



综述

异构迁移学习研究综述

朱应钊

(中国电信股份有限公司智能网络与终端研究院, 广东 广州 510063)

摘要: 异构迁移学习突破了同构迁移学习要求源域和目标域特征空间必须相同的界限, 实现对异构数据的分析挖掘和知识迁移, 进一步促进数据复用, 为机器学习领域开拓更大的应用范围。首先介绍了迁移学习的定义与分类, 然后深入阐述异构迁移学习的研究现状, 并对其应用场景进行分析, 最后指出了异构迁移学习当前存在的问题及未来可能的研究方向。

关键词: 异构迁移学习; 源域; 目标域; 知识迁移; 数据复用

中图分类号: TP181

文献标识码: A

doi: 10.11959/j.issn.1000-0801.2020060

Review on heterogeneous transfer learning

ZHU Yingzhao

Intelligent Network and Terminal Research Institute, China Telecom Co., Ltd., Guangzhou 510063, China

Abstract: Heterogeneous transfer learning breaks through the boundary that the feature space of source domain and target domain must be the same. It realizes analysis mining and knowledge migration of heterogeneous data. It further promotes data reuse and opens up a wider range of applications for the field of machine learning. Firstly, the definition and classification of transfer learning was introduced. Then, the research status of heterogeneous transfer learning was elaborated and its application scenarios were analyzed. At last, the existing problems and the possible research direction in the future were pointed out.

Key words: heterogeneous transfer learning, source domain, target domain, knowledge transfer, data reuse

1 引言

人工智能技术高速发展, 尤其是机器学习受到各界高度关注^[1]。机器学习正逐渐渗透到越来越多的领域, 孕育出很多新应用和新产品。但是, 传统机器学习都是假定训练数据与测试数据有着同样的分布^[2], 在实际应用中该假设不成立。而且传统机器学习往往需要大量的训练数据才能训

练出一个良好的模型, 但是目标领域可用的类标签很少, 人工标注标签需要付出昂贵的成本。为此, 迁移学习技术问世, 实现将源域的知识迁移到目标域中, 借助源域中丰富的标签资源增强目标域模型的性能, 让更多的源域数据可以复用。当源域与目标域的特征空间不同时, 进行知识迁移更具挑战性, 该问题就是所谓的异构迁移学习^[3]。异构迁移学习通过将异构的两域转换到一个潜在

的公共子空间或将源域直接转换到目标域或将目标域转换到源域的方式,实现异构数据之间的知识迁移。异构迁移学习在异构的源域与目标域之间架起连接桥梁,不需要训练数据与测试数据有同样的分布,让机器学习能拓展到更多的应用场景中。为此,很有必要对异构迁移学习进行深入研究。

2 迁移学习定义与分类

在迁移学习中,域与任务是两个常见的基本概念。迁移学习的域 D 是由两部分构成的,分别是特征空间 X 及边缘概率分布 $P(X)$,即:

$$D = \{X, P(X)\} \quad (1)$$

迁移学习的任务 T 也是由两部分构成的,分别是标签空间 Y 和条件概率分布 $P(Y|X)$,即:

$$T = \{Y, P(Y|X)\} \quad (2)$$

迁移学习利用源域或源任务中已有的知识来协助学习目标域或目标任务中的新知识,其关键就是找到源域与目标域或源任务与目标任务之间的共性,它们的共性涵盖样本实例、特征表达、网络架构或网络参数等方面。挖掘出这些共性之后,再进行知识迁移,得到一个新的模型,可以实现对目标域的样本进行分类或识别,可以有效完成目标任务,如图1所示。




图1 知识迁移

若按特征空间进行分类,迁移学习根据源域与目标域的样本特征空间是否相同可以分为同构迁移学习与异构迁移学习两类^[4]。对于同构迁移

学习,其源域和目标域的特征空间相同,即它的特征维度是相同的,但是它的特征分布是不同的,具体见表1。实现同构迁移学习需要解决域自适应学习的问题,常用的方法有样例加权域自适应学习、特征表示域自适应学习、参数和特征分解域自适应学习及多源域自适应学习^[5];而对于异构迁移学习,其源域和目标域的特征空间、特征维度不同,且其特征分布也不同。为此,实现异构迁移学习需要先解决特征空间对齐的问题,再解决域自适应学习的问题,比同构迁移学习更为复杂。

表1 同构迁移学习与异构迁移学习对比

迁移学习方式	源域与目标域特征空间	需解决的问题
同构迁移学习	相同	域自适应学习
异构迁移学习	不同	特征空间对齐+域自适应学习

若按迁移情景进行分类,根据源域与目标域是否具有类标数据又可以分为归纳式迁移学习、直推式迁移学习及无监督迁移学习3类^[6]。另外,归纳式迁移学习又可以继续分为多任务学习和自学习。上述分类的区别见表2。

表2 归纳式、直推式与无监督3种迁移学习对比

迁移学习方式	源域/目标域标注情况	
归纳式迁移学习	多任务学习	有/少量
	自学习	没有/少量
直推式迁移学习	—	有/没有
无监督迁移学习	—	没有/没有

若按迁移方法进行分类,根据在知识迁移的环节中迁移的内容可以分为基于实例的迁移学习、基于特征的迁移学习、基于网络的迁移学习及基于关系的迁移学习4类^[7],具体见表3。基于实例的迁移学习是从源域中挑出合适的样本用于辅助目标域训练,这类迁移学习的一个典型算法是 TrAdaBoost 算法^[8],对辅助数据集的样本重新



加权以接近目标域的分布, 并利用该部分加权的样本及目标域自身样本共同训练出良好模型。基于特征的迁移学习将源域与目标域的样本转换到新的特征空间中, 让两域的样本分布尽量靠近。

Long 等^[9]基于多核最大均值差异 (multi-kernel maximum mean discrepancy, MK-MMD), 实现最小化两域之间的距离。基于网络的迁移学习复用通过源域样本训练好的网络, 这里面的网络结构或参数都可以作为迁移的内容。Yosinski 等^[10]指出 LeNet、AlexNet、VGG、Inception 等都是良好的迁移网络。基于关系的迁移学习利用源域数据之间的关系与目标域数据之间的关系暗含的相关性进行迁移学习。Davis 等^[11]基于二阶马尔可夫逻辑形式, 挖掘出源域的一系列结构规律, 并将规律应用于目标域中完成知识迁移。

表 3 基于实例、特征、网络、关系的 4 种迁移学习对比

迁移学习方式	特点
基于实例的迁移学习	赋予源域实例一定的权重对其进行复用
基于特征的迁移学习	基于特征变换减少源域与目标域之间的差距
基于网络的迁移学习	找出源域与目标域网络模型之间的共享参数
基于关系的迁移学习	挖掘不同领域之间的关系相似性

对于迁移学习, 常常要重点关注的一个问题就是负迁移。负迁移的概念仍缺乏严格的定义, 其中一个被广泛接受的描述为: 从源头转移知识会对目标学习者产生负面影响^[12-13], 即负迁移。实质上, 联合分布之间的差异是负迁移的根源^[14]。诸如 MsTrAdaBoost^[15]、GFK^[16]、DSM^[17]及 MMKT^[18]等算法都会存在负迁移的现象。那么, 源域与目标域如何相关才能更有利于迁移学习^[19], 是个值得继续深入探究的方向。负迁移很大程度上取决于标记的目标数据的多少, 若目标数据的标记增加, 负迁移的机会也会减小。参考文献[20]提出传递迁移学习的想法, 实现了即使人脸与飞机两域

并不相似, 也可用人脸来协助识别飞机, 有效克服负迁移。

3 异构迁移学习的研究现状

在很多情况下, 源域与目标域的样本特征空间都是不一样的, 有着不同的特征维度和特征分布, 不同的特征分布又可能包含不同的边缘概率分布和条件概率分布。如对于文本评论这类应用场景, 假设源域是关于酒店评论的, 而目标域是关于电脑评论的。一般情况下, 它们包含的特征个数不相同, 拥有不同的特征维度。“干净”“宽敞”“明亮”等词汇可能屡次被用于评论酒店, 和酒店主题紧密相关, 但和电脑主题关系不大, 这表明两域的边缘分布存在差异, 也就是所谓的频率特征偏差, 即:

$$P(X_S) \neq P(X_T) \quad (3)$$

其中, X_S 为源域酒店评论的特征空间, X_T 为目标域电脑评论的特征空间, $P(X)$ 为边缘概率分布。另外, 在这两域中可能会出现“小”这种词汇, “小”对于酒店评论来说是负面的, 形容这酒店太小了住得不舒服, 而对于电脑评论来说却可能是正面的, 形容该超极本小巧轻薄。即同一个词汇在不同域中表示的含义不一致, 甚至相反, 在一个域中表示正面, 在另外一个域中却表示负面, 即存在上下文特征偏差, 两域的条件概率分布不同, 即:

$$P(Y_S | X_S) \neq P(Y_T | X_T) \quad (4)$$

其中, Y_S 为源域酒店评论的标签空间, Y_T 为目标域电脑评论的标签空间, $P(Y|X)$ 为条件概率分布。对两个特征空间不同的域进行知识迁移, 只能采用异构迁移学习。异构迁移学习分为基于对称特征的方法和基于非对称特征的方法。如果两域之间的样本能在没有上下文特征偏差的条件下进行转换, 采用基于非对称特征的方法更为合适^[13]。

3.1 基于对称特征的方法

基于对称特征的方法将源域特征空间与目标域特征空间转换到一个公共子空间进行,如图2所示。在这个公共子空间里,两域之间的样本实例会比原来更加靠近,满足知识迁移的要求。




图2 基于对称特征的方法

基于对称特征的方法在无目标标签的情况下,一种典型的方式是采用结构对应学习(structural correspondence learning, SCL)^[21]进行处理。SCL通过若干个线性分类器找出特征之间的对应关系,再深入学习两域的公共子空间。采用SCL的优势是无需目标标签,直接统一建模和归一化源域与目标域的特征,克服部分特征之间存在较大差异的影响。但是,SCL存在一个较大的问题,就是需要手动设计枢轴函数,而且设计出良好的枢轴函数往往是比较困难的。Prettenhofer等^[22]将SCL技术运用到跨语言文本分类的迁移学习中,提出跨语言结构对应学习(cross-language structural correspondence learning, CLSCL)方法,用一组组词 $\{w_S, w_T\}$ 表示枢轴函数,其中 w_S 表示来自源语言的词,而 w_T 表示来自目标语言的词,通过 $\{w_S, w_T\}$ 实现从源语言到目标语言的直接翻译。

若目标域具有有限的目标标签,可以通过频谱映射和流形对齐等方式学习公共潜在输入空间。参考文献[23]提出了一种异构谱映射(heterogeneous spectral mapping, HeMap)方法,假定源域和目标域的输入特征空间、数据分布及输出空间都不相同,通过频谱映射技术将源域与目标域投影到潜在输入空间,既保证数据原始结构不发生改变,又能使两域差异达到最小。然后,在公共子空间

里采用聚类的方法选择与目标数据最相似的源数据当作新的训练数据,解决不同数据分布的问题。再基于贝叶斯的方法重新缩放和校准完成对两输出空间的统一。针对多源的情况,采用流形对齐的方式可以将多源中的不同高维数据进行降维,并统一到公共的潜在低维空间,让来自不同源域的特征信息尽量接近。Wang等^[24]基于流形对齐提出了一种域适应流形对齐(domain adaptation manifold alignment, DAMA)方法,把各源域中的实例经过各自映射函数转换到公共子空间中,保持多个源域的底层结构,且分别建模,再用一个大矩阵把独立的各流形汇聚起来组成联合流形,并对其进行广义特征值分解,实现联合流形的降维,消除各域之间的特征冗余。最后,将源域实例在联合空间中训练出线性回归模型,并采用流形正则化及相加优化线性回归模型,克服各域之间的差异。

针对图像分类应用,Zhu等^[25]提出了一种异构迁移学习图像分类(heterogeneous transfer learning image classification, HTLIC)的算法,通过两层二分图将本来没有关联的图像和文本文档建立联系,由于从Flickr上获取的图像拥有对应的一个或多个单词标签,可用于构建第一层二分图。若在文本文档内用到单词标签,则创建连接,否则不创建,利用这些连接构建第二层二分图。该两层二分图模型以单词标签为媒介把图像和文本文档关联起来。再对其进行潜在语义分析,从低级图像特征中提取潜在语义特征,并通过集合矩阵分解(collective matrix factorization, CMF)学习高级特征,从而发现文本和图像之间的共同语义空间。Qi等^[26]提出了一种称为文本到图像(text to image, TTI)的算法,采用共现数据的方式关联图像和文本文档,共生矩阵包含文本实例和在该特定文本文档中找到的相应图像实例。

为了校正域之间的条件分布差异,Duan等^[27]



提出一种称为异构特征增强 (heterogeneous feature augmentation, HFA) 的算法。该算法也是采用两个变换矩阵将源域和目标域都映射到公共潜在空间中, 但是不同的是其将源变换阵和目标变换阵合并成一个组合矩阵, 且以 SVM 的结构风险函数^[28]最小化作为组合矩阵的优化过程, 通过交替优化过程解决了支持向量机的对偶问题, 并求解出最优转换组合矩阵。Li 等^[29]在 HFA 的基础上进行拓展, 提出一种半监督异构特征增强 (semi-supervised heterogeneous feature augmentation, SHFA) 算法, 将 HFA 中的组合矩阵分解为一组一阶半定矩阵的线性组合, 允许使用多个核学习求解器来寻找解。

3.2 基于非对称特征的方法

基于非对称特征的方法不需要挖掘出两域特征的潜在空间, 直接将源域特征空间转换到目标域特征空间或将目标域特征空间转换到源域特征空间, 实现两域输入特征的对齐, 如图 3 所示。




图 3 基于非对称特征的两种方法

对于源域直接转化到目标域这种非对称特征的方法, 它将源域特征空间转换到目标域特征空间, 即将源域样本实例映射到目标域, 然后将完成映射的实例用于模型的训练, 训练好模型后, 输入目标域自身的样本实例便可进行测试, 如图 4 所示。

该过程存在一个较大的问题, 因为在一些实际应用场景中, 收集到的目标样本的特征空间经常发生变化。一旦目标域样本的特征空间发生了改变, 通过图 4 方法训练好的模型就无法继续




图 4 源域样本转换后训练模型的方法

发挥出良好性能, 甚至完全不能用于当前的目标任务, 即方法不具有稳健性。因为模型是基于原来的目标域特征空间训练出来的, 只符合原来目标域特征空间的实例。目标域的特征空间一发生变化, 之前训练好的模型就无法使用, 需要重新训练模型, 这样会很浪费时间和资源。然而, 图 5 所示的这类方法可以解决由于目标域样本的特征空间发生变化造成的问题。首先利用源域样本实例直接训练出一个模型, 然后对目标域中的样本进行特征空间转换, 并用转换后的目标域样本对模型进行测试。通过这种方法训练出来的模型, 即使在目标域的特征空间发生变化的情况下, 只要将当前的目标域映射回源域的特征空间, 已训练好的模型就不会受到影响, 仍能发挥出良好的性能。




图 5 源域样本直接训练模型的方法

Kulis 等^[30]提出的一种不对称正则化交叉域变换 (asymmetric regularized cross-domain trans-

formation, ARC-t) 方法正是将异构的目标域实例映射到源域, 且映射是在核空间中学习的。通过采用高斯 RBF 核函数代替标准内积, 实现了源域输入空间和目标域输入空间之间的非线性变换, 完成异构非对称知识迁移。针对多源的情况, Harel 等^[31]提出一种多重映射算法 (multiple outlook mapping algorithm, MOMAP), 先规范源域和目标域中的特性, 再将源域和目标域中的样本按类进行分组, 且分组内的特征平均值为零。然后, 在这些源类组和目标类组之间进行配对, 并通过奇异值分解求解出源域各类组到目标域对应类组的变换矩阵。Zhou 等^[32]提出了一种称为稀疏异构特征表示 (sparse heterogeneous feature representation, SHFR) 的方法, 它给源域与目标域里每个类都建立一个二进制分类器, 且这些二进制分类器具有各自的权重项, 基于组合加权的分类器不断优化权重项, 以最小化目标权重与经过变换的源权重之差为目标, 得出变换矩阵。针对软件模块缺陷预测的应用, Nam 等^[33]提出了一种称为异构缺陷预测 (heterogeneous defect prediction,

HDP) 的算法, 先是采用增益比等特征选择方法在源域内挑出重要特征, 避免特征之间的冗余和不相关。然后, 通过柯尔莫哥洛夫—斯米尔诺夫 (Kolmogorov-Smirnov) 试验找出和目标特征有着密切统计匹配关系的源特征, 并将它们用于训练学习。很多异构解决方法都假定源域和目标域的实例分布相同, 但是在实际应用中并不总是这么理想。参考文献[34]提出混合异构迁移学习 (hybrid heterogeneous transfer learning, HHTL) 算法, 它基于边缘化堆叠去噪自动编码器的深度学习, 可以有效减少变换完成的未标记目标域与已标记源域之间的分布偏差。上述介绍的异构迁移学习算法的特点总结见表 4。

4 异构迁移学习的应用

随着互联网的高速发展, 各种各样的应用场景, 同时具有文本、图像、视频等多模态数据, 这些多模态数据之间的特征空间不相同, 甚至它们的边缘概率分布和条件概率分布也可能不相同, 同构迁移学习的方法已经无法满足要求, 异

表 4 各异构迁移学习算法的特点

方法	迁移类别	源数据	目标数据	多源	通用解决方案	负迁移
CLSCL	基于对称特征	标记	未标记	不支持	不支持	无
HeMap	基于对称特征	标记	部分标记	不支持	支持	无
DAMA	基于对称特征	标记	部分标记	支持	支持	无
HTLIC	基于对称特征	未标记	大量标记	不支持	支持	无
TTI	基于对称特征	标记	部分标记	不支持	不支持	无
HFA	基于对称特征	标记	部分标记	不支持	支持	无
SHFA	基于对称特征	标记	部分标记	不支持	支持	无
ARC-t	基于非对称特征	标记	部分标记	不支持	支持	无
MOMAP	基于非对称特征	标记	部分标记	支持	支持	无
SHFR	基于非对称特征	标记	部分标记	不支持	支持	无
HDP	基于非对称特征	标记	未标记	不支持	支持	无
HHTL	基于非对称特征	标记	未标记	不支持	不支持	无



构迁移学习变得越来越重要,可以应用在文本分类、图像分类、视频内容标注及跨软件项目缺陷预测等方面。

对于文本分类,当源域与目标域具有相同的特征空间和数据分布时,常用的算法有朴素贝叶斯^[35]、支持向量机^[36]和决策树^[37]等。朴素贝叶斯算法分类性能稳定,且不易受缺失数据影响;支持向量机能处理非线性问题,泛化性强;决策树算法不需要进行预处理操作。但是,在非平稳条件下,这些传统文本分类算法的预测准确率会受到较大干扰^[38],采用异构迁移学习更为合适。将异构迁移学习应用到文本分类^[22, 27, 29, 32, 34]中已经取得较大的成功,实现在异构文本域之间进行知识迁移,减少人工标注和新数据重新训练的工作量,提高文档分类任务的性能。

传统的图像分类算法只单纯采用图像视觉特征,虽然这些视觉特征可直接给出图像基本属性,但是无法直接表示出对象与场景这些语义信息^[39]。图像特征相近的两幅图,在语义上可能会存在较大差别,影响分类效果。另外,在很多情况下图像的可用标签会比较稀少,而文本的可用标签会比较多。为此,可以从与图像相关的文本内容中挖掘出有用的知识迁移应用于图像分类。常用共现数据的方法,收集共现数据的方式简单,在 Flickr 上就可以收集大量配对的文本—图像数据^[25-26, 40],因为 Flickr 里插图周围的文字是对该插图进行说明的,这些文本内容里的词语可以表达出图像蕴含的语义。通过这样的方式,可以在视觉特征的基础上,再有效利用图像的语义特征,提高图像分类的准确率。

对于视频内容标注,若采用传统机器学习算法,则需要许多带标注的训练实例才能训练出稳健性强的模型。而且,许多样本视频都会存在部分标注不全或人工过于主观标注标签的情况,传统的基于文本的视频检索和分类已经无法满足现

在视频集的要求^[41]。为此,需要将异构迁移学习应用到视频内容标注中,找出视频和图像存在的对应关系,打通图像源域与目标视频域的关联,完成异构知识迁移。参考文献[42]提出一种异构复合迁移学习,通过典型相关性分析(CCA)的方法,对源图像域与目标视频域的特征空间进行同构化。且以投影代价最小化为目标,找出能让源域特征空间对齐目标特征空间的矩阵,并以该对齐矩阵实现图像域至视频域的知识迁移。该算法的准确率比标准的支持向量机算法、领域适应支持向量机(domain adaptation SVM, DASVM)^[43]算法分别提高 58.03%、23.06%。

软件与人们的生活息息相关,含有缺陷的软件在部署后也许会造成意想不到的后果^[44],进行软件缺陷预测十分必要。如在 2011 年 7 月 23 日,因为控制中心软件系统的设计缺陷没有被发现,甬温线 D301 次列车和 D3115 次列车发生追尾事件,造成 40 人遇难、172 人受伤。软件缺陷预测通常采用以往的数据来训练出一个预测模型,然后对后续软件进行潜在缺陷的预测,保证软件质量。然而,在众多的新兴软件项目中,以往的历史数据可能非常少,甚至完全没有,所以只能采用跨项目软件缺陷预测的方式。跨项目软件缺陷预测存在分布差异与类不平衡等众多问题^[45]。异构迁移学习运用跨项目软件缺陷预测可以很好地优化这些问题,可以对足够多的历史软件数据实现复用^[46]。参考文献[47]提出了适用于异构空间的 HDMP 算法,通过对源项目完成类不平衡处理,基于 MOMAP 方法构建映射矩阵,让转换后的源项目与目标项目的距离最近,并运用分类算法对目标软件进行缺陷预测。当源项目和目标项目存在公共度量时,HDMP 的预测准确性比经典软件缺陷预测算法 TNB^[48]、NN-filter^[49]和 TCA+^[50]都要好;当源项目和目标项目不存在公共度量时,HDMP 算法预测准确率比 CCA+^[51]好。除了以上这些方面,异构迁移学

习还能用于情感分类、协同过滤及网络搜索排序等^[52]。

5 结束语

异构迁移学习突破了不同特征空间的界限,可以克服不同特征维度、不同标签空间及不同概率分布等障碍,学习不变特征和无偏模型,开拓出更多的知识迁移应用场景。但是,异构迁移学习仍存在较多问题需要研究者们继续深入探索,主要包括以下3个方面。

第一,许多异构迁移学习算法的可移植性和可拓展性差,只能运用于特定的应用场景,很难甚至无法复用到其他应用场景中。如HTLIC算法与TTI算法仅限于图像分类,无法移植到非图像任务上。即使部分异构迁移学习算法可以进行移植复用,移植后的算法性能也会大打折扣。为此,很有必要提高异构迁移学习算法的通用性,避免多套算法,减少对知识迁移应用工程优化及维护等所需的额外工作量。另外,大数据分析技术蓬勃发展^[53],当前线上数据众多,具有巨大的实际应用价值。异构迁移学习可以与跨领域大数据建模技术^[54]有机结合,最大限度地复用各跨学科领域的的数据,训练出高效的人工智能模型。

第二,无法在一个公共的实验平台上对新提出的异构迁移学习算法直接进行性能评估验证。上述众多的异构迁移学习文献都对研究中的基线算法与新提出的算法进行性能比较。虽然所有新提出的方法都比这些相应的基线算法有着更好的性能,但是这些基线算法最初并不是专门为异构知识迁移任务设计的,若用于异构知识迁移的任务,算法性能极大地降低。为此,很有必要为异构迁移学习算法开发一个标准化的测试框架,让各异构迁移学习算法能在实验条件相同的公共平台上进行测试验证,才能对各算法进行深入的分析,这样的实验结果让新提出算法的性能

更具说服力,也便于日后其他人根据自身需求或资源条件快速选择出合适的算法。

第三,若进行非对称异构知识迁移的源域与目标域之间没有很好的关联关系,目标学习者会受到这种弱关系的负面影响,也就是产生了负迁移。那么,在进行非对称异构知识迁移前,需要估量两域之间的关联程度,将度量与相似学习运用于此可能是一个不错的选择。通过度量与相似学习,可以学习出源域与目标域数据之间的距离函数^[55],有效评估两域特征之间是否有对应关系,能协助直观地判断出两域数据是否适合进行非对称异构知识迁移。若估算的两域相似值没有超过设定的阈值,则不在这两域之间进行非对称异构知识迁移,能有效避免负迁移,尤其有益于多源域的情况,协助剔除无用源域,选择出与目标域关联度高的源域,提高分类或识别性能。当前许多度量学习方法需要类标签以协助训练模型^[56],Jian等^[57]提出了MAI模型,可以实现无监督的度量学习,先构造一个假设特征之间相互独立的编码空间及另一个假设异构特征之间紧耦合的编码空间,再让它们相互学习直至形成统一与平衡,有效挖掘出数据中的异构耦合关系。未来,还可以在无监督度量学习中充分利用监督信息,增加先验知识以进一步提高度量性能。

参考文献:

- [1] 王志宏,杨震. 人工智能技术研究及未来智能化信息服务体系的思考[J]. 电信科学, 2017, 33(5): 1-11.
WANG Z H, YANG Z. Research on artificial intelligence technology and the future intelligent information service architecture[J]. Telecommunications Science, 2017, 33(5): 1-11.
- [2] 闫玉光. 面向异构特征空间的迁移学习研究[D]. 广州: 华南理工大学, 2019.
YAN Y G. Research on transfer learning for heterogeneous feature space[D]. Guangzhou: South China University of Technology, 2019.
- [3] DAY O, KHOSHGOFTAAR T M. A survey on heterogeneous transfer learning[J]. Journal of Big Data, 2017, 4(1).
- [4] 李茂莹,杨柳,胡清华. 同构迁移学习理论和算法研究进



- 展[J]. 南京信息工程大学学报(自然科学版), 2019(3): 269-277.
- LI M Y, YANG L, HU Q H. A survey on theories and algorithms about homogeneous transfer learning[J]. Journal of Nanjing University of Information Science and Technology (Natural Science Edition), 2019, 11(3): 269-277.
- [5] 刘建伟, 孙正康, 罗雄麟. 域自适应学习研究进展[J]. 自动化学报, 2014, 40(8): 1576-1600.
- LIU J W, SUN Z K, LUO X L. Review and research development on domain adaptation learning[J]. Acta Automatica Sinica, 2014, 40(8): 1576-1600.
- [6] 刘鑫鹏, 栾悉道, 谢毓湘, 等. 迁移学习研究和算法综述[J]. 长沙大学学报, 2018, 32(5): 33-36, 41.
- LIU X P, LUAN X D, XIE Y X, et al. Transfer learning research and algorithm review[J]. Journal of Changsha University, 2018, 32(5): 33-36, 41.
- [7] 王惠. 迁移学习研究综述[J]. 电脑知识与技术, 2017, 13(32): 209-211.
- WANG H. Transfer learning research[J]. Computer Knowledge and Technology, 2017, 13(32): 209-211.
- [8] DAI W, YANG Q, XUE G R. Boosting for transfer learning[C]//Proceedings of the 24th International Conference on Machine Learning. New York: ACM Press, 2007: 193-200.
- [9] LONG M, CAO Y, WANG J. Learning transferable features with deep adaptation networks[C]//Proceedings of the 32nd International Conference on Machine Learning. New York: ACM Press, 2015: 97-105.
- [10] YOSINSKI J, CLUNE J, BENGIO Y. How transferable are features in deep neural networks[C]//Proceedings of Annual Conference on Neural Information Processing Systems. Cambridge: MIT Press, 2014: 3320-3328.
- [11] DAVIS J, DOMINGOS P. Deep transfer via second-order Markov logic[C]//Proceedings of the 26th International Conference on Machine Learning. New York: ACM Press, 2009: 217-224.
- [12] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [13] WEISS K, KHOSHGOFTAAR T M, WANG D D. A survey of transfer learning[J]. Journal of Big Data, 2016, 3(1): 1-40.
- [14] WANG Z, DAI Z, POCZOS B, et al. Characterizing and avoiding negative transfer[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2019: 11293-11302.
- [15] YAO Y, DORETTO G. Boosting for transfer learning with multiple sources[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2010: 1855-1862.
- [16] SHA F, SHI Y, GONG B, et al. Geodesic flow kernel for unsupervised domain adaptation[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2012: 2066-2073.
- [17] CHANG S F, XU D, DUAN L. Exploiting web images for event recognition in consumer videos: A multiple source domain adaptation approach[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2012: 1338-1345.
- [18] TOMMASI T, ORABONA F, CAPUTO B. Safety in numbers: learning categories from few examples with multi model knowledge transfer[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2010: 3081-3088.
- [19] 徐崧崧. 基于迁移学习的表情识别算法研究[D]. 南京: 南京邮电大学, 2017.
- XU Q Y. Facial expression recognition based on transfer learning algorithm[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2017.
- [20] TAN B, ZHANG Y, PAN S J, et al. Distant domain transfer learning[C]//Proceedings of AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2017: 2604-2610.
- [21] BLITZER J, MCDONALD R, PEREIRA F. Domain adaptation with structural correspondence learning[C]//Proceedings of Conference on Empirical Methods in Natural Language Processing. [S.l.:s.n.], 2006: 120-128.
- [22] PRETTENHOFER P, STEIN B. Cross-language text classification using structural correspondence learning[C]//Proceedings of Annual Meeting of the Association for Computational Linguistics. [S.l.:s.n.], 2010: 1118-1127.
- [23] SHI X, LIU Q, FAN W, et al. Transfer learning on heterogeneous feature spaces via spectral transformation[C]//Proceedings of the 10th IEEE International Conference on Data Mining. Piscataway: IEEE Press, 2010: 1049-1054.
- [24] WANG C, MAHADEVAN S. Heterogeneous domain adaptation using manifold alignment[C]//Proceedings of International Joint Conference on Artificial Intelligence. San Francisco: Morgan Kaufmann Press, 2011: 1541-1546.
- [25] ZHU Y, CHEN Y, LU Z, et al. Heterogeneous transfer learning for image classification[C]//Proceedings of AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2011: 1-6.
- [26] QI G J, AGGARWAL C, HUANG T. Towards semantic knowledge propagation from text corpus to web images[C]//Proceedings of 20th International Conference on World Wide Web. New York: ACM Press, 2011: 297-306.

- [27] DUAN L, XU D, TSANG I W. Learning with augmented features for heterogeneous domain adaptation[C]//Proceedings of the 29th International Conference on Machine Learning. New York: ACM Press, 2012: 711-718.
- [28] VAPNIK V. Principles of risk minimization for learning theory[C]//Proceedings of Annual Conference on Neural Information Processing Systems. Cambridge: MIT Press, 1991: 831-838.
- [29] LI W, DUAN L, XU D, et al. Learning with augmented features for supervised and semi-supervised heterogeneous domain adaptation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(6): 1134-1148.
- [30] KULIS B, SAENKO K, DARRELL T. What you saw is not what you get: domain adaptation using asymmetric kernel transforms[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2011: 1785-1792.
- [31] HAREL M, MANNOR S. Learning from multiple outlooks[C]//Proceedings of the 28th International Conference on Machine Learning. New York: ACM Press, 2011: 401-408.
- [32] ZHOU J T, TSANG I W. Heterogeneous domain adaptation for multiple classes[C]//Proceedings of International conference on Artificial Intelligence and Statistics. [S.l.:s.n.], 2014: 1095-1103.
- [33] NAM J, Kim S. Heterogeneous defect prediction[C]//Proceedings of the 10th Joint Meeting on Foundations of Software Engineering. New York: ACM Press, 2015: 508-519.
- [34] ZHOU J T, PAN S, TSANG I W, et al. Hybrid heterogeneous transfer learning through deep learning[C]//Proceedings of AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2017: 2213-2220.
- [35] NIR F, DAN G, MOISES G. Bayesian network classifiers[J]. Machine Learning, 1997, 29(2-3): 131-163.
- [36] JOACHIMS T. Text categorization with support vector machines: learning with many relevant features[C]//Proceedings of the 10th European Conference on Machine Learning. Berlin: Springer Press, 1998: 137-142.
- [37] QUINLAN J R. Induction of decision trees[J]. Machine Learning, 1986, 1(1): 81-106.
- [38] SHIMODAIRA H. Improving predictive inference under covariate shift by weighting the log-likelihood function[J]. Journal of Statistical Planning and Inference, 2000, 90(2): 227-244.
- [39] 杨柳. 融合文本信息的图像分类和标注关键问题研究[D]. 北京: 北京交通大学, 2016.
YANG L. Research on key issues of images classification and annotation by fusing text information[D]. Beijing: Beijing Jiaotong University, 2016.
- [40] DAI W, CHEN Y, XUE G R, et al. Translated learning: transfer learning across different feature spaces[C]//Proceedings of Annual Conference on Neural Information Processing Systems. Cambridge: MIT Press, 2008: 353-360.
- [41] NIEBLES J C, CHEN C W, LI F F. Modeling temporal structure of decomposable motion segments for activity classification[C]//Proceedings of the 11th European Conference on Computer Vision. Berlin: Springer Press, 2010: 392-405.
- [42] 谭瑶, 饶文碧. 异构复合迁移学习的视频内容标注方法[J]. 计算机应用, 2018, 38(6): 1547-1553.
TAN Y, RAO W B. Heterogeneous compound transfer learning method for video content annotation[J]. Journal of Computer Applications, 2018, 38(6): 1547-1553.
- [43] LORENZO B, MATTIA M. Domain adaptation problems: a DASVM classification technique and a circular validation strategy[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(5): 770-787.
- [44] 倪超, 陈翔, 刘望舒, 等. 基于特征迁移和实例迁移的跨项目缺陷预测方法[J]. 软件学报, 2019, 30(5): 1308-1329.
NI C, CHEN X, LIU W S, et al. Cross-project defect prediction method based on feature transfer and instance transfer[J]. Journal of Software, 2019, 30(5): 1308-1329.
- [45] 刘树毅. 基于特征迁移的跨项目软件缺陷预测[D]. 呼和浩特: 内蒙古师范大学, 2019.
LIU S Y. Cross-project software defect prediction based on feature transfer[D]. Hohhot: Inner Mongolia Normal University, 2019.
- [46] 蒋兰华. 基于迁移学习的软件缺陷预测技术研究[J]. 微型电脑应用, 2019, 35(4): 93-94, 99.
JIANG L H. Research on software defect prediction technology based on transfer learning[J]. Microcomputer Applications, 2019, 35(4): 93-94, 99.
- [47] 吴琦. 基于迁移学习的跨项目软件缺陷预测[D]. 长春: 吉林大学, 2018.
WU Q. Cross-project defect prediction based on transfer learning[D]. Changchun: Jilin University, 2018.
- [48] MA Y, LUO G, ZENG X, et al. Transfer learning for cross-company software defect prediction[J]. Information & Software Technology, 2012, 54(3): 248-256.
- [49] TURHAN B, MENZIES T, BENER A B, et al. On the relative value of cross-company and within-company data for defect prediction[J]. Empirical Software Engineering, 2009, 14(5): 540-578.
- [50] NAM J, PAN S J, KIM S. Transfer defect learning[C]//Proceedings of the 35th International Conference on Software Engineering. Piscataway: IEEE Press, 2013: 382-391.



- [51] JING X, WU F, DONG X, et al. Heterogeneous cross-company defect prediction by unified metric representation and CCA-based transfer learning[C]//Proceedings of the 10th Joint Meeting on Foundations of Software Engineering. New York: ACM Press, 2015: 496-507.
- [52] 谭琦. 面向跨领域文档分类的异构迁移学习算法研究[D]. 广州: 华南理工大学, 2014.
TAN Q. Research on heterogeneous machine learning for cross-domain document classification[D]. Guangzhou: South China University of Technology, 2014.
- [53] 汪来富, 金华敏, 刘东鑫, 等. 面向网络大数据的安全分析技术应用[J]. 电信科学, 2017, 33(3): 112-118.
WANG L F, JIN H M, LIU D X, et al. Application of security analysis technology for network big data[J]. Telecommunications Science, 2017, 33(3): 112-118.
- [54] 吴涛, 刘韬, 王斌. 安徽联通企业级大数据平台构建及应用实践[J]. 电信科学, 2018, 34(1): 135-147.
WU T, LIU T, WANG B. Construction and application of Anhui Unicom enterprise big data platform[J]. Telecommunications Science, 2018, 34(1): 135-147.
- [55] MAGDA F, MARCEL J. Asymmetric heterogenous transfer learning: a survey[C]//Proceedings of the 6th International Conference on Data Science, Technology and Applications. New York: ACM Press, 2017: 17-27.
- [56] 蹇松雷, 卢凯. 复杂异构数据的表征学习综述[Z]. 2020.
JIAN S L, LU K. Survey on representation learning of complex heterogeneous data[Z]. 2020.
- [57] JIAN S, HU L, CAO L, et al. Metric-based auto-instructor for learning mixed data representation[C]//Proceedings of AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2018: 3318-3325.

[作者简介]



朱应钊（1993—），男，中国电信股份有限公司智能网络与终端研究院初级工程师，主要研究方向为机器学习、计算机视觉、自然语言处理。