=1}^c P(y=i|x) \log P(y=i|x). \quad (3)$$




图 6 由源域向目标域转移的估计原型

单主动域适应流程参见算法 1:

算法 1. 单主动域适应算法

输入: 样本数据 $x_i \in x$ ，随机标记目标域样本 T_l ，目标域未知样本 T_u ，所有源域样本 S ，主动学习次数 n ，每次主动选取样本数 B_l ，特征提取器 F ，分类器 C 。
输出: 目标域主动学习最终挑选的标记目标域样本 T_l ，未标记目标域样本 T_u ，已训练好的特征提取器参数 $\hat{\theta}_F$ 和分类器参数 $\hat{\theta}_C$ 。

1. FOR $i=1$ TO n DO
2. $\hat{\theta}_F = \arg \min L + \lambda H$, $\hat{\theta}_C = \arg \min L - \lambda H$
3. $X_l = F(x_l)$, $X_u = F(x_u)$, $T_l = T_l$

4. WHILE $|T_l| < B_l + |T_l|$
5. $b = \arg \max_{i \in T_u} \min_{j \in T_l} \Delta(X_i, X_j)$
6. $T_l = T_l + \{b\}$
7. $T_u = T - T_l$
8. RETURN $T_l, T_u, \hat{\theta}_F, \hat{\theta}_C$

3.3 双主动域适应算法

在单主动域适应算法选择出目标域最具价值的样本集后，本文随后基于此样本集在源域上采用损失预测策略的主动学习方法，以完成对源域样本的筛选，如图 7 所示。

基于损失预测策略的主动学习方法包括两个模块：目标预测模块和损失预测模块。前者包含特征提取层、输出层以及 SoftMax 分类层，用于预测输入的标签，并与实际标签计算实际损失 l 。后者接收目标预测模块所提取的输入特征，经过功能层和全连接层后输出损失预测 $\hat{l}$ ，即对输入样本实际目标损失的预测值。在训练阶段，用损失预测损失值 l_{loss} 衡量损失预测 $\hat{l}$ 与实际目标损失 l 的差距，通过最小化 l_{loss} 训练网络，使得损失预测模块能准确预测实际目标损失。在推理阶段，主动学习方法只接收源域样本及其标签，计算出最终的损失预测损失值 l_{loss} ，并由小到大排序，选取最小的 B_s 个样本，放入挑选的源域样本集 N 中加入下一轮迁移学习训练。通过这种机制，可以挑选出更接近目标域样本分布的源域，减少负迁移问题的出现。各模块的设计细节如下。

目标预测模块方面，训练阶段初始输入为第一轮单主动算法挑选出的标记目标域样本，之后加入本算法所挑选出的新的源域样本，如图 7 所示。目标预测模块中，由多个特征层进行特征提取。每个特征层的输出除传递至下一特征层外，还需传递至损失预测模块作为功能层的输入。本文提出的主动迁移方法不局限于固定结构网络，特征层能够适配多种网络结构类型。模块最后通过输出层和 SoftMax 层对输入的样本进行标签预测，通过预测标签与实际标签计算出实际目标损失：

$$l = L_{\text{target}}(\hat{y}, y) = \sum_{i=1}^n (\hat{y}_i - y_i)^2, \quad (4)$$

其中 n 为标记目标域样本数量 ($n = |T_l|$)， $\hat{y}_i$ 为第 i 个样本预测的标签， y_i 为第 i 个样本的实际标签。




图 7 源域上的主动学习框架

损失预测模块方面，是附加于目标预测模块的一个模型，以目标预测模块的中间层特征为输入，通过多重连接可以在层间选择对损失预测有用的必要信息。为充分利用所有中间层特征信息，且由于中间层特征维度不同，因此采用全连接层 FC (Fully Connected Layers) 连接所有特征信息，并以修正线性单元 ReLU (Rectified Linear Unit) 作为激活函数，输出为固定维特征向量。另外，为避免中间层维度过高导致网络参数过于冗余，在特征信息和 FC 层中间加入全局平均池化层 GAP (Global Average Pooling) 进行降采样。最后拼接所有特征向量，通过另一个 FC 层，计算得到损失预测量值 $\hat{l}$ 。

模型训练方面，包括两个目标：一是使目标预测模块正确预测样本标签，即减小实际目标损失 $l = L_{\text{target}}(\hat{y}, y)$ ；二是使损失预测模块准确预测目标

损失，即减小损失预测损失值 l_{loss} 。由于实际损失的大小会随着目标预测模块的学习而变化（总体上减小），若直接以拟合实际损失 l 为目标，则容易受样本标签预测任务的影响。因此通过比较两个样本的损失预测大小的方式，消除 l 尺度的影响。训练采用批量优化的方式，每个批次包含 B 个参与训练的样本，同时被分为 $B/2$ 个样本数据对 $\{x_p = (x_i, x_j)\}$ 计算 l_{loss} 。训练阶段总损失函数定义为：

$$\text{Loss} = \frac{1}{B} \sum_{(x, y) \in B} L_{\text{target}}(\hat{y}, y) + \lambda l_{\text{loss}}(\hat{l}_p, l_p), \quad (5)$$

$$l_{\text{loss}}(\hat{l}_p, l_p) = \frac{2}{B} \sum_{i=1}^{B/2} (\max(0, -I \cdot (\hat{l}_i - \hat{l}_j) + \varepsilon)), \quad (6)$$

$$I = \begin{cases} +1, l_i > l_j \\ -1, l_i \leq l_j \end{cases},$$

其中， $\hat{l}_p = (\hat{l}_i, \hat{l}_j)$ 为样本对的损失预测， $l_p = (l_i, l_j)$ 为样本对的实际目标损失， $l_{\text{loss}}(\hat{l}_p, l_p)$ 为样本对的损失预测差， λ 为比例常数（设定为 1）。

在推理阶段，即源域样本主动挑选阶段，将数据对上的损失预测损失按照由小到大进行排序，每次选取损失值靠前的 B_s 个源域样本，这样始于源域的估计原型会更接近目标域每个分类的代表特征，如图 8 所示。




图 8 贴近目标域的估计原型

完成第一批主动学习挑选后，此时用于目标预测模块分类器训练的样本数据有两种，一种是单主动域适应挑选出的目标域标记样本，样本数较少；第二种是第一批挑选出的接近目标域分布的源域标记样本，样本数较多。此时，需比较挑选更适用于后续主动学习的样本类别，即训练更为接近目标域分布的分类模型。比较这两种样本数据训练后在目标域验证集上的准确率 acc_t 和 acc_s ，若 $\text{acc}_s > \text{acc}_t$ ，则后续主动挑选源域样本来训练分类模型，反之则选择目标域样本参与训练。以此方式不断优化最终的损失预测损失，再进行源域样本的挑选。

总结双主动域适应流程如算法 2 所示。

算法 2. 双主动域适应算法

输入: 所有目标域样本 T , 所有源域样本 S , 主动学习次数 n , 每次主动选取样本数 B_s , 目标域验证集为 T_v , 目标预测模块 P_t , 损失预测模块 P_l 。

输出: 源域主动学习最终挑选出的标记源域样本 N , 目标域主动学习最终挑选出的标记目标域样本 T_l , 已训练好的目标预测模块 P_t , 已训练好的损失预测模块 P_l

1. $U = \emptyset, N = \emptyset$ //定义空的训练集 U 和标记源域样本集 N
2. $T_l = \text{RandomlySelect}(T)$ //随机挑选第一批目标域样本
3. $U = U + T_l$
4. FOR $i = 1$ TO n DO:
5. $P_t, P_l = \text{Train}(U, P_t, P_l)$ //公式(4-6)
6. $l_{\text{loss}} = \text{Forward}(S, P_t, P_l)$ //公式(6)
7. $S = \text{Sort}(l_{\text{loss}}, S)$ //根据 l_{loss} 从小到对 S 排序
8. $N = N + S[1:B_s]$ //挑选前 B_s 个源域样本
9. $P_t^N, P_l^N = \text{Train}(N, P_t, P_l)$ //在 N 上训练模块
10. $\text{acc}_s = \text{Test}(T_v, P_t^N, P_l^N)$
11. $P_t^{T_l}, P_l^{T_l} = \text{Train}(T_l, P_t, P_l)$ //在 T_l 上训练模块
12. $\text{acc}_t = \text{Test}(T_v, P_t^{T_l}, P_l^{T_l})$
13. IF $\text{acc}_s > \text{acc}_t$ //选取源域样本训练
14. $U = U + N$
15. ELSE //选取目标域样本训练
16. $T_l = T_l + S_{\text{AcT}}(T, B_t)$ //单主动域适应挑选 B_t 个样本
17. $U = U + T_l$
18. ENDFOR
19. RETURN N, T_l, P_t, P_l

4 实验结果与分析

4.1 数据集

Office31^[43] 基准数据集常用于迁移学习图像分类, 包括 3 个不同的真实对象域: 数码单反相机拍摄的图片(DSLR)、电商网站 Amazon.com 的商品展示图片(Amazon)及图像处理软件 Webcam 处理后的图片(Webcam)。每个域都包含 31 个类别, 共 4,652 张图片。

MNIST^[44] (Mixed National Institute of Standards and Technology database) 和 SVHN^[44] (Street View House Number) 常被用于数字识别分类任务。其中, MNIST 数据

集包含 60,000 张训练图片以及 10,000 张测试图片, 图片分辨率为 28×28 。SVHN 数据集为真实街道门牌号码数字, 图片分辨率为 32×32 。

DomainNet 是用于大规模域适应的最新基准数据集之一, 包括有 6 个不同域、60 万张图片, 每个域包含 345 个类别。为了保证实验设置相同, 本文采用 MME^[10] 中的 SubDomainNet 数据集, 包括 4 个不同的域(Real, Sketch, Painting, Clipart), 每个域包括 126 个分类。

4.2 对比实验设置

为验证本文所提出的单主动域适应方法 S_AcT 和双主动域适应方法 D_AcT, 本文选择最近提出的域适应算法 MME*^[10]、主动域适应算法 AADA^[38] 和 ADA_CLUE^[39] 进行对比。

- MME^[10] 和 MME*: MME*^[10] 是一种采用直接熵的极大极小化策略的直推式半监督域适应方法, 在训练过程需要提供目标域中每个分类一定量标记好的样本; MME 则是将 MME* 的直推式训练改为纯半监督训练, 其他与 MME* 保持一致。
- AADA 和 RADA^[38]: AADA 是一种通过 DANN (Domain-adversarial training of Neural Networks) 交替执行主动采样和对抗式域适应训练的主动域适应方法, 实现了在目标域上的主动挑选; RADA (Random Adversarial Domain Adaptation) 则是将 AADA 中的主动学习采样改为随机采样, 其他与 AADA 保持一致。
- ADA_CLUE 和 RDA_CLUE^[39]: 其中 ADA_CLUE^[39] 是一种基于聚类 and 不确定度加权嵌入主动学习的域适应方法, 实现了在目标域上的主动挑选; RDA_CLUE (Active Domain Adaptation via Clustering Uncertainty-weighted Embeddings) 将 ADA_CLUE 中的主动学习采样改为随机采样。
- S_AcT, S_AcT* 和 S_RT: 其中 S_AcT 是本文提出的一种结合 MME 以及核心集主动采样的纯半监督式单主动域适应方法, 实现了在目标域上的主动挑选; S_AcT* 则是将 S_AcT 的纯半监督式训练改为直推式训练, 其他与 S_AcT 保持一致; S_RT (Single domain random adaptation) 将 S_AcT 的主动采样改为随机采样。
- D_AcT 和 R_AcT: 其中 D_AcT 是在 S_AcT 基础上, 在源域中采用损失预测策略进行主动样本挑选的一种双主动域适应方法, 实现了在源域上的主动挑选; R_AcT (Random active domain adaptation) 则是将 D_AcT 中源域上主动挑选改为随机挑选。

训练过程与 MME 保持一致, 使用随机梯度下降优化器训练, 初始学习率 lr 为 0.01, 按照

$lr = lr * (1 + 0.0001 * step)^{-0.75}$ 衰减, 其中动量为 0.9, 权重衰减率为 0.0005。所有对比方法关于源域和目标域样本的使用详情参见表 1, 各实验所用参数参见附录 1。

4.3 实验结果与分析

4.3.1 单主动域适应方法有效性验证及分析

本小节将本文所提单主动域适应方法 S_AcT, 与传统主动迁移学习算法 AADA^[38] 和 ADA_CLUE^[39] 进行有效性对比。同时, 还将二者的原有主动挑选方法替换为了随机挑选方法做进一步分析, 记作 S_RT 和 RADA^[38]。

为保障对比公平, 本实验采用与 AADA^[38] 和 ADA_CLUE^[39] 相同的数据集和骨干网络设置: 从 SVHN 数据集迁移到 MNIST 数据集 (记作 SVHN→MNIST), 使用 LeNet^[45] 网络, 以 60,000 张图片作为训练集, 10,000 张图片作为测试集; 从 DSLR 数据集迁移到 Amazon 数据集, 使用基于主流 CNN (Convolution Neural Network) 之一的 ResNet18^[46] 网络, 训练集和测试集以 2:1 进行划分。S_RT、RADA^[38]、RDA_CLUE^[39] 分别将 S_AcT、AADA、ADA_CLUE^[39] 的主动挑选替换为随机挑

选。为验证所提方法在小样本条件下的效果, 进行了从规模较小的数据集迁移到规模较大的数据集的实验。

实验结果如表 2 所示。在使用相同目标域标记样本量的情况下, 本文提出的 S_AcT 方法的准确率比 AADA 方法的准确率高, 表明了 S_AcT 算法在主动迁移策略上的有效性。S_AcT 算法与 ADA_CLUE 相比则各有优劣, 在 SVHN 到 MNIST 的迁移实验中, ADA_CLUE 的准确率比 S_AcT 高 0.8%; 而在 DSLR 到 Amazon 的迁移中, S_AcT 的准确率比 ADA_CLUE 高出 1.9%。此外, S_RT 与 RADA 和 RDA_CLUE 的对比结果表明, 本文的方法在随机挑选的情况下效果依然比传统方法好, 进而证明了本文方法在迁移学习策略上的有效性。

图 11 和图 12 展示了在使用相同目标域标记样本量的情况下, 不同实验中 S_AcT 方法和 S_RT 方法的训练过程对比, 其中横轴为训练过程中的迭代次数, 纵轴为测试集上的准确率。结果表明 S_AcT 比 S_RT 的训练准确率更高, 验证了本文所提主动策略的有效性。

表 1 各方法的数据使用说明表

方 法	源域样本	有标记的目标域训练集	训练方式
MME ^[10]	全部使用	3-shot ¹	纯半监督式
MME* ^[10]	全部使用	3-shot	直推式
AADA ^[38]	全部使用	主动挑选 ³	-
RADA ^[38]	全部使用	随机挑选	-
S_AcT	全部使用	主动挑选	纯半监督式
S_AcT*	全部使用	主动挑选	直推式
S_RT	全部使用	随机挑选 ²	纯半监督式
R_AcT	随机挑选	主动挑选	纯半监督式
D_AcT	主动挑选	主动挑选	纯半监督式
ADA_CLUE ^[39]	全部使用	主动挑选	-

注: 1. 3-shot: 数据集所提供的随机挑选的每个类 3 张样本;

2. 随机挑选: 训练过程中, 每次迭代随机挑选固定数量样本;

3. 主动挑选: 训练过程中, 每次迭代主动挑选固定数量样本;

表 2 单主动域适应方法 S_AcT 对比结果

方 法	准确率(%)	
	SVHN→MNIST	DSLR→Amazon
RADA ^[38]	81.0	74.8
AADA ^[38]	90.0	76.3
RDA_CLUE ^[39]	89.0	78.2

ADA_CLUE ^[39]	93.3	78.9
S_RT	89.1	78.4
S_AcT	92.5	80.1




图 9 S_AcT, S_RT, AADA 与 RADA 的对比实验结果 (SVHN→MNIST)




图 10 S_AcT, S_RT, AADA, RADA 的对比实验结果 (DSLR→Amazon)




图 11 D_AcT、S_AcT 与 S_RT 的训练过程各批次对比 (SVHN→MNIST)




图 12 S_AcT 与 S_RT 的训练过程各批次对比 (DSLR→Amazon)

图 9 和图 10 展示了随着目标域标记样本量的增加不同算法的准确率变化趋势, 在 MNIST 数据集中每次递增的样本量为 10, 在 Amazon 数据集中每次递增的数据量为 50。很明显, 随着目标域标记样本量递增, 所有模型准确率都稳定提升。此外, 该结果表明在不同训练样本数量情况下, 相比传统方法, 本文所提出的算法都具有更高的准确率。

4.3.2 单主动域适应方法消融实验分析

本小节验证所提纯半监督式单主动域适应方法 S_AcT 是否能达到非主动直推式半监督迁移学习 MME^[10]的准确率。为更全面对比二者效果, 同时测试了直推式 S_AcT* 和纯半监督式 MME^[10]。

实验采用了与 MME^[10]相同的数据集和骨干网络设置。在 SubDomainNet 数据集上多个域之间(Real, Sketch,

Painting, Clipart), 使用 ResNet34^[46]网络结构, 训练集和测试集以 2:1 划分。在本实验对比的各数据集中, 传统直推式 MME^[10]和纯半监督式 MME^[10]方法要求每个类别提供三个训练标记样本, 即 3-shot 策略。而本文通过主动学习对样本进行自由筛选, 不限制每个类别样本数。为了公平对比, 本文方法和传统方法均使用 378 个标记样本。

实验结果如表 3 所示。可以发现, S_AcT 的准确率全部优于 MME, S_AcT* 的准确率同样全部优于 MME*, 结果表明无论在纯半监督学习条件下还是直推式半监督学习条件下, 主动学习挑选的样本均比直接提供的样本更有价值, 更有益于迁移学习。另外, 由于直推式学习封闭性特点, 只考虑在当前数据集上的性能, 通常准确率高于纯半监督学习, 但并不像纯半监督学习具备泛化能力。本实验结果表明纯半监督式 S_AcT 准确率与直推式 MME* 准确率

接近, 说明了所提出的算法在具备泛化性的同时也兼具较高的准确率。

数据样本经过单主动域适应框架中的特征提取器 F 进

行特征提取, 以 Real 数据集中的数据样本为例, 其特征变化过程如图 13 所示。

表 3 单主动域适应方法 S_AcT 的消融实验结果

方 法	准确率(%)			
	Real→Sketch	Sketch→Painting	Painting→Clipart	Clipart→Sketch
MME ^[10]	61.7	65.7	70.9	61.7
S_AcT	62.4	66.5	71.4	62.3
MME ^{*[10]}	62.6	66.4	71.4	63.1
S_AcT*	64.2	66.9	72.8	63.8




图 13 Real 数据样本的特征变化




图 14 在 Sketch 上采用 3-shot 策略(a)以及主动学习策略(b)提供的标记样本分布

在 Sketch 数据集上采用 3-shot 策略以及主动学习策略提供的标记样本分布如图 14 所示。其中不同颜色的子集表示不同的类别, 黑色数字表示对应分类。很明显, 主动学习可为 S_AcT 筛选出均匀覆盖多个类别的样本, 并且相比 MME 的 3-shot 策略, 主动学习可灵活提供每个类别的训练标记样本量, 更符合实际应用需求。

4.3.3 双主动域适应方法有效性验证及分析

本小节将 D_AcT 与传统主动迁移学习方法 AADA^[38]和 ADA_CLUE^[39]对比, 验证算法能否挑选出有益于迁移学习的源域样本及其性能。同时, 还进一步对比了所提

S_AcT 及根据 S_AcT 所改编的随机域适应算法 R_AcT。采用实验数据对包括: 从 Real 数据集迁移到 Sketch 数据集、SVHN 数据集迁移到 MNIST 数据集以及 DSLR 迁移到 Aamaon 数据集。

表 4 展示了各源域参与训练的样本量以及各实验的准确率。在选取相同数量的源域训练样本时, D_AcT 的准确率比 R_AcT 更高, 同样优于使用全部源域训练样本的 S_AcT。结果证明了本文提出的算法可以摒弃冗余无效样本, 实现源域样本的有效筛选, 大幅提升了迁移学习知识复用效果。另

外, 由表 4 可以看出, D_AcT 方法较传统 AADA 和 ADA_CLUE 方法, 可使用少于源域总量训练数据的 50%来进行迁移学习, 并且准确率较 AADA 准确率提升了 4%, 较 ADA_CLUE 准确率提升了 0.7%。此外还可看出 D_AcT 方法效果最为明显的是 SVHN 数据集, 仅选取占比 2.7%的样本参与迁移学习, 但获得了高达 94%的准确率; 其次是 DSLR

数据集。这是因为 SVHN 数据集仅包含 10 个分类, 分类数远远小于其庞大的样本量, 一方面, 用于训练分类模型的所需样本量较少; 另一方面, 存在无效样本的可能性较大, 所以在 SVHN 数据集上效果最好。而 Real 数据集中包含 126 个分类, 样本量相对较少, 所以源域主动提挑选的提升相对其他数据集较小。

表 4 双主动域适应方法 D_AcT 对比结果

方 法	SVHN→MNIST		DSLR→Amazon		Real→Sketch	
	SVHN 训练样本数	准确率(%)	DSLR 训练样本数	准确率(%)	Real 训练样本数	准确率(%)
AADA ^[38]	73,257	90.0	498	76.3	-	-
ADA_CLUE ^[39]	73,257	93.3	498	78.9	-	-
S_AcT	73,257	92.5	498	80.1	70,358	62.4
R_AcT	2,000	91.1	248	78.6	50,400	61.8
D_AcT	2,000	94.0	248	80.5	50,400	62.8

此外, 本文对比了所提出的 S_AcT 方法和 D_AcT 方法与传统主动迁移方法 ADA_CLUE 所需的训练时间, 对比结果参见表 5。可以看出, 本文所提两种方法在训练时间上同样占有优势。结合表 4 的结果, 单主动方法 S_AcT 所需训练时间最短, 但准确率比 ADA_CLUE 略低; 双主动方法 D_AcT 在 S_AcT 的基础上增加了源域主动挑选, 训练时间略增, 但仍优于 ADA_CLUE 方法, 且取得了最高的准确率。

表 5 S_AcT, D_AcT 与 ADA_CLUE 训练时间对比

方 法	SVHN→MNIST	DSLR→Amazon
	训练时间 (s)	训练时间 (s)
ADA_CLUE ^[39]	11,064.00	54,937.50
S_AcT	6,958.70	40,447.60
D_AcT	8,255.00	50,582.80

在 DSLR 数据集迁移到 Amazon 数据集的实验中, D_AcT 筛选出的目标域和源域样本分布分别如图 15(b)、图 16(b)所示, 其中不同颜色的子集表示不同的类别, 黑色数字表示对应分类。由图 15 和图 16 可以看出, 本文所提 D_AcT 方法, 能够对源域与目标域的样本进行价值度量, 所挑选样本能够有效覆盖整个数据类别分布。

在 SVHN 迁移到 MNIST 数据集, 以及 DSLR 数据集迁移到 Amazon 数据集的实验中, 随着源域训练样本的增加, D_AcT 和 R_AcT 的准确率变化趋势如图 17 和图 18 所示, 设置逐增样本的梯度

分别为 500 和 124。结果表明, 在选取相同量的源域训练样本时, D_AcT 的准确率均高于 R_AcT, 证明了 D_AcT 主动选取的样本比 R_AcT 随机挑选的样本更有效, 更益于迁移学习。但随着源域样本量的逐渐递增, 准确率呈现先增后减的变化。原因在于前期源域样本少, 未达到饱和值, 准确率会随着源域样本量的增加而提高。当达到峰值时, 样本量已趋于饱和, 此时的源域样本是最有效的。当样本量超过饱和值时, 部分无效样本被选择, 进而影响准确率的提升。

图 11 和图 19 分别展示了在使用相同目标域标记样本量的情况下, 不同实验中 S_AcT 算法和 D_AcT 算法的训练过程对比, 其中横轴为训练过程中的迭代次数, 纵轴为测试集上的准确率。结果表明 D_AcT 比 S_AcT 的训练准确率更高, 这进一步证明了 D_AcT 算法基于源域上的价值评估策略筛选出的源域样本有益于迁移学习。

5 总结

本文将主动学习价值评估模型引入域适应目标域, 提出的单主动域适应方法实现了主动学习和迁移学习有效结合, 该方法一定程度上克服了传统主动学习对标记样本量的依赖性、域适应缺乏目标域样本信息以及对标记样本的高要求问题, 在多个数据集上的结果验证了该方法的有效性。此外, 本文将价值评估策略适配到域适应源域中, 提出双主




图 15 DSLR→Amazon 实验中 Amazon 样本分布




图 16 DSLR→Amazon 实验中 DSLR 样本分布




图 17 D_AcT 与 R_AcT 的各批次准确率对比结果 (SVHN→MNIST)




图 18 D_AcT 与 R_AcT 的各批次准确率对比结果 (DSLR→Amazon)




图 19 S_AcT 与 D_AcT 训练过程对比结果
(Real→Sketch)

动域适应策略, 进一步提升迁移学习知识复用有效性, 降低模型训练代价, 达到了使用更少源域样本但准确率超过使用全部源域样本效果, 解决了负迁移问题。但本文提出的算法目前仅针对一般的图像分类任务, 更加复杂的图像分类任务比如多标签分类等, 还需在今后进一步加强研究。

参考文献

- [1] Ganin Y, Ustinova E, Ajakan H, et al. Domain-adversarial training of neural networks. *The journal of machine learning research*, 2016, 17(1): 2096-2030.
- [2] Ao S, Li X, Ling C. Fast generalized distillation for semi-supervised domain adaptation//*Proceedings of the AAAI Conference on Artificial Intelligence*. San Francisco, California USA. 2017, 31(1)
- [3] Wang D, Cui P, Zhu W. Deep asymmetric transfer network for unbalanced domain adaptation//*Proceedings of the AAAI Conference on Artificial Intelligence*. New Orleans, Louisiana USA. 2018, 32(1).
- [4] Motian S, Jones Q, Iranmanesh S, et al. Few-shot adversarial domain adaptation//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. Long Beach, USA. 2017: 6673-6683.
- [5] Ganin Y, Lempitsky V. Unsupervised domain adaptation by backpropagation//*International conference on machine learning*. Lille, France. 2015: 1180-1189.
- [6] Eric Tzeng, Judy Hoffman, Ning Zhang, Kate Saenko, and Trevor Darrell. Deep domain confusion: Maximizing for domain invariance. *arXiv preprint arXiv:1412.3474*, 2014.
- [7] Long M, Cao Y, Wang J, et al. Learning transferable features with deep adaptation networks//*International conference on machine learning*. Lille, France. 2015: 97-105.
- [8] Long M, Cao Z, Wang J, et al. Conditional adversarial domain adaptation//*Proceedings of the 32nd International Conference on Neural Information Processing Systems*. Montreal, Canada. 2018, 31.
- [9] Shu R, Bui H H, Narui H, et al. A dirt-t approach to unsupervised domain adaptation. *arXiv preprint arXiv:1802.08735*, 2018.
- [10] Saito K, Kim D, Sclaroff S, et al. Semi-supervised domain adaptation via minimax entropy//*Proceedings of the IEEE International Conference on Computer Vision*. Seoul, Korea. 2019: 8050-8058.
- [11] Donahue J, Hoffman J, Rodner E, et al. Semi-supervised domain adaptation with instance constraints//*Proceedings of the IEEE conference on computer vision and pattern recognition*. Portland, USA. 2013: 668-675.
- [12] Yao T, Pan Y, Ngo C W, et al. Semi-supervised domain adaptation with subspace learning for visual recognition//*Proceedings of the IEEE conference on Computer Vision and Pattern Recognition*. Boston, USA. 2015: 2142-2150.
- [13] Shu Xing, Yu Hui-Min, Zheng Wei-Wei, Xie Yi, Hu Hao-Ji, Tang Hui-Ming. Classifier-designing algorithm on a small dataset based on margin Fisher criterion and transfer learning. *Acta Automatica Sinica*, 2016, 42(9): 1313-1321.
(舒醒, 于慧敏, 郑伟伟, 谢奕, 胡浩基, 唐慧明. 基于边际Fisher准则和迁移学习的小样本集分类器设计算法. *自动化学报*, 2016, 42(9): 1313-1321)
- [14] Tsai Y H, Hung W C, Schuster S, et al. Learning to adapt structured output space for semantic segmentation//*Proceedings of the IEEE conference on computer vision and pattern recognition*. Salt Lake City, USA. 2018: 7472-7481.
- [15] Chen Y, Li W, Sakaridis C, et al. Domain adaptive faster r-cnn for object detection in the wild//*Proceedings of the IEEE conference on computer vision and pattern recognition*. Salt Lake City, USA. 2018: 3339-3348.
- [16] Ash J T, Zhang C, Krishnamurthy A, et al. Deep batch active learning by diverse, uncertain gradient lower bounds. *arXiv preprint arXiv:1906.03671*, 2019.
- [17] Yoo D, Kweon I S. Learning loss for active learning//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Long Beach, USA. 2019: 93-102.
- [18] Kothawade S, Beck N, Killamsetty K, et al. Similar: Submodular information measures based active learning in realistic scenarios //*Advances in Neural Information Processing Systems*. Virtual-only. 2021, 34.
- [19] Zhang Xiao-Yu. SVM active learning via Dynamic Version Space Division. *Computer Science*, 2012, 39(07): 175-177+189.
(张晓宇. 基于动态可行域划分的SVM主动学习. *计算机科学*, 2012, 39(07): 175-177+189.)
- [20] Sener O, Savarese S. Active learning for convolutional neural networks: A core-set approach. *arXiv preprint arXiv:1708.00489*, 2017.
- [21] Gissin D, Shalev-Shwartz S. Discriminative active learning. *arXiv preprint arXiv:1907.06347*, 2019.
- [22] Sinha S, Ebrahimi S, Darrell T. Variational adversarial active learning//*Proceedings of the IEEE/CVF International Conference on*

- Computer Vision. Seoul, Korea. 2019: 5972-5981.
- [23] Yonatan Geifman and Ran El-Yaniv. Deep active learning over the long tail. arXiv preprint arXiv:1711.00941, 2017.
- [24] Gal Y, Islam R, Ghahramani Z. Deep bayesian active learning with image data//International Conference on Machine Learning. Venice, Italy. 2017: 1183-1192.
- [25] Melanie Ducoffe and Frederic Precioso. Adversarial active learning for deep networks: a margin based approach. arXiv preprint arXiv:1802.09841, 2018.
- [26] Simon Tong and Daphne Koller. Support vector machine active learning with applications to text classification. Journal of machine learning research, 2001, 2(Nov):45 – 66.
- [27] Citeseer, 2000.Schohn G, Cohn D. Less is more: Active learning with support vector machines//International Conference on Machine Learning. Standford, USA. 2000, 2(4): 6.
- [28] Ren P, Xiao Y, Chang X, et al. A survey of deep active learning. ACM Computing Surveys (CSUR), 2021, 54(9): 1-40.
- [29] Aggarwal C C, Kong X, Gu Q, et al. Active learning: A survey//Data Classification. Boca Raton, Florida: Chapman and Hall/CRC, 2014: 599-634.
- [30] Zhu J, Wang H, Tsou B K, et al. Active Learning With Sampling by Uncertainty and Density for Data Annotations. IEEE Transactions on Audio Speech & Language Processing, 2010, 18(6):1323-1331.
- [31] Roth D, Small K. Margin-based active learning for structured output spaces//European Conference on Machine Learning. Berlin, Germany: Springer, 2006: 413-424.
- [32] Wang D, Shang Y. A new active labeling method for deep learning//2014 International joint conference on neural networks (IJCNN). Beijing, China. 2014: 112-119.
- [33] Tran T, Do T T, Reid I, et al. Bayesian generative active deep learning//International Conference on Machine Learning. Long Beach, USA. 2019: 6295-6304.
- [34] Shi X, Fan W, Ren J. Actively transfer domain knowledge//Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Berlin, Germany: Springer, 2008: 342-357.
- [35] Saha A, Rai P, Daumé H, et al. Active supervised domain adaptation//Joint European Conference on Machine Learning and Knowledge Discovery in Databases. Berlin, Germany: Springer, 2011: 97-112.
- [36] Chu H M, Lin H T. Can active learning experience be transferred?//2016 IEEE 16th International Conference on Data Mining (ICDM). Barcelona, Spain. 2016: 841-846.
- [37] Huang S J, Zhao J W, Liu Z Y. Cost-effective training of deep cnns with active model adaptation//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London, UK. 2018: 1580-1588.
- [38] Su J C, Tsai Y H, Sohn K, et al. Active Adversarial Domain Adaptation[J]. arXiv preprint arXiv:1904.07848, 2019.
- [39] Prabhu V, Chandrasekaran A, Saenko K, et al. Active domain adaptation via clustering uncertainty-weighted embeddings//Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal, Canada. 2021: 8505-8514.
- [40] Pan S J, Yang Q. A survey on transfer learning. IEEE Transactions on knowledge and data engineering, 2009, 22(10): 1345-1359.
- [41] Wang Jun, Li Shi-Jun, Yang Sha, Jin Hong, Yu Wei. A New Transfer Learning Model for Cross-Domain Recommendation. Chinese Journal of Computer, 2017, 40(10): 2367-2380.
(王俊, 李石君, 杨莎, 金红, 余伟. 一种新的用于跨领域推荐的迁移学习模型. 计算机学报, 2017, 40(10):2367-2380.)
- [42] Yves Grandvalet Y B. Semi-supervised Learning by Entropy Minimization[C]//Proceedings of the 17th International Conference on Neural Information Processing Systems. Vancouver, British Columbia, Canada. 2005, 17.
- [43] Wang Jin, Wang Ke, Min Zi-Jian, Sun Kai-Wei, Deng Xin. Transfer Weight Based Conditional Adversarial Domain Adaptation. Journal of Electronics & Information Technology, 2019, 41(11):2729-2735.
(王进, 王科, 闵子剑, 孙开伟, 邓欣. 基于迁移权重的条件对抗领域适应. 电子与信息学报, 2019, 41(11):2729-2735.)
- [44] Bai Jing, Tian Dong-Wen, Zhang lin, Yang Ning. Cross-Domain Variational Adversarial Autoencoder. Journal of Computer-Aided Design and Computer Graphics, 2020, 32(09): 1402-1410.
- [45] J. Hoffman, E. Tzeng, T. Park, J.-Y. Zhu, P. Isola, K. Saenko, A. A. Efros, and T. Darrell. Cycada: Cycle-consistent adversarial domain adaptation. arXiv preprint arXiv:1211.03213,2017.
- [46] K. He, X. Zhang, S. Ren, and J. Sun. Deep residual learning for image recognition//Proceedings of the IEEE conference on computer vision and pattern recognition. Las Vegas, USA, 2016: 770–778.

实验参数见表 6, 其中 λ 与 MME^[10]保持一致, 网络结构 Net 分别根据 MME^[10]、AADA^[38]以及 ADA_CLUE^[39]对应实验设置, 其余参数为经验参数。

表 6 实验参数说明表

实 验	λ	B_t	$ T_t $	$ T_u $	$ S $	$ B_s $	N	Step	Net
SVHN→MNIST	0.1	10	50	59830	73257	500	2000	50000	LeNet
DSLR→Amazon	0.1	50	200	1585	498	124	248	12500	ResNet
Real→Sketch	0.1	126	378	15632	70358	16800	50400	12500	ResNet
Sketch→Painting	0.1	126	378	20246	24582	-	-	12500	ResNet
Painting→Clipart	0.1	126	378	11713	31502	-	-	12500	ResNet
Clipart→Sketch	0.1	126	378	15632	18703	-	-	12500	ResNet



Liu Guisong, Ph.D., Professor. His current research interests include artificial intelligence, deep learning and image processing.

Zheng Yu, M. S. Her current research interests include deep learning, transfer learning and active learning.

Xie Xiurui, Ph.D., Associate Professor. Her current research interests include artificial intelligence, zero-short learning and neuromorphic learning.

Huang Li, Ph.D., Lecturer. Her current research interests include artificial intelligence and natural language processing.

Ding Haolun, M.S. His current research interests include deep learning and image processing.

Background

With the continuous development of big data technology and application, it becomes easier to obtain massive samples in image classification task. However, most of these samples are unlabeled, and the number of accurately labeled samples is very limited because of high cost. Therefore, it is particularly important to improve the accuracy of image classification in the case of limited labeled samples. Transfer learning is one of the common methods to solve the problem of insufficient sample labeling, but unsupervised transfer learning lacks the key sample information of the target domain and semi-supervised transfer learning usually has high requirements for labeled samples. Different from transfer learning, active learning can effectively evaluate and select samples with high value to reduce the demand for tags of the model, thus reducing the training cost. However, in order to achieve high accuracy, active learning still has a large demand for

labeled samples, which does not meet the conditions of small sample learning. Active transfer learning combines the advantages of both active learning and transfer learning, and is more effective than a single strategy in solving the problem of insufficient labeled samples. On the one hand, active learning can train the classifier by a large number of known samples in the source domain to overcome the problem of high demand for labeled samples. On the other hand, active learning can be used to select high-value unknown samples for the target domain, so as to overcome the problem of lack of target domain sample information or high requirement for labeled samples in transfer learning. However, the research found that there are relatively few studies on active transfer learning in the field of artificial intelligence. The current active transfer learning algorithms' accuracy still needs to be improved, and the negative transfer problem has not been solved. In this paper, a dual active domain

adaptive learning algorithm is proposed to measure the data value of both source domain and target domain simultaneously, which realizes the effective application of sample value estimation strategy on target domain datasets and eliminates the negative transfer effect. Finally, experimental results prove that the proposed method can use less than 50% of the total source domain training data for transfer learning, and the accuracy is improved by 4% compared with the traditional active transfer learning.

This work was supported by the Social Foundation of Zhongshan Sci-Tech Institute under Grant 420S36, the Natural Science Foundation of

Guangdong Province under Grant 2021A1515011866, and the National Natural Science Foundation of China under Grant 61806040: Research on the Spiking-Transfer Learning models with good sequential knowledge transfer capability. The project intends to study transfer learning mechanism on deep neural networks to address the label cost problem in real applications. The research group has done some efforts: proposed an effective dynamic domain adaptation method; proposed an effective domain adaptation method on deep spiking neural networks; proposed effective active learning strategies for multi-label image classification.