



基于 K -means 聚类的子结构相关适配迁移学习方法

刘昊双¹, 张永^{2,3}, 曹莹波¹

(1. 辽宁师范大学计算机与信息技术学院, 辽宁 大连 116081;

2. 湖州师范学院信息工程学院, 浙江 湖州 313000;

3. 浙江省现代农业资源智慧管理与应用研究重点实验室, 浙江 湖州 313000)

摘要: 域漂移严重影响了传统机器学习方法的性能, 现有的领域自适应方法主要通过全局、类级或样本级分布匹配自适应地调整跨域表示。但全局匹配和类级匹配过于粗糙会导致自适应不足, 而样本级匹配受到噪声的影响可能导致过度自适应。基于此, 提出了一种基于 K 均值 (K -means) 聚类的子结构相关适配 (SCOAD) 迁移学习算法, 首先通过 K -means 聚类分别获得源域和目标域的多个子域, 其次寻求子域中心二阶统计量的匹配, 最后利用子域内结构对目标域样本进行分类。该方法在传统方法的基础上进一步提高了源域与目标域之间知识迁移的性能。在常用迁移学习数据集上的实验结果表明了所提方法的有效性。

关键词: 迁移学习; 领域自适应; 子结构适配; 聚类

中图分类号: TP181

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2023045

Substructure correlation adaptation transfer learning method based on K -means clustering

LIU Haoshuang¹, ZHANG Yong^{2,3}, CAO Yingbo¹

1. School of Computer & Information Technology, Liaoning Normal University, Dalian 116081, China

2. School of Information Engineering, Huzhou University, Huzhou 313000, China

3. Zhejiang Province Key Laboratory of Smart Management & Application of Modern Agricultural Resources, Huzhou 313000, China

Abstract: Domain drifts severely affect the performance of traditional machine learning methods, and existing domain adaptive methods are mainly represented by adaptive adjustment cross-domain through global, class-level, or sample-level distribution adaptation. However, too coarse global matching and class-level matching can lead to insufficient adaptation, and sample-level adaptation to noise can lead to excessive adaptation. A substructure correlation adaptation (SCOAD) transfer learning algorithm based on K -means clustering was proposed. Firstly, multiple subdomains of the source domain and the target domain were obtained by K -means clustering. Then, the matching of the

收稿日期: 2022-12-05; 修回日期: 2023-03-15

通信作者: 张永, zhyong@zjhu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61772252); 辽宁省教育厅科学研究经费项目 (No.LJKZ0965)

Foundation Items: The National Natural Science Foundation of China (No.61772252), Scientific Research Foundation of the Education Department of Liaoning Province (No.LJKZ0965)

second-order statistics of the subdomain center was sought. Finally, the target domain samples were classified by using the subdomain structure. The proposed method approach further improves the performance of knowledge transfer between the source and target domains on top of the traditional approach. Experimental results on common transfer learning datasets show the effectiveness of the proposed method.

Key words: transfer learning, domain adaptation, substructural adaptation, clustering

0 引言

随着网络 and 多媒体技术的发展, 信息世界中的数据呈爆炸式增长, 导致在数据挖掘领域已有的训练数据与新出现的数据分布不一致。与此同时, 新数据的标签很难获取, 引发了机器学习中一个重要问题, 即如何利用少量的有标签训练样本(源域数据)建立一个可靠的模型对大量的无标签测试样本(目标域数据)进行预测。在训练数据和测试数据分布发生变化的情况下, 研究人员通过充分利用已经存在的不同分布下的标注数据辅助目标域数据的学习, 称之为迁移学习^[1]或领域自适应, 其目标是将某个领域或任务中学习到的知识或模式应用到不同但相关的领域中。

早期的领域自适应方法主要学习全局的域漂移, 即不考虑两个域中更小的两个子结构之间的关系, 将全局的源域和目标域分布直接进行对齐。大多数领域自适应方法都采用最大均值差异(maximum mean discrepancy, MMD)^[2]计算领域分布之间的差异, 这类方法需要通过调整多个超参数实现相关领域的对齐。相比之下, 相关对齐(correlation alignment, CORAL)^[3]只需要计算源域数据和目标域数据的协方差就能够对齐源域和目标域的输入特征分布。但这些方法都存在粗糙匹配问题, 不仅导致来自源域和目标域的全部数据被混淆, 而且其区分结构也可能被混淆, 从而丢失每个子结构的详细(细粒度)信息。研究表明, 在一些场景中直接对全局的源域和目标域进行匹配效果并不理想。近年来, 越来越多的研究人员关注以学习局部域漂移为目标的子结构适配^[4-5]。早期的子结构适配大多按类别划分子结构, 通过

匹配源域和目标域中相关类的分布, 使匹配后源域和目标域的局部分布近似相同, 从而使得全局分布也近似相同。但全局匹配和类级的子结构适配仍然粗糙, 可能存在更小的子结构没有对齐, 这意味着仅执行粗糙的匹配可能会导致适应不足。基于样本级的匹配方法使源域中的一个数据点对应于目标域中的多个数据点, 耗时长, 且源域和目标域的边界和重叠部分容易发生错误, 可能导致样本级匹配出现过度适应。此外, 传统的领域自适应方法大多使用最近邻分类器对特征对齐后的数据进行分类, 然而, 在迁移学习中使用最近邻分类器存在以下两个问题: (1) 在处理域之间的分布差异时, 容易受影响; (2) 当样本不平衡时, 预测偏差较大, 计算时间较长。

由于现阶段的迁移学习研究存在以上问题, 探索一种介于类级匹配和样本级匹配之间的子结构适配方法避免适应不足和过度适应, 以及采用不易受领域间分布差异影响的分类方法成为了本文的主要研究动机。因此, 本文提出了一种基于 K 均值(K -means)聚类的子结构相关适配(substructure correlation adaptation, SCOAD)迁移学习算法, 简称 SCOAD 算法。相对于现有的领域适应方法, 本文提出的方法通过对齐聚类得到的子域中心实现领域之间分布差异的对齐。此外, 为了使对齐后的样本能够被更精准地分类, 本文还设计、提出了子域内规划分类器, 通过计算目标域样本与子域中心标签相同的置信度构造出一个概率标注矩阵, 置信度越高表示样本标签与子域标签相同的概率越大, 最终选取置信度最高的子域标签为预测的样本标签。综上, SCOAD 算法首先使用 K -means 聚类算法^[6-7]分别将源域和目标域数据聚合得到相同数量的子



域,然后对齐各子域中心的二阶协方差匹配数据分布,最后利用子域内数据的结构对目标域样本进行分类。

与以前的领域自适应方法相比,本文的主要贡献是:引入了子结构适配的思想,并通过聚类算法生成了数据量介于类级和样本级之间的子结构命名为子域,利用更细粒度的局部信息改善以往方法匹配过于粗糙的问题,同时相对于样本级方法不容易受噪声或异常值的影响;通过拉近源域和目标域子域中心的二阶协方差距离实现域对齐;提出了子域内规划分类器,在概率标注矩阵的基础上构造了一个无参数的迁移学习分类器,改善了分类时易受分布差异影响、预测偏差较大、计算时间长的问题,提高了方法的性能。本文在3个常用迁移学习数据集 USPS+MNIST^[8-9]、Office-Caltech10^[10]和 Amazon Review^[11]上进行实验,结果表明了本文方法的有效性。

1 相关工作

由于迁移学习中源域和目标域的分布是不同的,因此进行迁移学习的关键是减少源域和目标域的分布发散。现有的迁移学习方法可分为基于实例的迁移学习^[12]、基于特征的迁移学习^[13]、基于模型的迁移学习^[14-15]和基于关系的迁移学习^[16-17]。

领域自适应作为迁移学习的一个分支,已成功应用于许多领域,如图像分类^[18-19]、自然语言处理^[19]、情感分类^[20]等。领域自适应大致可以分为3类:全局匹配、子结构匹配和样本级匹配。现有的迁移学习方法大多利用两个域之间的全局匹配。Pan等^[21]提出了一种迁移成分分析(transfer component analysis, TCA)方法,该方法在再生核希尔伯特空间中学习一个核,以最小化领域之间的最大均值差异。Long等^[22]提出联合分布适配(joint distribution adaptation, JDA)迁移学习方法,通过降维学习得到数据紧凑特征表示,同时减小边缘分布和条件分布差异。Wang等^[23]提出均衡分

布适配(balanced distribution adaptation, BDA)学习方法,自适应地调节边缘分布差异和条件分布差异的重要性。CORAL^[3]通过对齐源域和目标域分布的二阶统计量,在不需要任何目标域标签的情况下,最小化分布差异。样本级匹配是领域自适应的另一类方法,具有代表性的工作是Courty等^[24]提出的领域自适应最优传输(optimal transport for domain adaptation, OTDA)方法,该方法利用最优传输理论,学习两个概率密度函数之间的耦合,通过重心映射,获得目标域内源样本的图像,然后使用一个分类模型对目标样本进行分类。此外,Das等^[25]提出了基于正则化超图匹配的无监督域自适应方法,使用超图匹配两个域之间的样本。

子结构适配通过将源域和目标域分别划分为若干个子结构,改善了对源域和目标域进行全局特征匹配的效果。Pei等^[26]提出了多对抗领域自适应方法,通过捕获多模态结构,以实现基于多个域鉴别器的不同数据分布的细粒度对齐。Kumar等^[27]提出了无监督领域自适应的共正则化对齐方法,构建多个不同的特征空间,并分别对齐每个特征空间中的源和目标分布。Zhao等^[28]提出了一种局部域适应(local domain adaptation, LDA)方法,该方法在域级和类级匹配之间进行折中,并利用高级抽象集群组织数据。本文提出的方法属于子结构自适应,通过利用聚类得到介于样本级和类级之间的子结构的数据局部信息解决迁移学习中常见的适应不足或过度适应问题,实现更有效的领域自适应。SCOAD算法与几种方法的比较见表1,将本文提出的SCOAD算法与几种有代表性的工作进行了对比分析,可以发现SCOAD算法在参数数量、细粒度程度等方面都更有优势。

聚类是一种经典的无监督机器学习算法,无监督学习不依赖于训练样本的标签发掘数据集本身潜在的结构与规律。聚类试图将数据集的样本划分为若干个互不相交的子集,每个子集称为一

表 1 SCOAD 算法与几种方法的比较

方法	BDA ^[23]	OTDA ^[24]	LDA ^[28]	SCOAD (本文)
参数	μ	α, λ, η	$\lambda, \lambda_1, \eta, k_i$	K
子结构适配	不是	不是	是	是
子域内规划	不是	不是	不是	是
特征对齐	是	不是	不是	是

个簇。 K -means 聚类算法^[6-7]和基于密度的噪声应用空间聚类 (density-based spatial clustering of applications with noise, DBSCAN) 算法^[29]都是经典的聚类算法, 前者属于划分类聚类算法, 后者是一个基于密度的聚类算法。近年来, 许多学者对聚类算法进行创新和改进, 并利用聚类算法解决了许多现实任务^[30]。

2 基于 K -means 聚类的子结构相关适配

SCOAD 算法的主要过程如图 1 所示, 包括以

下 3 个步骤。

步骤 1 运用 K -means 聚类算法分别将源域和目标域数据聚合得到相同数量的子域, 子域的数量要大于源域数据的类别数且小于数据量最小的数据的个数。

步骤 2 通过对齐各子域域中心的二阶协方差匹配数据分布, 解决迁移学习中源域和目标域分布不同的问题。

步骤 3 利用一个非参数子域内规划分类器对目标域中的无标签样本进行分类。




图 1 SCOAD 算法的主要过程



2.1 问题定义和符号说明

记有标签信息的源域 $D_s = \{(\mathbf{x}_i, \mathbf{y}_i)\}_{i=1}^{n_s}$ ，无标签信息的目标域 $D_T = \{\mathbf{x}_j\}_{j=1}^{n_t}$ 。假设特征空间 $\mathbf{X}_s = \mathbf{X}_T$ ，标签空间 $\mathbf{Y}_s = \mathbf{Y}_T$ 。 n_s 和 n_t 分别为源样本和目标样本的数量， $y_s \in \{1, \dots, C\}$ 为源域标签， C 为类别数。迁移学习的目标是通过源域 D_s 学习目标域 D_T 的标签 $\mathbf{Y}_T$ 。

当通过粗糙的分布匹配对齐数据时，难以实现完美的数据匹配，在进行迁移学习时需要注意捕获数据的局部性信息。在采用样本级匹配对齐数据时，可能会引入噪声。因此，需要在粗糙匹配和样本级匹配之间进行折中，寻找既能获得更细粒度的对齐，又能避免噪声影响的方法。本文提出的 SCOAD 算法通过对聚类获得的子簇中心进行匹配，从而解决迁移学习问题，既解决了之前方法中匹配太过粗糙和过度自适应的问题，又避免了噪声的影响，进一步提高了源域与目标域之间知识迁移的性能。具体来说，SCOAD 算法先分别将源域和目标域通过 K -means 聚类得到若干个子域，再对子域中心进行二阶协方差对齐，最后运用提出的子域内规划分类器进行分类确定目标域样本的标签。

2.2 子结构相关适配

为了有效地将源域和目标域进行匹配，本文采用了一种简单快速的细粒度领域适应方法。首先通过 K -means 聚类将源域和目标域分别划分为数量相同的若干个子域，再将得到的子域中心的二阶协方差进行对齐。 K -means 聚类通过计算簇中所有样本点到质心距离的平方和来衡量聚类结果，平方和越小聚类结果越好，其损失函数可表示为：

$$L = \sum_{i=1}^K \sum_{\mathbf{x} \in c_i} \|\mathbf{x} - \boldsymbol{\mu}_i\|_2^2 \quad (1)$$

其中， K 为簇数， $\boldsymbol{\mu}_i$ 为簇 c_i 的均值向量，在本文中称为子域中心。由于目标域中缺少标签，本文

在整个源域和目标域中分别执行相同的聚类，并且聚类的数量取决于具体的数据集。得到的子域中心可表示为：

$$\boldsymbol{\mu}_i = \frac{1}{|c_i|} \sum_{\mathbf{x} \in c_i} \mathbf{x} \quad (2)$$

通过以上步骤得到源域的子域中心集合 $\mathbf{Q}_s = \{\boldsymbol{\mu}_k^s\}$ ，目标域的子域中心集合 $\mathbf{Q}_T = \{\boldsymbol{\mu}_k^t\}$ 。源域子域中心对应的标签集合为 $\tilde{\mathbf{Y}} = \{\tilde{\mathbf{y}}_k^s\}$ ，即源域每个子域中心元素的标签集合。接下来可以得到源域和目标域子域中心集合的协方差矩阵 $\mathbf{C}_s$ 和 $\mathbf{C}_T$ 。本文通过最小化源域特征和目标域特征的二阶统计量（协方差）之间的距离实现源域和目标域特征分布之间的对齐，即通过对原始源域特征运用线性变换并使用弗罗贝尼乌斯（Frobenius）范数作为矩阵距离度量，如式（3）所示。

$$\min_A \|\mathbf{C}_s - \mathbf{C}_T\|_F^2 = \min_A \|\mathbf{A}^T \mathbf{C}_s \mathbf{A} - \mathbf{C}_T\|_F^2 \quad (3)$$

其中， $\mathbf{C}_s$ 为变换后的源域特征 $D_s \mathbf{A}$ 的协方差， $\mathbf{A}$ 为变换矩阵。受 CORAL^[3] 的启发，利用矩阵技巧可以得到式（3）的最优解： $\mathbf{C}_s = \mathbf{U}_{T[l:r]} \Sigma_{T[l:r]} \mathbf{U}_{T[l:r]}^T$ 。根据上述结果继续对线性变换 $\mathbf{A}$ 求解，由式（3）可得 $\mathbf{A}^T \mathbf{C}_s \mathbf{A} = \mathbf{U}_{T[l:r]} \Sigma_{T[l:r]} \mathbf{U}_{T[l:r]}^T$ 。对 $\mathbf{C}_s$ 进行奇异值分解可得 $\mathbf{C}_s = \mathbf{U}_s \Sigma_s \mathbf{U}_s^T$ ，代入式（3）可得：

$$(\mathbf{U}_s^T \mathbf{A})^T \Sigma_s (\mathbf{U}_s^T \mathbf{A}) = \mathbf{U}_{T[l:r]} \Sigma_{T[l:r]} \mathbf{U}_{T[l:r]}^T \quad (4)$$

设 $\mathbf{E} = \Sigma_s^{-\frac{1}{2}} \mathbf{U}_s^T \mathbf{U}_{T[l:r]} \Sigma_{T[l:r]}^{\frac{1}{2}} \mathbf{U}_{T[l:r]}^T$ ，则式（4）可以写成：

$$(\mathbf{U}_s^T \mathbf{A})^T \Sigma_s (\mathbf{U}_s^T \mathbf{A}) = \mathbf{E}^T \Sigma_s \mathbf{E} \quad (5)$$

由式（5）可得 $\mathbf{U}_s^T \mathbf{A} = \mathbf{E}$ ，因此可以得到最优变换矩阵 $\mathbf{A}^*$ 为：

$$\begin{aligned} \mathbf{A}^* &= \mathbf{U}_s \mathbf{E} \\ &= \mathbf{U}_s \Sigma_s^{-\frac{1}{2}} \mathbf{U}_s^T \mathbf{U}_{T[l:r]} \Sigma_{T[l:r]}^{\frac{1}{2}} \mathbf{U}_{T[l:r]}^T \end{aligned} \quad (6)$$

因为 C_S 和 C_T 是对称矩阵, 所以 $C_S = U_S \Sigma_S U_S^T$ 和 $C_T = U_T \Sigma_T U_T^T$ 分别是对 C_S 和 C_T 进行奇异值分解后得到的。为了简化和高效, 只执行从源域到目标域子空间的特征变换, 综上所述, 可以得到变换后的源域子域中心集合 $\hat{Q}_S = \{\mu_i^s\}$, 如式 (7) 所示, 用 I_S 、 I_T 分别表示与 D_S 、 D_T 大小一致的单位矩阵。

$$\hat{Q}_S = Q_S \cdot A^* = Q_S \cdot (C_S + I_S)^{-\frac{1}{2}} \cdot (C_T + I_T)^{\frac{1}{2}} \quad (7)$$

2.3 子域内规划分类器

源域和目标域子域中心特征分布对齐后, 本文提出了一种子域内规划分类器, 它在概率标注矩阵的基础上构造了一个无参数的迁移学习分类器。概率标注矩阵的示例如图 2 所示, 说明了概率标注矩阵的主要思想。 $\tilde{y}_k^s$ 代表 K 个子域中心的标签, x_n^t 代表 n 个目标样本。概率标注矩阵中的元素 M_j^k 的值是一个概率, 取值范围为 $0 \leq M_j^k \leq 1$ 。 M_j^k 表示目标样本 x_n^t 的标签与变换后的源域子域中心 $\hat{\mu}_i^s$ 所属的标签 $\tilde{y}_k^s$ 是否相同的置信度, 与神经网络中广泛采用的 softmax 分类器相似。例如, x_1^t 的最高概率值为 0.3, 这表明它的标签与 $\tilde{y}_4^s$ 相同。在概率标注矩阵中一个样本 x_n^t 的标签与 $\tilde{y}_k^s$ 相同的概率之和为 1。

	$\tilde{y}_1^s$	$\tilde{y}_2^s$	$\tilde{y}_3^s$	$\tilde{y}_4^s$	...	$\tilde{y}_K^s$
x_1^t	0.1	0.1	0.1	0.3	...	0.2
x_2^t	0.2	0.1	0.05	0.1	...	0.15
x_3^t	0.02	0.2	0.02	0.3	...	0.18
x_4^t	0.2	0.1	0.1	0.1	...	0.1
...						
x_n^t	...	...	...	...	...	...

图 2 概率标注矩阵的示例

子域内规划分类器通过学习概率标注矩阵 M 得到目标域标签 Y_T 。通过这种方式, 可以得到损失函数:

$$J = \sum_j^{n_t} \sum_k^K D_j^k M_j^k \quad (8)$$

其中, $D_j^k = \|x_j^t - \hat{\mu}_i^s\|^2$ 是距离矩阵 D 中的一个元素, 表示 x_j^t 与源域的子域中心 μ_i^s 之间的距离。矩阵 $M \in R^{n_t \times K}$ 表示概率标注矩阵。此外, 对于任何给定的源域的子域中心 μ_i^s , 都必须至少有一个样本 x_j^t 与其标签相同。在不影响计算结果的情况下, M_j^k 的理想状态应该是一个二进制值 (0 或 1)。即如果 x_j^t 的标签与 $\tilde{y}_i^s$ 相同则 $M_j^k = 1$, 否则 $M_j^k = 0$ 。因此, 结合式 (7), 最终的学习目标为:

$$\min J = \sum_j^{n_t} \sum_k^K D_j^k M_j^k$$

$$\text{s.t.} \begin{cases} 0 \leq M_j^k \leq 1 \\ \sum_k^K M_j^k = 1, \forall_j \in \{1, \dots, n_t\} \\ \sum_j^{n_t} M_j^k \geq 1, \forall_k \in \{1, \dots, K\} \end{cases} \quad (9)$$

得到 M 后, 通过 softmax 函数可得出 x_j^t 的标签:

$$y_j^t = \arg \max_c \frac{M_j^c}{\sum_{k=1}^K M_j^k}, c \in \{1, \dots, K\} \quad (10)$$

2.4 算法步骤

本文提出的 SCOAD 算法描述如算法 1 所示。

算法 1 SCOAD 算法

输入 n_s 个有标签的源域样本 $\{(x_i, y_i)\}_{i=1}^{n_s}$,
 n_t 个无标签的目标域样本 $\{(x_j)\}_{j=1}^{n_t}$

源域和目标域输入数据 $X = \{(x_1, x_2, \dots, x_n)\}_{i=1}^{n_s+n_t}$ 参数 K, λ

输出 目标域测试样本的预测标签 $\{y_j^t\}_{j=1}^{n_t}$

对源域和目标域中的数据进行 K -means 聚类分别得到 K 个子域中心 $\{(\mu_i^s, \tilde{y}_i^s)\}_{i=1}^K$ 、

$\{(\mu_j^t)\}_{j=1}^K$, 聚类数量为 K



通过式(3)最小化源域子域中心和目标域子域中心的协方差之间的距离,得到变换后的源域子域中心集合 $\mathbf{Q}_s^*$

根据式(9)将 $\{(\mathbf{x}_j)\}_{j=1}^{n_i}$ 与 $\mathbf{Q}_s^*$ 进行子域内规划,得到概率标注矩阵 $\mathbf{M}$

通过式(10)得到目标域样本的预测标签 $\{\mathbf{y}'_j\}_{j=1}^{n_t}$

3 实验及结果分析

本文通过大量实验评估所提出的 SCOAD 算法的性能,使用的数据集包括 USPS+MNIST、Office-Caltech10 和 Amazon Review 数据集,实验数据集信息见表 2。USPS+MNIST 是手写数字的标准数字识别数据集,它包含 10 个类别,每个类别对应 0~9 的某个数,USPS 包含 7 291 幅训练图像和 2 007 幅测试图像,MNIST 包含 60 000 张训练图像和 10 000 张测试图像,在迁移学习中一般使用随机选取的 1 800 张 USPS 图片和 2 000 张 MNIST 图片进行实验。Office-Caltech10 包括 Webcam、DSLR、Amazon 和 Caltech 4 个图像域,每个域都包含 10 个通用的类别。Amazon Review 是一个情感分析数据集,包含对 4 种产品 Kitchen (K)、DVDs (D)、Electronics (E)和 Books (B)的正面和负面评价。

表 2 实验数据集信息

数据集	名称	特征维数	类别	样本个数
USPS+MNIST	USPS	256	10	1 800
	MNIST	256	10	2 000
Office-Caltech10	Caltech	800	10	1 123
	Webcam	800	10	295
	Amazon	800	10	958
	DSLR	800	10	157
Amazon Review	Kitchen	400	2	1 999
	DVDs	400	2	1 999
	Electronics	400	2	1 998
	Books	400	2	2 000

3.1 对比算法和参数设置

本文将 SCOAD 算法与多个迁移学习算法进行了比较: TCA^[21]、JDA^[22]、迁移联合匹配 (transfer joint matching, TJM)^[31]、BDA^[23]、CORAL^[3]、简单迁移学习 (easy transfer learning, EASYTL)^[32]、联合几何和统计对齐 (joint geometrical and statistical alignment, JGSA)^[33]和 OTDA^[24]。TCA、TJM、BDA、JGSA、EASYTL 和 CORAL 执行粗糙匹配,而 OTDA 属于样本级匹配方法。本文对传统的迁移学习方法采用最近邻分类器 (1-nearest neighbor, 1-NN)。对于 Amazon 数据集,本文使用文献[34]处理后的数据,其中对词袋特征的维数进行了降维,在不损失性能的情况下保留了前 400 个特征。对于 Office-Caltech10 数据集,在浅层特征数据集 SURF 上进行实验,特征维数为 800。聚类的数量 K 取决于具体的数据集,实验采用目标域分类准确率作为评价指标。

3.2 实验结果分析

7 种算法在 14 个迁移学习任务上的准确率对比见表 3,给出了本文提出的 SCOAD 算法和 1-NN、TCA、TJM、OTDA、CORAL、EASYTL 等算法在 MNIST+USPS、Office+Caltech10 数据集上的迁移准确率结果。从表 3 可看出,SCOAD 算法获得了最好的平均准确率。对于 CORAL、EASYTL 和 1-NN,SCOAD 算法的平均准确率分别提高了 0.6%、3.6%和 13.8%。对于 EASYTL,本文算法结合了子结构适配弥补了匹配粗糙的问题。

SCOAD 算法与 1-NN、TCA、BDA、JGSA、CORAL 等算法在 Amazon Review 数据集上迁移学习任务的准确率对比见表 4。从表 4 可看出,相对于 TCA、BDA、JGSA、CORAL 等迁移学习算法,SCOAD 算法在 Amazon Review 数据集的迁移学习任务中有着明显优势,平均准确率最高提高 20.4%,最低提高 2.5%。除了在 Books→DVDs 任务上的准确率低于 CORAL 以外,在其他迁移

表3 7种算法在14个迁移学习任务上的准确率对比

数据集	1-NN	TCA	TJM	OTDA	CORAL	EASYTL	SCOAD
MNIST→USPS	65.9%	54.3%	42.9%	49.3%	65.6%	54.5%	66.2%
USPS→MNIST	44.7%	52.2%	41.4%	50.7%	46.9%	31.0%	51.2%
Caltech→Amazon	23.7%	43.4%	46.7%	30.5%	47.2%	50.1%	40.0%
Caltech→Webcam	25.8%	37.3%	38.0%	23.8%	39.2%	49.5%	42.0%
Caltech→DSLR	25.5%	44.0%	43.3%	26.6%	40.7%	48.4%	50.3%
Amazon→Caltech	26.0%	38.2%	39.6%	29.4%	40.3%	43.0%	38.6%
Amazon→Webcam	29.8%	38.0%	40.7%	25.6%	38.7%	40.7%	40.7%
Amazon→DSLR	25.5%	30.6%	42.2%	35.7%	38.3%	38.9%	42.7%
Webcam→Caltech	19.9%	29.7%	30.2%	25.9%	34.6%	29.7%	35.4%
Webcam→Amazon	23.0%	32.3%	29.9%	27.4%	37.8%	35.2%	40.2%
Webcam→DSLR	59.2%	82.4%	88.7%	76.5%	84.9%	77.1%	75.8%
DSLR→Caltech	26.3%	30.9%	31.5%	27.3%	34.2%	31.2%	34.3%
DSLR→Amazon	28.5%	29.3%	32.6%	29.1%	38.1%	31.9%	36.5%
DSLR→Webcam	63.4%	84.8%	85.6%	65.7%	85.9%	69.5%	86.4%
平均值	34.8%	44.8%	45.2%	37.4%	48.0%	45.0%	48.6%

表4 在Amazon Review数据集上迁移学习任务的准确率对比

数据集	1-NN	TCA	BDA	JGSA	CORAL	SCOAD
Books→DVDs	49.6%	63.6%	64.2%	66.6%	71.6%	65.4%
Books→Electronics	49.8%	60.9%	62.1%	75.0%	65.1%	69.2%
Books→Kitchen	50.3%	64.2%	65.4%	72.1%	67.3%	74.0%
DVDs→Books	53.3%	63.3%	62.4%	55.5%	70.1%	72.4%
DVDs→Electronics	51.0%	64.2%	66.3%	67.3%	65.6%	70.0%
DVDs→Kitchen	53.1%	69.1%	68.9%	65.6%	67.1%	74.9%
Electronics→Books	50.8%	59.5%	59.2%	51.6%	67.1%	69.0%
Electronics→DVDs	50.9%	62.1%	61.6%	50.8%	66.2%	67.6%
Electronics→Kitchen	51.2%	74.8%	74.7%	55.0%	77.6%	81.0%
Kitchen→Books	52.2%	64.1%	62.7%	58.3%	68.2%	69.1%
Kitchen→DVDs	51.2%	65.4%	64.3%	56.4%	68.9%	69.6%
Kitchen→Electronics	52.3%	74.5%	74.0%	51.7%	75.4%	78.1%
平均值	51.3%	65.5%	65.5%	60.5%	69.2%	71.7%

学习任务上的准确率均高于 CORAL, 验证了本文算法在 CORAL 算法基础上结合子结构适配和子域内规划分类器的有效性, 迁移效果更佳。

本文还使用弗里德曼检验 (Friedman test) 对实验结果进一步分析。弗里德曼检验首先使用留一法或交叉验证法得到每个算法在每个数据集上的测试结果。然后, 在每个数据集上根据测试性能由好到坏排序, 并赋予序值, 若算法的测试性能相同, 则平分序值。最后对每一列的序值求平

均, 得到平均序值, 序值越小表示算法性能越好。在 MNIST + USPS、Office + Caltech10 数据集上的 Friedman 检验结果见表 5, 序值排序结果从高到低依次为 1-NN、OTDA、TCA、TJM、EASYTL、CORAL、SCOAD, 可知本文提出的 SCOAD 算法的序值最小为 2.14, 表明 SCOAD 的性能在这两个数据集上优于其他 6 种算法。几种算法在 Amazon Review 数据集上的 Friedman 检验结果见表 6, SCOAD 算法的序值小于其他 5 种算法, 表



表 5 在 MNIST + USPS、Office + Caltech10 数据集上表的 Friedman 检验结果

算法	1-NN	TCA	TJM	OTDA	CORAL	EASYTL	SCOAD
序值	6.35	4.25	3.50	5.78	2.71	3.24	2.14

表 6 在 Amazon Review 数据集上的 Friedman 检验结果


算法	1-NN	TCA	BDA	JGSA	CORAL	SCOAD
序值	5.83	3.58	3.83	4.08	2.42	1.25

明 SCOAD 算法的性能在 Amazon Review 数据集上仍然优于其他 5 种算法。

通过观察不同方法在不同数据集上的分类准确率平均值可看出, SCOAD 算法的分类准确率平均值最高。同时证明了本文算法采用的介于粗糙匹配和样本级匹配之间的子结构匹配和子域内规划在解决迁移学习任务中具有明显优势。综上所述,可以看出本文算法在各类数据集上的有效性和稳健性。

3.3 参数分析

为了分析实验中参数对算法性能的影响, 本文分别从 3 个数据集中选择 Amazon→DSLR (A→D)、MNIST→USPS (M→U)和 Electronics→Books (E→B) 3 组跨领域分类任务测试簇数 K 的参数敏感性, 3 组任务的类别数分别为 10、10、2, 簇数 K 对 SCODA 算法性能的影响如图 3 所示。在图 3 中可以发现, 在这 3 组不同任务中 SCOAD 算法在较大的参数范围内可以得到优于 TCA 算法的迁移学习性能。上述参数分析实验表明, SCOAD 算法能在较大的参数范围内保持较稳定的性能, 比其他算法更有效、更稳健。通过观察图 3 各组任务中分类准确率得到最大值时参数 K 的取值可知, 在不同数据集的不同任务中参数 K 的最优取值也不同, 迁移任务 A→D、M→U 和 E→B 分别在参数 K 取值为 28、221、5 时获得最好的分类效果。通过观察还能够得出, 在大于每组任务类别数的较大的参数范围内本文算法都能取得较好且较稳定的结果。总之, 本文算法能在较宽泛的参数范围内, 稳定地提高迁移学习的性能, 实现源域到目标域的有效迁移。

图 3 簇数 K 对 SCODA 算法性能的影响

4 结束语

本文提出基于 K -means 聚类的子结构相关适配迁移学习算法, 首先通过对齐源域和目标域子域中心的二阶协方差匹配分布, 再利用提出的子域内规划分类器对目标域样本进行分类。提出的方法考虑了更细粒度的域结构, 避免了噪声的影响, 具有一定的稳健性。在 3 个数据集上的实验表明本文方法具有良好的迁移学习性能。由于深度学习能够提取到更精准的特征, 大幅提高学习性能, 现已在迁移学习的研究中被广泛使用, 因此未来我们计划结合深度学习方法继续在细粒度的迁移学习方面进行探索。此外, 本文仅在迁移学习常用数据集中进行实验, 未来我们计划将方法应用在其他领域的数据集中, 以解决更多现实世界生产生活中的问题。

参考文献:

- [1] ZHUANG F Z, QI Z Y, DUAN K Y, et al. A comprehensive survey on transfer learning[J]. Proceedings of the IEEE, 2021, 109(1): 43-76.
- [2] GRETTON A, BORGWARDT K M, RASCH M J, et al. A kernel two-sample test[J]. The Journal of Machine Learning Research, 2012, 13(1): 723-773.
- [3] SUN B C, FENG J S, SAENKO K. Return of frustratingly easy domain adaptation[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2016, 30(1): 2058-2065.
- [4] GAO J, HUANG R, LI H X. Sub-domain adaptation learning methodology[J]. Information Sciences, 2015(298): 237-256.
- [5] ZHU Y C, ZHUANG F Z, WANG J D, et al. Deep subdomain adaptation network for image classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(4): 1713-1722.
- [6] KRISHNA K, NARASIMHA M M. Genetic K -means algorithm[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 1999, 29(3): 433-439.
- [7] HARTIGAN J A, WONG M A. A K -means clustering algorithm[J]. Journal of the Royal Statistical Society Series C: Applied Statistics, 1979, 28(1): 100-108.
- [8] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [9] HULL J J. A database for handwritten text recognition research[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1994, 16(5): 550-554.
- [10] GONG B Q, SHI Y, SHA F, et al. Geodesic flow kernel for unsupervised domain adaptation[C]//Proceedings of 2012 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2012: 2066-2073.
- [11] CHEN M, XU Z, WEINBERGER K, et al. Marginalized denoising autoencoders for domain adaptation[EB]. 2012: arXiv: 1206.4683.
- [12] JIANG S Y, XU Y H, SONG H J, et al. Multi-instance transfer metric learning by weighted distribution and consistent maximum likelihood estimation[J]. Neurocomputing, 2018(321): 49-60.
- [13] ZUO H, ZHANG G Q, BEHBOOD V, et al. Transfer learning in hierarchical feature spaces[C]//Proceedings of 2015 10th International Conference on Intelligent Systems and Knowledge Engineering (ISKE). Piscataway: IEEE Press, 2016: 183-188.
- [14] ZHAO Z, CHEN Y, LIU J, et al. Cross-people mobile-phone based activity recognition[C]//Proceedings of the 22th International Joint Conference on Artificial Intelligence. Barcelona, Catalonia, Spain: AAAI Press, 2011: 2545-2550.
- [15] WEI Y, ZHU Y, LEUNG C, et al. Instilling social to physical: Co-regularized heterogeneous transfer learning[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2016, 30(1): 1338-1344.
- [16] MIHALKOVA L, HUYNH T, MOONEY R J. Mapping and revising Markov logic networks for transfer learning[C]//Proceedings of the 22nd National Conference on Artificial Intelligence. Vancouver, BC, Canada: AAAI Press, 2007: 608-614.
- [17] MIHALKOVA L, MOONEY R J. Transfer learning by mapping with minimal target data[C]//Proceedings of the AAAI-08 Workshop on Transfer Learning for Complex Tasks. Chicago, IL, USA: AAAI Press, 2008: 1163-1168.
- [18] WANG M, DENG W. Deep visual domain adaptation: a survey[J]. Neurocomputing, 2018(312): 135-153.
- [19] LI J, HE R, YE H, et al. Unsupervised domain adaptation of a pretrained cross-lingual language model[J]. ArXiv, 2020, preprint arXiv: 2011.11499.
- [20] DAI Y, LIU J, REN X C, et al. Adversarial training based multi-source unsupervised domain adaptation for sentiment analysis[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(5): 7618-7625.
- [21] 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.
- [22] LONG M S, WANG J M, DING G G, et al. Transfer feature learning with joint distribution adaptation[C]//Proceedings of 2013 IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2014: 2200-2207.



- [23] WANG J D, CHEN Y Q, HAO S J, et al. Balanced distribution adaptation for transfer learning[C]//Proceedings of 2017 IEEE International Conference on Data Mining (ICDM). Piscataway: IEEE Press, 2017: 1129-1134.
- [24] COURT Y N, FLAMARY R, TUIA D, et al. Optimal transport for domain adaptation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(9): 1853-1865.
- [25] DAS D, LEE C S G. Unsupervised domain adaptation using regularized hyper-graph matching[C]//Proceedings of 2018 25th IEEE International Conference on Image Processing (ICIP). Piscataway: IEEE Press, 2018: 3758-3762.
- [26] PEI Z Y, CAO Z J, LONG M S, et al. Multi-adversarial domain adaptation[C]//Proceedings of the thirty-second AAAI Conference on Artificial Intelligence. New Orleans, LA, USA: AAAI Press, 2018.
- [27] KUMAR A, SATTIGERI P, WADHAWAN K, et al. Co-regularized alignment for unsupervised domain adaptation-[EB]. 2018, arXiv, 1811.05443.
- [28] ZHAO J C, DENG F, HE H B, et al. Local domain adaptation for cross-domain activity recognition[J]. IEEE Transactions on Human-Machine Systems, 2021, 51(1): 12-21.
- [29] ESTER M, KRIEGEL H P, SANDER J, et al. A density-based algorithm for discovering clusters in large spatial databases with noise[C]//Proceedings of the Second International Conference on Knowledge Discovery and Data Mining. Portland, OR, USA: AAAI Press, 1996: 226-231.
- [30] 徐晓, 丁世飞, 孙统凤, 等. 基于网格筛选的大规模密度峰值聚类算法[J]. 计算机研究与发展, 2018, 55(11): 2419-2429.
- XU X, DING S F, SUN T F, et al. Large-scale density peaks clustering algorithm based on grid screening[J]. Journal of Computer Research and Development, 2018, 55(11): 2419-2429.
- [31] LONG M S, WANG J M, DING G G, et al. Transfer joint matching for unsupervised domain adaptation[C]//Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition. New York: ACM, 2014: 1410-1417.
- [32] WANG J D, CHEN Y Q, YU H, et al. Easy transfer learning by exploiting intra-domain structures[C]//Proceedings of 2019 IEEE International Conference on Multimedia and Expo (ICME). Piscataway: IEEE Press, 2019: 1210-1215.
- [33] ZHANG J, LI W Q, OGUNBONA P. Joint geometrical and statistical alignment for visual domain adaptation[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2017: 5150-5158.
- [34] GONG B Q, GRAUMAN K, SHA F. Reshaping visual datasets for domain adaptation[C]//Proceedings of the 26th International Conference on Neural Information Processing Systems-Volume 1. New York: ACM, 2013: 1286-1294.

[作者简介]



刘昊双 (1996-), 女, 辽宁师范大学硕士生, 主要研究方向为数据挖掘、机器学习。



张永 (1975-), 男, 博士, 湖州师范学院教授、博士生导师, 主要研究方向为数据挖掘、智能计算。



曹莹波 (1999-), 女, 辽宁师范大学硕士生, 主要研究方向为机器学习、智能计算。