



同构迁移学习理论和算法研究进展

摘要

迁移学习的目的是解决目标领域中训练样本不足的学习问题,可以把一些在其他相关的源领域中获得的知识,迁移到目标领域中.它放宽了传统机器学习中的两个基本假设:用于学习的训练样本与新的测试样本满足独立同分布的条件;必须有足够可利用的训练样本才能学习得到一个较好的分类模型.按照源领域和目标领域的特征空间是否相同可划分为同构迁移学习和异构迁移学习.本文主要针对同构迁移学习的相关研究进展进行了综述,从理论、算法、应用方面介绍了在该领域所做的研究工作,并指出了同构迁移学习未来可能的研究方向.

关键词

同构迁移学习;机器学习;领域适应

中图分类号 TP181

文献标志码 A

收稿日期 2019-05-19

资助项目 国家自然科学基金重点项目(61732011);国家自然科学基金青年项目(61702358)

作者简介

李茂莹,女,硕士生,研究方向为机器学习.limaoying@tju.edu.cn

胡清华(通信作者),男,博士,教授,博士生导师,研究方向为机器学习.huqinghua@tju.edu.cn

¹ 天津大学 智能与计算学部,天津,300350

0 引言

大部分机器学习算法的最基本的假设是训练和测试的数据在相同的特征空间中,并满足独立同分布的条件,且需要训练足够多的数据才能学习到一个具有较高性能的分类模型.然而,在许多实际应用中,这个假设可能是不成立的.例如:1)想要获得人工标注的数据是非常昂贵的,因为它是一项劳动密集的任务,而且由于人的主观因素,数据的标注容易出错,如果可以成功地进行知识迁移,就可以轻松获得大量的标注数据;2)数据的分布有时会随着时间等其他因素的变化而发生变化,对于大多数统计模型来说,需要使用新的训练数据重新构建.举一个经典的迁移学习问题来说,室内 WiFi 定位主要是基于历史的 WiFi 数据来对用户当前所在的位置进行定位.而较大范围内建模来校准 WiFi 数据将花费大量的人力物力,因为在每个位置上都需要标记收集的 WiFi 数据.但是, WiFi 信号的强弱取决于时间、设备等许多动态因素.如果在某时间段或某设备上训练的模型直接用于另一个时间段或另一个设备的位置估计,性能可能会大打折扣.我们希望在某时间段训练的模型能够迁移到另一个新的时间段,或从某移动设备上迁移到新的移动设备.为了缓解这些问题,迁移学习应运而生.

迁移学习(transfer learning)方法可以根据不同分类方式进行划分.针对源领域和目标领域是否标注以及任务是否相同,可以把迁移学习的工作划分为归纳迁移学习(inductive transfer learning)、直推式迁移学习(transductive transfer learning)以及无监督迁移学习(unsupervised transfer learning)等.而按照迁移学习的内容划分,又可以把迁移学习方法分为特征表示迁移、实例迁移、参数迁移和关联关系迁移等.按照源领域和目标领域的特征空间是否相同可划分为同构迁移学习(homogeneous transfer learning)和异构迁移学习(heterogeneous transfer learning).本文主要对同构迁移学习的相关研究进行综述,由浅入深,由简单到复杂.

本文其余部分内容如下:首先简要回顾迁移学习的历史发展,然后总结同构迁移学习的理论及算法研究进展,并介绍了同构迁移学习的一些成功应用.最后,讨论了同构迁移学习未来的工作和可能的发展方向.

1 迁移学习的发展

Thorndike 和 Woodworth 在 1901 年从心理学和教育学的角度,提出了迁移学习的理论^[1].从人类智能的角度来看,人类可以在不同领域之间、不同问题之间,根据已获得的知识进行知识的迁移或知识的转化.如果机器能模仿人类,可以根据多种与问题相关的数据源,进行知识迁移或转化,这就是迁移学习,也称作领域适配^[2].对迁移学习的研究始于 1995 年 NIPS-95 的“学会学习(learning to learn)”的专题研讨会.

按照源领域和目标领域是否具有相同的特征空间,迁移学习可分成同构迁移学习和异构迁移学习.同构空间下的迁移学习是指源领域和目标领域的特征空间相同,可以把与目标领域相关的源领域中的数据,直接应用到目标领域中.代表性工作主要有基于主题的隐含语义分析算法^[3]、谱分析算法^[4]、基于流形结构的算法^[5]、潜变量的核空间模型^[6]、自学习聚类算法^[7]、Tradaboosting 算法^[8]等.异构空间下的迁移学习^[9]也称为翻译学习,源领域和目标领域的特征空间不同,通常需要学习异构的源领域和目标领域之间的关系,可以直接进行特征映射,也可以映射到共同的子空间中.主要模型有风险最小化框架^[9]、概率隐含语义分析方法^[10-11]、协同矩阵分解技术^[12]、积极迁移学习框架^[13]等.

根据源领域和目标领域标注数据的有无^[14],迁移学习可以分为归纳迁移学习、直推式迁移学习和无监督迁移学习,如表 1 所示.归纳迁移学习^[8,15-18]的目标领域中只有少量的标注数据.根据源领域中标注数据的有无,还可以把归纳迁移学习划分成多任务学习(multitask learning)和自学习(self learning).多任务学习的源领域有标注样本,而自学习的源领域中没有标注样本.直推式迁移学习^[19-22]只有源领域中有标注数据,源领域和目标领域具有

相同的任务,而数据可能是相关但不相同的.但当源领域和目标领域都没有标注数据时则是无监督迁移学习^[7,23]关注的问题.

按照迁移内容的不同对迁移学习划分,主要分为基于特征表示的迁移、基于实例的迁移、基于参数的迁移和基于关联关系的迁移等.特征表示迁移的主要目的是使得联合表示的特征优于只基于目标领域数据的特征表示^[24],较为重要的工作有:自学习聚类算法^[7]、基于概率的隐含语义分析算法^[3]、基于流形结构的算法^[5]等.实例迁移从源领域中选择一些适合目标领域中测试数据的实例,并将其增加到测试数据中来达到迁移的目的.较为重要的工作包括 Tradaboosting 算法^[8]、基于隐含稀疏领域的迁移方法^[25]等.参数迁移的主要思想是假设源领域和目标领域的某些参数是共享的,较为重要的工作有基于高斯过程(Gaussian process)的模型^[26-27],以及结合层次贝叶斯(hierarchical Bayesian)框架的模型^[28-29].关联关系迁移一般是通过迁移源领域和目标领域数据之间的关联关系来达到迁移的目的.较为重要的工作有 Markov Logic 网络进行关系迁移^[30-32].

以上大部分都是浅层的模型,随着深度学习的不断发展,很多学者把深度学习方法的思想加入到了迁移学习的各种方法中,构建具有很多隐层的网络来学习更好的特征,达到提升迁移学习在目标领域中表现的目的^[33-45].Bengio^[33]研究分析了无监督预训练特征的有效性,并将其应用到了迁移学习的场景下.Glorot 等^[34]将不同领域的数据放入叠加降噪自动编码器中,学习到的特征更加健壮,并重新表示了源领域和目标领域中的数据.Oquab 等^[35]首先利用源领域中已标注的样本训练卷积神经网络(Convolutional Neural Networks, CNN),使用适应层来弥补领域差异,并利用了目标领域中标签数据微

表 1 迁移学习的分类

Table 1 Classification of transfer learning

学习方式	源领域和目标领域	源任务和目标任务	源领域/目标领域标注情况		
传统机器学习	相同	相同	有/没有		
迁移学习	归纳式迁移学习	多任务学习	相同/相关	相关	有/少量
		自学习	相同/相关	相关	没有/少量
	无监督迁移学习	相关	相关	没有/没有	
	直推式迁移学习	相关	相同	有/没有	

调训练的 CNN. Yosinski 等^[36]对神经网络中的每一层特征的可迁移性进行了量化. Zhuang 等^[37]通过研究深度自动编码器来进行知识迁移,最小化源领域和目标领域隐藏层的 KL 距离(Kullback-Leibler Divergence)获得了领域不变的特征表示. Long 等^[38]提出了联合自适应网络来解决目标领域中标注数据较少的问题. Sun 等^[39]和 Rozantsev 等^[40]提出了深度领域自适应的方法. 文献[41-43]是基于深度学习的异构迁移学习方法,已应用到人脸识别、图像文本迁移等工作中. 深度学习与迁移学习的结合,使得算法的性能普遍得到了提高,但深度学习在可解释性和参数调整等方面仍需进一步研究.

2 同构迁移学习理论研究进展

从理论上来看,同构迁移学习研究的是:1)何条件下源领域训练的模型可以在目标领域表现出优异的性能;2)目标领域中没有或只有少量的标记样本,如何与大量有标记的数据结合并进行训练来减小测试的误差. 目前,已有很多同构迁移学习理论的研究.

关于领域适应性问题的理论分析最早是由 Ben-Davi 等^[46]提出的. Ben-Davi 等基于 VC 维给出了领域适应性问题的推广性的界. 其中,最重要的贡献是定义了分布之间的距离. 在此研究的基础上, Kifer 等^[47]针对有限 VC 维的情况,提出了从有限个样本估计适应推广能力的方法. 但针对不是有限 VC 维的情况并未给出相关研究. 然而,领域分布之间计算出的不同距离的误差估计的精度是不同的,可以通过研究各种距离的特性以解决领域适应性的问题,从而可以满足不同的应用场合. 文献[19]提出的结构对应学习(Structural Correspondence Learning, SCL)可以将某领域中独有的某些特征映射到其他所有领域共享的“轴”特征中,然后就在这个“轴”特征下进行训练学习. Ben-David 等^[46]通过分析领域中数据的表示,提出的模型可以同时最小化模型在训练数据上的泛化误差以及源领域、目标领域之间的差异性. Blitzer 等^[21]针对源领域数据通过加权组合建立模型,给出了在特定经验风险最小化的情形下的误差率. Ben-David 等^[48]对何条件下分类器可以在目标领域表现出较好的性能进行了研究,还研究了给定少量目标领域标注数据,如何结合源领域中的标注数据来使得目标误差最小.

Mansour 等^[49]研究提出对任意的目标函数来说,存在着某个源假设的领域加权分布组合,可以保

证损失至多为给定的某个值. 另外, Mansour 等^[50]给出了对于任一目标分布的基于源领域和目标领域之间 Rényi 散度的领域推广误差,并将更加精确的推广误差的上界估计应用到回归和一般的损益函数中,同时提出了通过加权实现经验分布能够将目标领域的分布更好地反映出来^[51]. Zhang 等^[52]分析了典型领域适应性学习过程中的理论性质,将多个源领域和单个目标领域的问题结合起来考虑. 该文使用积分概率度量来衡量源领域和目标领域分布之间的差异. 然后,分别针对多领域提出了 Hoeffding 型、McMiarmid 型和 Bennett 型偏差不等式以及对称不等式. 之后,利用以上不等式获得了基于统一熵数的 Hoeffding 型和 Bennett 型泛化边界. 此外,提出了一种基于 Rademacher 复杂度的泛化边界,并分析研究了渐近收敛性和学习过程中的收敛速度的相关问题. Kumagai^[53]分析了参数迁移学习的 margin 边界. Flennerhag 等^[54]通过跨学习过程传递知识来在更高抽象层次上进行迁移学习. 将每个任务与训练过程从初始化到最终参数所经过的流形相关联,并构造一个元学习目标,使此路径的期望长度最小化. Le 等^[55]严谨地解释了为什么在联合特征空间中缩小两个域之间的差距可以直接将两个域之间迁移分类学习过程中的损失最小化,并提供了具体的理论结果来量化这种差距.

然而,正如文献[56]所指出的,尽管各位研究者在同构迁移学习的理论层面进行了一系列相关的研究,但这还远远不够,我们还需要对研究理论进行更深入的研究,尤其是同构迁移学习有效性的相关理论研究.

3 同构迁移学习算法研究进展

迄今为止,为促进来自不同领域数据的共同表示,在保持原始数据的重要性质的同时改善分布的一致性方面,已经取得了显著的研究成果.

首先, Dai 等^[8]将 Boosting 算法和迁移学习方法相结合,提出了 TrAdaBoost 算法. 它在每次迭代过程中更新样本采样的权重,源领域的样本权重会被逐渐减弱,然而目标领域中有利于提升模型精度的样本权重会被逐渐加强,它还通过 PAC 理论来证明算法的有效性. 最大均值差异(Maximum Mean Discrepancy, MMD)是把源领域和目标领域用一个相同的映射,映射到一个再生核希尔伯特空间(Reproducing Kernel Hilbert Space, RKHS)中,然后

求映射后两部分数据的均值差异,就当作是两部分数据的差异.迁移成分分析(TCA)^[57]方法使用MMD方法学习在一个可复制核希尔伯特空间(RKHS)中跨域的传输组件,这是一种常用的测量源领域和目标领域之间差异的方法.通过降维来减少数据维度,使用核函数进行映射,得到源领域和目标领域的降维后的数据,就可以使用传统机器学习方法.TCA实现简单,但大矩阵伪逆的求解以及特征值分解需要时间较长.迁移联合匹配(TJM)^[58]方法增强了数据分布中的一致性,目标是在一个有原则的维数重建过程中,通过联合匹配特征对跨域实例重新加权来减少域间的差异,并构造对分布差异和不相关实例都不变的新特征表示.Gong等^[59]基于采样测地线流方法(Sample Geodesic Flow, SGF)提出了测地线流内核方法(Geodesic Flow Kernel, GFK).SGF算法认为源领域和目标领域是高维空间中的两个点,在这两个点的测地线上取 n 个中间点,将它们依次连接起来就构成了一条测地线路径.如果能找到这个过程每一步变换,就能从源领域变换到目标领域.GFK算法是经典的子空间转换方面的迁移学习算法,它可以解决无监督迁移学习的领域适配问题.通过特征映射把源领域和目标领域变换到一个距离度量最小而相似度最高的公共子空间上.然后, CORrelation ALignment (CORAL)^[60]方法通过对源分布和目标分布的二阶统计数据进行对齐,最大限度地减少了域偏移,而不需要任何目标标签.此外,基于landmark的子空间对齐(LSA)^[61]方法在数据中选择重要的地标,并在此基础上进行有效的子空间对齐,以减少域之间的差异.

根据Elhamifar等^[62],来自同一类的那些数据样本应该位于一个公共子空间,即使它们属于不同的领域,这个公共子空间称为潜在空间或子流形.因此,为了克服全局域迁移的限制,有必要利用每个类的内部关系.现有的方法往往借助于标准分类器获得的伪标签来计算类内分布距离.联合分布适配方法(JDA)^[63]和平衡分布适配方法(BDA)^[64]基于预测的伪标签同时调整边际分布和条件分布.JDA为了解决迁移学习中的领域适配问题,假设源领域和目标领域边缘分布不同、条件分布不同,用TCA来适配边缘分布,用MMD适配源领域和目标领域的条件概率分布.然后,通过弱分类器不断迭代循环,将上一轮更新的标签作为新一轮的伪标签,迭代多次以达到提升精度的目的.另外,基于适应正则化的迁

移学习(ARTL)^[65]基于结构风险最小化原理和正则化理论,通过同时优化结构风险函数、域间的联合分布匹配和底层边缘分布的流形一致性来学习自适应分类器.流形嵌入分布对齐(MEDA)^[66]学习了一种具有结构风险最小化的域不变分类器,同时进行动态分布对齐,定量地考虑了边际分布和条件分布的相对重要性.联合几何和统计对齐(JGSA)^[67]学习了两个耦合投影,将源领域和目标领域数据投影到低维子空间中,同时减少几何位移和分布位移.目标函数可以用封闭形式有效地求解.分层迁移学习(STL)^[68]通过多数投票技术获得目标领域的伪标签,迭代地执行类内知识迁移,将两个域转换为相同的子空间.最后再通过第二次标注得到目标领域的标签.

Dai等^[69]提出的基于特征和标签联合聚类的跨领域文档的分类方法称为COCC.该算法会识别出源领域与目标领域文档共享的词特征,然后将学习到的知识和标签信息通过共享词特征从源领域迁移到目标领域,以实现领域特征和标签进行同步联合聚类.域自适应神经网络(DaNN)^[70]提出了一种简单的神经网络模型来处理目标识别中的域适应问题.它把MMD度量作为一种正则化在潜在空间的源领域和目标领域之间减小分布不匹配.Tahmoresnezhad等^[71]在2017年提出视觉领域自适应(Visual Domain Adaptation, VDA).VDA可以处理视觉问题中源领域和目标领域分布差异较大的问题,它通过使用联合迁移学习在测试集没有标签数据的情况下同时减小跨领域的联合边际和条件分布.此外,VDA算法构造的嵌入表示中的凝聚域不变集群可以将各个域与类迁移分开,并不断迭代和细化伪标签直至收敛至最终解.同样地,采用迭代策略和新颖的优化方法为跨领域适应创建了健壮的代表.

另外,在实际问题中,常有目标领域类别数目大于源领域类别数目或源领域与目标领域的类别完全不同的开放集问题,Busto和Gall^[72]提出了开集域的适应方法,它利用源领域和目标领域的关系,为目标领域样本分配标签,并将源领域和目标领域转换到同一空间,学习标签和学习映射不断进行交替,直到收敛或目标小于阈值.Saito等^[73]提出了一种使用对抗训练的开放集域适应方法,它可以提取从已知目标样本中分离出未知目标样本的特征.在训练期间,特征生成器可以将目标样本与已知源领域样本对

齐,或将其判定为未知的目标样本。

4 同构迁移学习的应用

同构迁移学习典型的应用主要有文本处理、情感分析、图像处理、定位估计、智能规划、排序检索及度量学习等方面。

首先,在文本处理领域有很多同构迁移学习的相关工作^[3,7,69,74-79]。Dai等^[74]提出的迁移贝叶斯分类器通过估计源领域的分布,对其不断进行修正,并使其与目标领域数据相适应。Zhuang等^[76]在概念层面上对文本进行处理,并提出了挖掘文档概念与词特征概念的迁移学习方法。在此基础上,Long等^[78]进一步对概念进行划分,提出双重迁移模型来提高算法性能。另外,Gu等^[77]提出共享子空间的多任务的聚类方法来解决文本处理问题。

在情感分析方面也有很多研究工作^[5,80-81]。Li等^[81]提出的模型利用了领域无关的带有情感倾向的词先验以及领域相关的无标签数据,提高了模型的准确率。另外,Pan等^[5]提出的谱特征对齐方法利用了独立于领域的词特征,并将不同领域的特有词特征对齐到同一聚类。例如,在评价某商品的情感分类任务中,由于无法收集到全面的用户评价,可以利用迁移学习将已有的少量数据与测试数据相似的其他评价数据结合起来一同进行训练,以提升分类准确率。

在图像处理领域也有较多同构迁移学习的相关工作。Raina等^[82]提出了无标签自学习模型,在大量无标签数据中,利用系数编码技术可以构造较好的高层特征来提高图像分类的准确度。Si等^[83]采用了边际最大化原则,可以很好地保留区分不同类的判别信息。在与数据流形局部等距的局部切线空间中对每个训练类的局部几何进行编码,从而保持类内局部几何。例如,在医学影像处理任务中,由于医学知识学习难度较大,想要获得大量标注的医学图像作为训练数据是一件非常困难的事情。将迁移学习应用到医学图像的语义映射,可以利用医学图像的识别结果辅助医生诊断,促进医疗的发展。

在定位估计方面,也有一些同构迁移学习方面的工作^[14,84-86]。Wang等^[85]研究发现虽然不同楼层的信号数据分布差别特别大,但楼层的结构设计是相似的,可以把不同楼层的差异较大的数据嵌入到同一低维流形中,这种流形结构会把标签信息传播到无标签样本,完成不同楼层信号数据的迁移。Zheng

等^[86]对室内定位系统中的多个设备同时学习,并提出了多任务学习,采用交替优化方法来迭代学习设备的特征映射和多任务回归模型。

在智能规划方面,Zhou等^[87]提出的TRAMP迁移学习框架,将迁移学习用于智能规划方面来获取动作模型。它首先建立源领域与目标领域之间的结构映射,然后从Web搜索中挖掘额外的知识,并将知识从源领域通过桥梁传递到目标领域。

在排序检索及度量学习方面的工作有很多文献^[88-90]。由于低层次的视觉特征与高层次的语义概念存在缺口,导致传统视觉重排序不能很好地解决基于文本的视频搜索问题。Tian等^[88]提出的维度降低工具可以有效地编码用户的标记信息来提高检索性能。Geng等^[90]提出的领域适应性度量学习方法在常规的度量学习过程中引入依赖于数据的正则化项,来缓解源领域与目标领域之间分布的不同。

总体来说,越来越多的同构迁移学习工作被应用于各种领域。同时,也取得了非常显著的研究成果。然而,在这个大数据蓬勃发展的时代,现有的算法还不能完全满足实际应用的数据需求,健壮且高效的同构迁移学习算法仍然值得研究者们不断探索。

5 同构迁移学习的未来展望

迁移学习主要解决的是如何将已获得的知识或较为容易获得的知识迁移到目标领域来帮助目标领域学习的问题。迁移学习已经有许多经典的算法,这些算法无不推动着同构迁移学习的不断发展。然而,同构迁移学习还有许多问题有待研究者们进一步研究,可将其概括为以下几个方面:

第一,同构迁移学习算法有效性、领域适应性等问题的理论研究还比较缺乏。根据上文提到的,虽已有一些相关理论研究,但针对迁移学习基本理论还是没有非常完整的理论系统。可迁移学习的条件、探索正迁移的本质属性、如何避免负迁移等都是学者们研究的重要问题。因此需要不断补充迁移学习的理论研究,逐渐形成一套完整的理论体系。

第二,针对领域不同性、差异性度量已有相关研究,但目前针对领域相似性、共同性的度量,还没有特别深入的研究成果。由于同构迁移学习的迁移效果在很大程度上取决于领域之间的相似程度,且不同的相似性度量可能产生不同的迁移效果,所以研究丰富的领域之间相似性的度量是非常重要的工作。

第三,由于从单一领域获得的知识是有限的,所以从多个不同的源领域进行知识迁移是一个值得研究的问题.从多个相关的领域同时迁移知识到目标领域,可以学习到更多有利于目标领域的知识,从而提高算法的性能.然而,如何将多个领域的知识进行非常有效的结合是研究者需要研究的重要难点.

第四,从应用适用性的方面考虑,不同的应用场景对迁移学习算法的需求也有所不同.目前很多优秀的研究工作主要集中在分类算法方面,其他方面的应用算法有待各位研究者进一步补充,比如自动驾驶、仿真技术等方面.

最后,鲁棒且高效的同构迁移学习算法在实际应用中尤为重要.目前的研究主要集中在学术领域,实验使用的数据量较小且数据集非常标准.但在大数据环境下,在实际的工业领域应用中,获得的真实数据具有数据量巨大且数据非常不规范的特点,算法在这种情况下是否也能表现出非常好的性能也是非常值得研究的问题.

参考文献

References

- [1] Ormrod J E. Human learning [M]. 4th ed. Upper Saddle River, NJ, USA: Pearson, 2004
- [2] Long M S. Transfer learning: problems and methods [M]. Tsinghua University, Dissertation, 2014
- [3] Xue G R, Dai W Y, Yang Q, et al. Topic-bridged PLSA for cross-domain text classification [C] // Proceedings of the Thirty-first International ACM SIGIR Conference on Research and Development on Information Retrieval, 2008: 627-634
- [4] Ling X, Dai W, Xue G R, et al. Spectral domain-transfer learning [C] // Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2008: 488-496
- [5] Pan S J, Ni X, Sun J, et al. Cross-domain sentiment classification via spectral feature alignment [C] // Proceedings of the 19th International Conference on World Wide Web, 2010: 751-760
- [6] Gao X B, Wang X M, Li X L, et al. Transfer latent variable model based on divergence analysis [J]. Pattern Recognition, 2011, 44(10-11): 2358-2366
- [7] Dai W Y, Yang Q, Xue G R, et al. Self-taught clustering [C] // Proceedings of the International Conference on Machine Learning, 2008: 200-207
- [8] Dai W Y, Yang Q, Xue G R, et al. Boosting for transfer learning [C] // Proceedings of the International Conference on Machine Learning, 2007: 193-200
- [9] Dai W, Chen Y, Xue G R, et al. Translated learning: transfer learning across different feature spaces [C] // Advances in Neural Information Processing Systems 21, Proceedings of the Twenty-Second Annual Conference on Neural Information Processing Systems, 2008: 353-360
- [10] Yang Q, Chen Y, Xue G R, et al. Heterogeneous transfer learning for image clustering via the social web [C] // Joint Conference of the Meeting of the ACL and the International Joint Conference on Natural Language Processing of the AFNLP, Association for Computational Linguistics, 2009: 1-9
- [11] Zhuang Z F, Luo P, Shen Z Y, et al. Collaborative dual-PLSA: mining distinction and commonality across multiple domains for classification [C] // Proceedings of the International Conference on Information and Knowledge Management, 2010: 359-368
- [12] Yang L, Jing L P, Ng M K. Robust and non-negative collective matrix factorization for text-to-image transfer learning [J]. IEEE Transactions on Image Processing, 2015, 24(12): 4701-4714
- [13] Yang L, Hanneke S, Carbonell J. A theory of transfer learning with applications to active learning [J]. Machine Learning, 2013, 90(2): 161-189
- [14] Pan S J, Yang Q. A survey on transfer learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359
- [15] Jiang J, Zhai C X. Instance weighting for domain adaptation in NLP [C] // Proceedings of the 45th Annual Meeting of the Association for Computational Linguistics, 2007: 264-271
- [16] Wang C, Mahadevan S. Manifold alignment using procrustes analysis [C] // Proceedings of the International Conference on Machine Learning, 2008: 1120-1127
- [17] Chang W C, Wu Y, Liu H, et al. Cross-domain kernel induction for transfer learning [C] // Proceedings of the Association for the Advancement of Artificial Intelligence, 2017: 1-7
- [18] Segev N, Harel M, Mannor S, et al. Learn on source, refine on target: a model transfer learning framework with random forests [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(9): 1811-1824
- [19] Blitzer J, McDonald R, Pereira F. Domain adaptation with structural correspondence learning [C] // Proceedings of the International Conference on Empirical Methods in Natural Language Processing, 2006: 120-128
- [20] Xing D K, Dai W Y, Xue G R, et al. Bridged refinement for transfer learning [C] // Proceedings of the 11th European Conference on Practice of Knowledge Discovery in Databases, 2007: 324-335
- [21] Blitzer J, Crammer K, Kulesza A, et al. Learning bounds for domain adaptation [C] // Proceedings of the Advances in Neural Information Processing Systems, 2008: 129-136
- [22] Zen G, Porzi L, Sangineto E, et al. Learning personalized models for facial expression analysis and gesture recognition [J]. IEEE Transactions on Multimedia, 2016, 18(4): 775-788
- [23] Wang Z, Song Y Q, Zhang C S. Transferred dimensionality reduction [C] // Proceedings of the European Conference on Machine Learning and Knowledge Discovery in Databases, 2008: 550-565
- [24] Jiang W, Chung F. Transfer spectral clustering [C] // Pro-

- ceedings of the 2012 European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases,2012:789-803
- [25] Zhang L,Zuo W M,Zhang D.LSDT:latent sparse domain transfer learning for visual adaptation[J].IEEE Transactions on Image Processing,2016,25(3):1177-1191
- [26] Lawrence N D,Platt J C.Learning to learn with the informative vector machine[C]//Proceedings of the 21st International Conference on Machine Learning,2004
- [27] Bonilla E,Chai K M,Williams C.Multi-task Gaussian process prediction[C]//Proceedings of the 20th Advances in Neural Information Processing Systems,2008:153-160
- [28] Schwaighofer A,Tresp V,Yu K.Learning gaussian process kernels via hierarchical bayes[C]//Proceedings of the 17th Advances in Neural Information Processing Systems,2005:1209-1216
- [29] Evgeniou T,Pontil M.Regularized multi-task learning[C]//Proceedings of the 10th ACM SIGKDD Conference on Knowledge Discovery and Data Mining,2004:109-117
- [30] Mihalkova L,Huynh T,Mooney R J.Mapping and revising Markov logic networks for transfer learning[C]//Proceedings of the 22nd Association for the Advancement of Artificial Intelligence,2007:608-614
- [31] Mihalkova L,Mooney R J.Transfer learning by mapping with minimal target data[C]//Proceedings of the Association for the Advancement of Artificial Intelligence Workshop Transfer Learning for Complex Tasks,2008:31-36
- [32] Davis J,Domingos P.Deep transfer via second-order Markov logic[C]//Proceedings of the 26th International Conference on Machine Learning,2009:217-224
- [33] Bengio Y.Deep learning of representations for unsupervised and transfer learning[C]//Proceedings of the International Conference on Machine Learning Workshop on Unsupervised and Transfer Learning,2012:17-36
- [34] Glorot X,Bordes A,Bengio Y.Domain adaptation for large-scale sentiment classification:a deep learning approach[C]//Proceedings of the 28th International Conference on Machine Learning,2011,513-520
- [35] Oquab M,Bottou L,Laptev I,et al.Learning and transferring mid-level image representations using convolutional neural networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition,2014,1717-1724
- [36] Yosinski J,Clune J,Bengio Y,et al.How transferable are features in deep neural networks?[C]//Proceedings of the Advances in Neural Information Processing Systems,2014:3320-3328
- [37] Zhuang F,Cheng X,Luo P,et al.Supervised representation learning:transfer learning with deep autoencoders[C]//Proceedings of the 24th International Conference on Artificial Intelligence,2015:4119-4125
- [38] Long M,Zhu H,Wang J,et al.Deep transfer learning with joint adaptation networks[C]//Proceedings of the 34th International Conference on Machine Learning,2017:2208-2217
- [39] Sun B,Saenko K.Deep coral:correlation alignment for deep domain adaptation[C]//Proceedings of the European Conference on Computer Vision Workshop on Transferring and Adapting Source Knowledge in Computer Vision,2016:443-450
- [40] Rozantsev A,Salzmann M,Fua P.Beyond sharing weights for deep domain adaptation[J].IEEE Transactions on Pattern Analysis and Machine Intelligence,2019,41(4):801-814
- [41] Chen W Y,Hsu T M,Tsai Y H.Transfer neural trees for heterogeneous domain adaptation[C]//Proceedings of the European Conference on Computer Vision,2016:399-414
- [42] Saxena S,Verbeek J.Heterogeneous face recognition with CNNs[C]//Proceedings of the European Conference on Computer Vision Workshop on Transferring and Adapting Source Knowledge in Computer Vision,2016:483-491
- [43] Wang L,Li Y,Lazebnik S.Learning deep structure-preserving image-text embeddings[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition,2016:5005-5013
- [44] Ganin Y,Ustinova E,Ajakan H,et al.Domain adversarial training of neural networks[J].Journal of Machine Learning Research,2016,17(59):1-35
- [45] Liu M Y,Tuzel O.Coupled generative adversarial networks[C]//Proceedings of the Advances in Neural Information Processing Systems,2016:469-477
- [46] Ben-David S,Blitzer J,Crammer K,et al.Analysis of representations for domain adaptation[C]//Advances in Neural Information Processing Systems,2007:137-144
- [47] Kifer D,Ben-David S,Gehrke J.Detecting change in data streams[C]//Proceedings of the Thirtieth International Conference on Very large Data Bases,2004:180-191
- [48] Ben-David S,Blitzer J,Crammer K,et al.A theory of learning from different domains[J].Machine Learning,2010,79(1/2):151-175
- [49] Mansour Y,Mohri M,Rostamizadeh A.Domain adaptation with multiple sources[C]//Proceedings of the Advances in Neural Information Processing Systems,2009:1041-1048
- [50] Mansour Y,Mohri M,Rostamizadeh A.Multiple source adaptation and the Rényi divergence[C]//Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence.AUAI,2009:367-374
- [51] Mansour Y,Mohri M,Rostamizadeh A.Domain adaptation; Learning bounds and algorithms[J].arXiv Preprint arXiv:0902.3430,2009
- [52] Zhang C,Zhang L,Fan W,et al.Generalization bounds for representative domain adaptation[J].arXiv Preprint arXiv:1401.0376,2014:1-40
- [53] Kumagai W.Learning bound for parameter transfer learning[C]//Proceedings of Advances in Neural Information Processing Systems,2016:2721-2729
- [54] Flennerhag S,Moreno P G,Lawrence N D,et al.Transferring knowledge across learning processes[J].arXiv Preprint arXiv:1812.01054,2018
- [55] Le T,Nguyen K,Ho N,et al.Theoretical perspective of deep domain adaptation[J].arXiv Preprint arXiv:1811.06199,2018
- [56] 庄福振,罗平,何清,等.迁移学习研究进展[J].软件

- 学报, 2015, 26(1): 26-39
 ZHUANG Fuzhen, LUO Ping, HE Qing, et al. Survey on transfer learning research [J]. Journal of Software, 2015, 26(1): 26-39
- [57] Pan S J, Tsang I W, Kwok J T, et al. Domain adaptation via transfer component analysis [J]. IEEE Transactions on Neural Networks, 2011, 22(2): 199-210
- [58] Long M S, Wang J M, Ding G G, et al. Transfer joint matching for unsupervised domain adaptation [C] // 2014 IEEE Conference on Computer Vision and Pattern Recognition, 2014: 1410-1417
- [59] Gong B Q, Shi Y, Sha F, et al. Geodesic flow kernel for unsupervised domain adaptation [C] // 2012 IEEE Conference on Computer Vision and Pattern Recognition, 2012: 2066-2073
- [60] Sun B, Feng J, Saenko K. Return of frustratingly easy domain adaptation [C] // Thirtieth AAAI Conference on Artificial Intelligence, 2016
- [61] Aljundi R, Emonet R, Muselet D, et al. Landmarks-based kernelized subspace alignment for unsupervised domain adaptation [C] // 2015 IEEE Conference on Computer Vision and Pattern Recognition, 2015: 56-63
- [62] Elhamifar E, Vidal R. Sparse subspace clustering: algorithm, theory, and applications [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(11): 2765-2781
- [63] Long M S, Wang J M, Ding G G, et al. Transfer feature learning with joint distribution adaptation [C] // 2013 IEEE International Conference on Computer Vision, 2013: 2200-2207
- [64] Wang J D, Chen Y Q, Hao S J, et al. Balanced distribution adaptation for transfer learning [C] // 2017 IEEE International Conference on Data Mining, 2017: 1129-1134
- [65] Long M S, Wang J M, Ding G G, et al. Adaptation regularization: a general framework for transfer learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2014, 26(5): 1076-1089
- [66] Wang J, Feng W, Chen Y, et al. Visual domain adaptation with manifold embedded distribution alignment [C] // 2018 ACM Multimedia Conference on Multimedia Conference. ACM, 2018: 402-410
- [67] Zhang J, Li W Q, Ogunbona P. Joint geometrical and statistical alignment for visual domain adaptation [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 5150-5158
- [68] Wang J D, Chen Y Q, Hu L S, et al. Stratified transfer learning for cross-domain activity recognition [C] // 2018 IEEE International Conference on Pervasive Computing and Communications, 2018: 1-10
- [69] Dai W Y, Xue G R, Yang Q, et al. Co-clustering based classification for out-of-domain documents [C] // Proceedings of the 13th ACM International Conference on Knowledge Discovery and Data Mining. ACM, 2007: 210-219
- [70] Ghifary M, Kleijn W B, Zhang M J. Domain adaptive neural networks for object recognition [C] // Pacific Rim International Conference on Artificial Intelligence. Springer, Cham, 2014: 898-904
- [71] Tahmoresnezhad J, Hashemi S. Visual domain adaptation via transfer feature learning [J]. Knowledge and Information Systems, 2017, 50(2): 585-605
- [72] Busto P P, Gall J. Open set domain adaptation [C] // 2017 IEEE International Conference on Computer Vision, 2017: 754-763
- [73] Saito K, Yamamoto S, Ushiku Y, et al. Open set domain adaptation by backpropagation [C] // Proceedings of the European Conference on Computer Vision, 2018: 153-168
- [74] Dai W Y, Xue G R, Yang Q, et al. Transferring naive bayes classifiers for text classification [C] // Proceedings of the 22nd Conference on Artificial Intelligence. AAAI, 2007: 540-545
- [75] Zhuang F Z, Luo P, Xiong H, et al. Cross-domain learning from multiple sources: a consensus regularization perspective [J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(12): 1664-1678
- [76] Zhuang F, Luo P, Xiong H, et al. Exploiting associations between word clusters and document classes for cross-domain text categorization [J]. Statistical Analysis and Data Mining, 2011, 4(1): 100-114
- [77] Gu Q Q, Zhou J. Learning the shared subspace for multi-task clustering and transductive transfer classification [C] // 2009 Ninth IEEE International Conference on Data Mining, 2009: 159-168
- [78] Long M S, Wang J M, Ding G G, et al. Dual transfer learning [C] // Proceedings of the 2012 SIAM International Conference on Data Mining, Society for Industrial and Applied Mathematics, 2012: 540-551
- [79] Yang P, Gao W. Information-Theoretic multi-view domain adaptation: a theoretical and empirical study [J]. Journal of Artificial Intelligence Research, 2014, 49: 501-525
- [80] Blitzer J, Dredze M, Pereira F. Biographies, bollywood, boom-boxes and blenders: domain adaptation for sentiment classification [C] // Proceedings of the 45th Annual Meeting of the Association for Computational Linguistics, Stroudsburg: ACL, 2007: 440-447
- [81] Li T, Zhang Y, Sindhvani V. A non-negative matrix tri-factorization approach to sentiment classification with lexical prior knowledge [C] // Proceedings of the Joint Conference of the 47th Annual Meeting of the ACL and the 4th International Joint Conference on Natural Language Processing of the AFNLP, Singapore: Association for Computational Linguistics, 2009: 244-252
- [82] Raina R, Battle A, Lee H, et al. Self-taught learning: transfer learning from unlabeled data [C] // Proceedings of the 24th International Conference on Machine Learning, San Francisco: Morgan Kaufmann Publishers, 2007: 759-766
- [83] Si S, Tao D C, Chan K P. Evolutionary cross-domain discriminative hessian eigenmaps [J]. IEEE Transactions on Image Processing, 2010, 19(4): 1075-1086
- [84] Pan S J, Kwok J T, Yang Q. Transfer learning via dimensionality reduction [C] // Proceedings of the Twenty-Third AAAI Conference on Artificial Intelligence. AAAI, 2008: 677-682
- [85] Wang H Y, Zheng V W, Zhao J H, et al. Indoor localization in multi-floor environments with reduced

- effort[C]//2010 IEEE International Conference on Pervasive Computing and Communications,2010:244-252
- [86] Zheng V W, Pan S J, Yang Q, et al. Transferring multi-device localization models using latent multi-task learning [C] // Proceedings of the Twenty-Third AAAI Conference on Artificial Intelligence. AAAI, 2008: 1427-1432
- [87] Zhuo H H, Yang Q. Action-model acquisition for planning via transfer learning [J]. Artificial Intelligence, 2014, 212:80-103
- [88] Tian X M, Tao D C, Rui Y. Sparse transfer learning for interactive video search reranking [J]. ACM Transactions on Multimedia Computing, Communications, and Applications, 2012, 8(3): 1-19
- [89] Bai J, Zhou K, Xue G R, et al. Multi-task learning for learning to rank in web search [C] // Proceedings of the 18th ACM Conference on Information and Knowledge Management. ACM, 2009: 1549-1552
- [90] Geng B, Tao D C, Xu C. DAML: domain adaptation metric learning [J]. IEEE Transactions on Image Processing, 2011, 20(10): 2980-2989

A survey on theories and algorithms about homogeneous transfer learning

LI Maoying¹ YANG Liu¹ HU Qinghua¹

¹ College of Intelligence and Computing, Tianjin University, Tianjin 300350

Abstract The goal of transfer learning is to solve the problem of insufficient training samples in the target domain. It can transfer the acquired knowledge from related source domain to the target domain. It relaxes two basic assumptions in traditional machine learning: the training samples and the new test samples satisfy the conditions of independent and identical distribution; furthermore, there must be enough training samples to learn a good classification model. According to whether the feature space of the source domain and the target domain are the same, it can be divided into homogeneous transfer learning and heterogeneous transfer learning. This paper mainly reviews the related research progress of homogeneous transfer learning, introduces the theory, algorithm and application of homogeneous transfer learning, and points out the hot issues of homogeneous transfer learning.

Key words homogeneous transfer learning; machine learning; domain adaptation