基于投影重构的领域适应字典对学习方法

周国华[1,2], 韩少勇[1,3], 徐亦卿[1], 顾晓清[4], 倪彤光[4], 殷新春[2]

[1] (常州工业职业技术学院信息工程学院 常州 213164)
[2] (扬州大学信息工程学院 扬州 225127)
[3] (郑州银行博士后科研工作站 郑州 450015)
[4] (常州大学计算机与人工智能学院 常州 213164)
(zgh@ciit.edu.cn)

摘 要: 图像识别中数据来源复杂, 不同领域的数据在分布上存在差异等问题. 为提高跨领域图像的识别能力, 提出了一种基于投影重构的领域适应字典对学习方法. 该方法采用交叉重构技术构建新的源域和目标域, 使用综合和分析字典对来对齐不同领域的样本, 并利用字典原子与类信息的关联将判别信息从源域传递到目标领域; 同时, 通过分析字典约束项提高字典的判别性, 通过源域目标域的分类判别项最小化每类数据的分类误差和最大化类间差异, 达到提高稀疏系数的判别性的目的. 利用 Caltech-256 和 Office 数据集进行的实验结果表明, 所提方法在 Surf 特征单源域和多源域实验中分别获得 54.99%和 58.64%分类精度; 在深度特征单源域和多源域实验中分别获得 91.43%和 92.66%分类精度.

关键词: 投影重构; 领域适应; 字典对学习; 图像识别
中图法分类号: TP391.41 **DOI:** 10.3724/SP.J.1089.2023-00480

Projection Reconstruction Based Domain-Adaptive Dictionary Pair Learning Method

Zhou Guohua[1,2], Han Shaoyong[1,3], Xu Yiqing[1], Gu Xiaoqing[4], Ni Tongguang[4], and Yin Xinchun[2]

[1] (*Department of Information Engineering, Changzhou Vocational Institute of Industry Technology, Changzhou* 213164)
[2] (*College of Information Engineering, Yangzhou University, Yangzhou* 225127)
[3] (*Postdoctoral Scientific Research Workstation, Bank of Zhengzhou, Zhengzhou* 450015)
[4] (*School of Computer Science and Artificial Intelligence, Changzhou University, Changzhou* 213164)

Abstract: The data sources in image recognition are complex, and there are differences in the distribution of data from different domains. To improve the recognition ability of cross-domain images, this paper proposes a projection reconstruction based domain-adaptive dictionary pair learning (PRDDPL) method. This method employs cross-reconstruction technique to construct new source and target domains, uses synthesis and analysis dictionary pairs to align samples in different domains, and utilizes the association of dictionary atoms with class information to transfer discriminative information from the source domain to the target domain. At the same time, the discriminative ability of the dictionary is improved by analyzing the dictionary constraints. By minimizing the linear classification error of each class of data and maximizing the difference between different classes, the discriminative ability of the sparse coefficients is improved through the classification discriminant of the source domain and target domain. The experiment is performed on the Cal-

收稿日期: 2023-07-26; 修回日期: 2024-02-27. **基金项目**: 国家自然科学基金(61806026); 江苏省教育厅未来网络科研基金(FNSRFP-2021-YB-36); 常州市第十一批科技计划(社会发展科技支撑)项目(CE20215032). **周国华**(1977—), 男, 硕士, 副教授, CCF 高级会员, 主要研究方向为智能学习、模式识别; **韩少勇**(1982—), 男, 博士, 副教授, 主要研究方向为智能信息处理; **徐亦卿**(1994—), 女, 博士, 讲师, 主要研究方向为智能信息处理; **顾晓清**(1981—), 女, 博士, 副教授, 硕士生导师, 主要研究方向为模式识别、模糊系统; **倪彤光**(1978—), 男, 博士, 副教授, 硕士生导师, 主要研究方向为人工智能、模式识别; **殷新春**(1962—), 男, 博士, 教授, 博士生导师, CCF 高级会员, 主要研究方向为人工智能、密码学.

tech-256 and Office datasets. The experimental results show that using Surf features the proposed method achieves the classification accuracy of 54.99% and 58.64% in single source domain and multi-source domain experiments, respectively. Using deep features, the proposed method achieves the classification accuracy of 91.43% and 92.66% in single source domain and multi-source domain experiments, respectively.

Key words: projection reconstruction; domain adaptation; dictionary pair learning; image recognition

随着计算机和互联网技术的飞速发展, 社交媒体的信息量呈指数形式增长, 在谷歌、百度和微博等网站, 每天都会产生大量的图像、文本和视频数据. 这些社交媒体数据是进行媒体数据分析、数据挖掘的基础. 在信息爆炸时代, 传统的人工进行数据分类早已不适用, 社交媒体的大数据处理越来越依赖人工智能技术, 如神经网络、稀疏编码和深度学习等. 近年来, 字典学习在计算机视觉领域取得了很大进展, 已成功地应用于图像分类和人脸识别等方向. 在稀疏编码和压缩感知的理论背景下, 字典学习旨在寻找一组合适的基来捕获输入数据的语义, 并将数据编码作为一组高保真编码表示, 使得数据易于操作和理解[1-2]. 与深度学习方法相比, 字典学习对计算机硬件的要求不高, 且不需要大量的训练数据就能完成模型的构建. 与传统的机器学习方法相似, 字典学习使用人工注释的数据训练模型, 同时假设测试数据和训练数据的数据分布相同. 然而, 在实际应用中, 由于人工注释的高昂成本和环境限制, 无法保证足够的训练数据且其与测试数据具有相同的分布, 在这种情况下, 训练数据不足会限制模型的分类效果[3].

为此, 研究者使用领域适应方法解决这一问题. 领域适应方法通过挖掘不同领域任务间共享的知识, 将它们作为相关领域(源领域)到目标领域的桥梁, 可以辅助完成目标任务[4]. 常用的领域适应方法有: 领域不变特征方法(如特征选择、实例加权等)、基于数据分布的自适应方法(如分布自适应、迁移联合匹配等)、共享子空间方法(如子空间对齐、引导子空间等)、深度迁移学习方法(如领域对抗学习、领域注意力机制)等[5-7]. 近年来, 研究者提出了不同类型的基于字典学习的领域适应方法. Ni 等[3]利用不同领域图像的全局结构和成对约束的信息, 将判别度量空间学习嵌入字典学习中得到领域共享字典. Wu 等[8]提出了一种结构化的判别张量字典学习方法, 其通过显式地分离数据中特定领域的因素和特定类别的因素, 产生可迁移数据表示, 进而达到样本分布对齐的目的. Shekhar 等[9]提出了类特定重构转移学习模型, 其联合学习不同领域中数据投影技术, 在投影低维空间中学习领域共享的潜在字典, 且能够扩展到非线性特征空间. Xu 等[10]提出了异构域适应的字典学习方法, 将 2 个域的数据嵌入到具有较低维度的特征空间中, 然后使用字典测量 2 个映射数据域之间的差异. Cai 等[11]提出了通过几何和统计适应来学习共享字典的方法, 使用 Nyström 逼近误差测量源域和目标域之间的距离, 并通过最小化领域之间的最大平均差异距离来获得潜在统计信息, 最后训练一个共享字典来处理跨领域数据分类. 上述字典学习方法主要通过学习领域共享字典来匹配不同数据域, 没有考虑字典与类信息间的关联, 因此, 字典的判别能力不强. 另外, 综合字典在求解编码系数时需要涉及计算负担较大的 ℓ_0 或 ℓ_1 范数最小化问题, 且容易导致 NP-hard 问题. 尽管一些贪婪方法可以求解上述问题, 如正交匹配追求(orthogonal matching pursuit, OMP), 但其通常只能找到次优稀疏解, 而不是最优稀疏解[12].

为提高跨领域图像的识别能力, 本文在不同领域数据对齐的基础上, 将交叉重构技术嵌入字典对学习模型, 提出了一种基于投影重构的领域适应字典对学习(projection reconstruction based domain-adaptive dictionary pair learning, PRDDPL)方法. PRDDPL 方法使用基于投影重构技术对源域和目标域进行交叉重构, 2 个领域联合学习共享的综合和分析字典对, 建立不同领域之间的桥梁, 并实现识别信息从源域到目标域的迁移. 数据交叉重排可有效地减少源域和目标域的分布差异; 同时, PRDDPL 利用字典原子与类信息的关联, 通过每类数据的子字典来增强字典的识别能力. 此外, PRDDPL 方法充分地利用已知样本的标签信息, 在模型中加入源域和目标域的分类器项, 在最小化每类数据的分类误差同时最大化类别间的差异, 以提高方法对各类数据的区分度. 在 Office 和 Caltech-256 数据集上的实验结果表明, PRDDPL 方法的识别正确率高于对比方法.

1　字典学习

1.1　综合分析字典对

设有 c 类数据 $[\boldsymbol{X}_1,\boldsymbol{X}_2,\cdots,\boldsymbol{X}_c]\in\mathbb{R}^{d\times N}$, d 表示数据维数, N 表示样本个数; 第 l 类数据为 $\boldsymbol{X}_l\in\mathbb{R}^{d\times N_l}$, N_l 表示第 l 类样本的个数, 则有 $\sum_{l=1}^{c}N_l=N$. 综合字典 $\boldsymbol{D}$ 基于每类样本学习子字典, 利用少量字典原子的线性组合来稀疏表示样本, 分析字典 $\boldsymbol{P}$ 将样本投影到稀疏编码特征空间. 在综合字典 $\boldsymbol{D}$ 和分析字典 $\boldsymbol{P}$ 共同作用下, 综合分析字典对方法的目标函数[13-14]为

$$\begin{aligned}&\arg\min_{\boldsymbol{P},\boldsymbol{D}}\sum_{l=1}^{c}\left\|\boldsymbol{X}_l-\boldsymbol{D}_l\boldsymbol{P}_l\boldsymbol{X}_l\right\|_{\mathrm{F}}^2+\lambda\left\|\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{\mathrm{F}}^2,\\&\text{s.t. }\left\|d_i\right\|_2^2\leqslant 1,\forall i\end{aligned}\tag{1}$$

其中, $\bar{\boldsymbol{X}}_l$ 表示 $\boldsymbol{X}$ 中 $\boldsymbol{X}_l$ 的补集; $\boldsymbol{D}_l\in\mathbb{R}^{d\times K_l}$ 表示在 $\boldsymbol{X}_l$ 上的综合字典, K_l 表示原子维数, $\sum_{l=1}^{c}K_l=K$; $\boldsymbol{P}_l\in\mathbb{R}^{K_l\times d}$ 表示第 l 类数据的分析字典; c 个类别的 $\boldsymbol{D}_l$ 和 $\boldsymbol{P}_l$ 排列构成训练集 $\boldsymbol{X}$ 上的综合字典 $\boldsymbol{D}=[\boldsymbol{D}_1,\boldsymbol{D}_2,\cdots,\boldsymbol{D}_k,\cdots,\boldsymbol{D}_c]\in\mathbb{R}^{d\times K}$ 和分析字典 $\boldsymbol{P}=[\boldsymbol{P}_1,\cdots,\boldsymbol{P}_k,\cdots,\boldsymbol{P}_c]\in\mathbb{R}^{K\times d}$. 与传统的综合字典学习相比, 综合分析字典对学习添加了分析字典, 可由 $\boldsymbol{PX}$ 求得 $\boldsymbol{X}$ 对应的稀疏系数矩阵. 式(1)中的第 2 项约束 $\left\|\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{\mathrm{F}}^2$ 可转换为 $\boldsymbol{P}_i\boldsymbol{X}_j\approx 0,\forall i\neq j$, 使 $\boldsymbol{PX}$ 矩阵近似为块对角矩阵, 可提高模型的运算效率.

1.2　投影双重构字典学习

源域和目标域数据分别表示为

$$\tilde{\boldsymbol{X}}_{\mathrm{S}}=\left[\tilde{\boldsymbol{X}}_{\mathrm{S}}^1,\tilde{\boldsymbol{X}}_{\mathrm{S}}^2,\cdots,\tilde{\boldsymbol{X}}_{\mathrm{S}}^c\right]\in\mathbb{R}^{d\times N_{\mathrm{S}}},$$

$$\tilde{\boldsymbol{X}}_{\mathrm{T}}=\left[\tilde{\boldsymbol{X}}_{\mathrm{T}}^1,\tilde{\boldsymbol{X}}_{\mathrm{T}}^2,\cdots,\tilde{\boldsymbol{X}}_{\mathrm{T}}^c\right]\in\mathbb{R}^{d\times N_{\mathrm{T}}}.$$

其中, $\tilde{\boldsymbol{X}}_{\mathrm{S}}^i$ 和 $\tilde{\boldsymbol{X}}_{\mathrm{T}}^i(i=1,2,\cdots,c)$ 分别表示源领域和目标领域第 i 类样本. PDR 方法[11]的核心是提出了一种用于领域适应的数据交叉重构方法, 根据样本的类别, 重新构造源域和目标域分别为

$$\tilde{\boldsymbol{X}}=\left[\tilde{\boldsymbol{X}}_{\mathrm{S}}^1\tilde{\boldsymbol{X}}_{\mathrm{T}}^1,\tilde{\boldsymbol{X}}_{\mathrm{S}}^2\tilde{\boldsymbol{X}}_{\mathrm{T}}^2,\cdots,\tilde{\boldsymbol{X}}_{\mathrm{S}}^c\tilde{\boldsymbol{X}}_{\mathrm{T}}^c\right],$$

$$\tilde{\boldsymbol{Y}}=\left[\tilde{\boldsymbol{X}}_{\mathrm{T}}^1\tilde{\boldsymbol{X}}_{\mathrm{S}}^1,\tilde{\boldsymbol{X}}_{\mathrm{T}}^2\tilde{\boldsymbol{X}}_{\mathrm{S}}^2,\cdots,\tilde{\boldsymbol{X}}_{\mathrm{T}}^c\tilde{\boldsymbol{X}}_{\mathrm{S}}^c\right].$$

其初衷是利用交叉数据的差异性和相关性来降低领域适应学习中多领域数据的分布差异[15]. 基于得到的新训练数据 $\tilde{\boldsymbol{X}}$ 和 $\tilde{\boldsymbol{Y}}$, 投影双重构(projective double reconstructions, PDR)字典学习[15]目标式表示为

$$\begin{aligned}&\min_{\boldsymbol{P},\boldsymbol{D}}\left\|\tilde{\boldsymbol{X}}-\boldsymbol{DP}\tilde{\boldsymbol{X}}\right\|_{\mathrm{F}}^2+\left\|\tilde{\boldsymbol{X}}-\boldsymbol{DP}\tilde{\boldsymbol{Y}}\right\|_{\mathrm{F}}^2,\\&\text{s.t. }\boldsymbol{d}_i^{\mathrm{T}}\boldsymbol{d}_i=1,\forall i\end{aligned}\tag{2}$$

其中, $\left\|\tilde{\boldsymbol{X}}-\boldsymbol{DP}\tilde{\boldsymbol{X}}\right\|_{\mathrm{F}}^2$ 表示模型具有数据自重构能力. 分析字典 $\boldsymbol{P}$ 起到投影矩阵的作用, 数据 $\tilde{\boldsymbol{X}}$ 的交叉重构表示为 $\tilde{\boldsymbol{X}}=\boldsymbol{DP}\tilde{\boldsymbol{Y}}$. 因此, 它表示模型具有投影的交叉重构能力. 与式(1)相比, PDR 方法使用对齐的多领域数据, 兼顾自重构和交叉重构, 能较好地适用于领域适应学习. 但通过式(2)可以看出, PDR 方法是将综合字典和分析字典建立在整个训练集上, 未考虑类间分离性和类别独立性.

2　本文方法

2.1　目标函数

假设原始源域和目标域数据集包含 c 类样本, 在式(2)的基础上, PRDDPL 方法依据样本的类别信息重构源域和目标域得到新源域和新目标域, 分别表示为 $\boldsymbol{X}=\left[\tilde{\boldsymbol{X}}_1,\tilde{\boldsymbol{X}}_2,\cdots,\tilde{\boldsymbol{X}}_c\right]$ 和 $\boldsymbol{Y}=\left[\tilde{\boldsymbol{Y}}_1,\tilde{\boldsymbol{Y}}_2,\cdots,\tilde{\boldsymbol{Y}}_c\right]$. 第 l 类样本对应的综合子字典表示为 $\boldsymbol{D}_l(1\leqslant l\leqslant c)$, 第 l 类样本对应的分析子字典, 即分析字典 $\boldsymbol{P}$ 表示为 $\boldsymbol{P}_l(1\leqslant l\leqslant c)$. 基于投影重构的领域适应字典对学习的示意图如图 1 所示, 建立每个类别上的数据自重构和交叉重构项表示为

$$\left\|\boldsymbol{X}_l-\boldsymbol{D}_l\boldsymbol{P}_l\boldsymbol{X}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{X}_l-\boldsymbol{D}_l\boldsymbol{P}_l\boldsymbol{Y}_l\right\|_{\mathrm{F}}^2\tag{3}$$

与式(2)相比, PRDDPL 方法基于每个子类数据构建类关联的综合子字典和分析子字典, 促使学习到的 $\boldsymbol{D}_l$ 和 $\boldsymbol{P}_l$ 具有较好的判别能力, 更适用于分类任务.

PRDDPL 方法构建分析字典约束项, 即每个 $\boldsymbol{P}_l$ 将第 l 类样本 $\boldsymbol{X}_l$ 和 $\boldsymbol{Y}_l$ 投影到非零稀疏空间, 而将非 l 类样本投影到近似的零空间, 可以得到

$$\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\approx 0,\quad \boldsymbol{P}_l\bar{\boldsymbol{Y}}_l\approx 0\tag{4}$$

其中, $\bar{\boldsymbol{X}}_l$ 和 $\bar{\boldsymbol{Y}}_l$ 分别表示 $\boldsymbol{X}_l$ 和 $\boldsymbol{Y}_l$ 的补集. 显然, $\boldsymbol{P}_l\boldsymbol{X}_l$ 和 $\boldsymbol{P}_l\boldsymbol{Y}_l$ 在式(3)的约束下能够得到近似块对角结构, 进而可以提高模型的判别能力. 为了充分地利用样本的标签信息, PRDDPL 方法融入类别的标签和判别信息, 在每个类别样本上引入线性分类器. 设 $\boldsymbol{W}_l\in\mathbb{R}^{c\times K_l}$ 是分类器, 新源域的第 l 类样本的分类误差项为 $\left\|\boldsymbol{H}_l-\boldsymbol{W}_l\boldsymbol{P}_l\boldsymbol{X}_l\right\|_{\mathrm{F}}^2$; 其中, $\boldsymbol{H}_l$ 表示 $\boldsymbol{X}_l$ 的类别标签矩阵. 不同类别的样本特征表示不相同, 每个类别对应的分类器也应具有类别差异

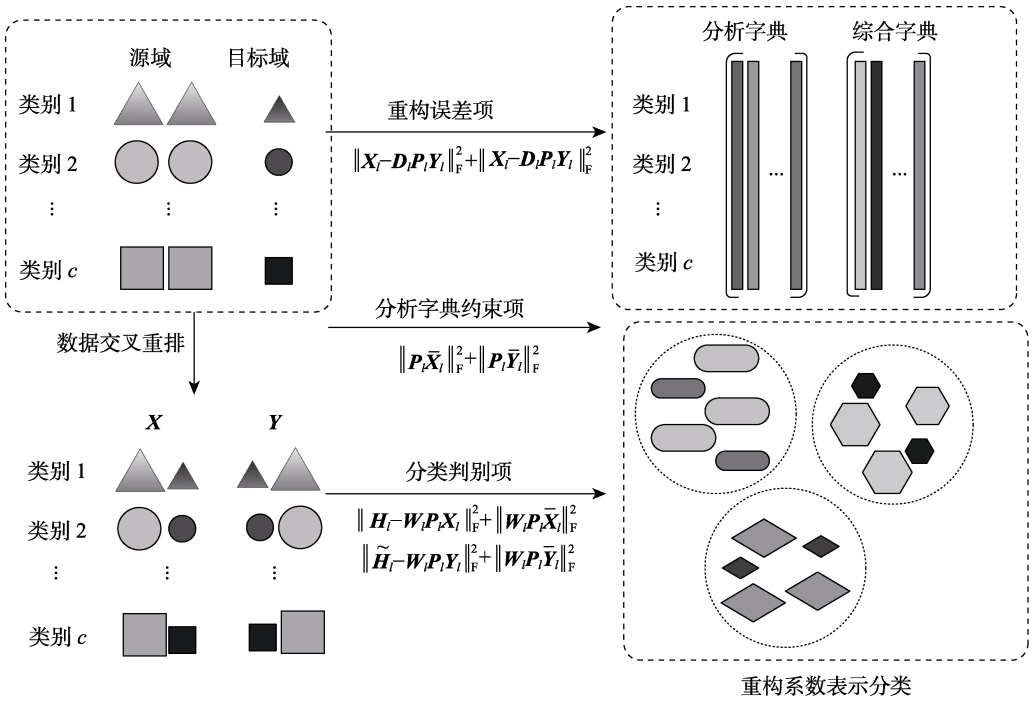


图 1 基于投影重构的领域适应字典对学习的示意图

性和独立性, 一个具有良好分类性能的分类器 $\boldsymbol{W}_l$ 可以将非 l 类样本的标签预测到近似零空间, 即 $\left\|\boldsymbol{W}_l\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{\mathrm{F}}^2\approx 0$. 因此, 可得 PRDDPL 方法中关于源域 $\boldsymbol{X}_l$ 的分类判别项表示为

$$\left\|\boldsymbol{H}_l-\boldsymbol{W}_l\boldsymbol{P}_l\boldsymbol{X}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{W}_l\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{\mathrm{F}}^2 \tag{5}$$

类似地, 关于目标域 $\boldsymbol{X}_l$ 的分类器项表示为

$$\left\|\tilde{\boldsymbol{H}}_l-\boldsymbol{W}_l\boldsymbol{P}_l\boldsymbol{Y}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{W}_l\boldsymbol{P}_l\bar{\boldsymbol{Y}}_l\right\|_{\mathrm{F}}^2 \tag{6}$$

其中, $\tilde{\boldsymbol{H}}_l$ 是目标域 $\boldsymbol{Y}_l$ 的类别标签矩阵.

结合式(3)~式(6), PRDDPL 方法的目标函数为

$$\begin{aligned}\min_{\boldsymbol{D},\boldsymbol{P},\boldsymbol{W}}\sum_{l=1}^{c}\Big\{&\left\|\boldsymbol{X}_l-\boldsymbol{D}_l\boldsymbol{P}_l\boldsymbol{X}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{X}_l-\boldsymbol{D}_l\boldsymbol{P}_l\boldsymbol{Y}_l\right\|_{\mathrm{F}}^2+\\&\lambda\left(\left\|\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{P}_l\bar{\boldsymbol{Y}}_l\right\|_{\mathrm{F}}^2\right)+\\&\eta\left(\left\|\boldsymbol{H}_l-\boldsymbol{W}_l\boldsymbol{P}_l\boldsymbol{X}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{W}_l\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{\mathrm{F}}^2\right)+\\&\gamma\left(\left\|\tilde{\boldsymbol{H}}_l-\boldsymbol{W}_l\boldsymbol{P}_l\boldsymbol{Y}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{W}_l\boldsymbol{P}_l\bar{\boldsymbol{Y}}_l\right\|_{\mathrm{F}}^2\right)\Big\}\\&\text{s.t. }\boldsymbol{d}_i^{\mathrm{T}}\boldsymbol{d}_i=1,\forall i\end{aligned} \tag{7}$$

其中, λ, γ 和 η 为平衡因子.

式(7)中, 第 1 项 $\left\|\boldsymbol{X}_l-\boldsymbol{D}_l\boldsymbol{P}_l\boldsymbol{X}_l\right\|_{\mathrm{F}}^2$ 表示数据交叉重排之后源域的自重构误差项, 以保证学习得到的综合字典具备较强的重构能力. 第 2 项 $\left\|\boldsymbol{X}_l-\boldsymbol{D}_l\boldsymbol{P}_l\boldsymbol{Y}_l\right\|_{\mathrm{F}}^2$ 表示交叉重排数据与次序相反的交叉重构误差项, 目的是利用源领域和目标领域中同类别数据的类别特性. 第 3 项 $\left\|\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{P}_l\bar{\boldsymbol{Y}}_l\right\|_{\mathrm{F}}^2$ 表示分析字典约束项, 效果为 $\boldsymbol{P}_i\boldsymbol{X}_j\approx 0$, $\boldsymbol{P}_i\boldsymbol{Y}_j\approx 0$, $\forall i\neq j$, 从而使得 $\boldsymbol{PX}$ 和 $\boldsymbol{PY}$ 尽可能地呈现块对角矩阵的效果. 第 4 项 $\left\|\boldsymbol{H}_l-\boldsymbol{W}_l\boldsymbol{P}_l\boldsymbol{X}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{W}_l\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{\mathrm{F}}^2$ 为源域上的分类判别项, 使用分类器 $\boldsymbol{W}_l$ 将数据转换到标签空间, 并利用分类误差最小化来提升字典的分类能力; 同时该项也约束了每类 $\boldsymbol{W}_l$ 和其他类数据的关系, 效果为 $\boldsymbol{W}_i\boldsymbol{P}_i\boldsymbol{X}_j\approx 0$, $\forall i\neq j$, 从而使得 $\left\|\boldsymbol{W}_l\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{\mathrm{F}}^2$ 的结果应近似为零. 第 5 项 $\left\|\tilde{\boldsymbol{H}}_l-\boldsymbol{W}_l\boldsymbol{P}_l\boldsymbol{Y}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{W}_l\boldsymbol{P}_l\bar{\boldsymbol{Y}}_l\right\|_{\mathrm{F}}^2$ 为目标域上的分类判别项, 其效果与第 4 项一致.

2.2 模型求解

PRDDPL 方法目标函数是非凸的, 本文使用交替优化的方式更新参数 $\{\boldsymbol{D},\boldsymbol{P},\boldsymbol{W}\}$.

(1) 固定 $\{\boldsymbol{D},\boldsymbol{W}\}$ 更新 $\boldsymbol{P}$, 目标式表示为

$$\begin{aligned}&\left\|\boldsymbol{X}_l-\boldsymbol{D}_l\boldsymbol{P}_l\boldsymbol{X}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{X}_l-\boldsymbol{D}_l\boldsymbol{P}_l\boldsymbol{Y}_l\right\|_{\mathrm{F}}^2+\\&\lambda\left(\left\|\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{F}^2+\left\|\boldsymbol{P}_l\bar{\boldsymbol{Y}}_l\right\|_{\mathrm{F}}^2\right)+\\&\eta\left(\left\|\boldsymbol{H}_l-\boldsymbol{W}_l\boldsymbol{P}_l\boldsymbol{X}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{W}_l\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{\mathrm{F}}^2\right)+\\&\gamma\left(\left\|\tilde{\boldsymbol{H}}_l-\boldsymbol{W}_l\boldsymbol{P}_l\boldsymbol{Y}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{W}_l\boldsymbol{P}_l\bar{\boldsymbol{Y}}_l\right\|_{\mathrm{F}}^2\right)\end{aligned} \tag{8}$$

对 $\boldsymbol{P}_l$ 求一阶导数, 可得 $\boldsymbol{P}_l$ 的更新表达式

$$\boldsymbol{P}_l^{*}=\left(2\lambda\boldsymbol{I}+(\eta+\gamma)\boldsymbol{W}_l^{\mathrm{T}}\boldsymbol{W}_l+2\boldsymbol{D}_l^{\mathrm{T}}\boldsymbol{D}_l\right)^{-1}\times$$
$$\left(\boldsymbol{D}_l^{\mathrm{T}}\boldsymbol{X}_l\boldsymbol{X}_l^{\mathrm{T}}+\boldsymbol{D}_l^{\mathrm{T}}\boldsymbol{X}_l\boldsymbol{Y}_l^{\mathrm{T}}+\eta\boldsymbol{W}_l^{\mathrm{T}}\boldsymbol{H}_l\boldsymbol{X}_l^{\mathrm{T}}+\gamma\boldsymbol{W}_l^{\mathrm{T}}\tilde{\boldsymbol{H}}_l\boldsymbol{X}_l^{\mathrm{T}}\right)\times$$
$$\left(\boldsymbol{X}_l\boldsymbol{X}_l^{\mathrm{T}}+\boldsymbol{Y}_l\boldsymbol{Y}_l^{\mathrm{T}}+\bar{\boldsymbol{X}}_l\bar{\boldsymbol{X}}_l^{\mathrm{T}}+\bar{\boldsymbol{Y}}_l\bar{\boldsymbol{Y}}_l^{\mathrm{T}}\right)^{-1} \tag{9}$$

(2) 固定 $\{\boldsymbol{P},\boldsymbol{W}\}$ 更新 $\boldsymbol{D}$, 目标式表示为

$$\min_{\boldsymbol{D}}\sum_{l=1}^{c}\left\{\left\|\boldsymbol{X}_l-\boldsymbol{D}_l\boldsymbol{P}_l\boldsymbol{X}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{X}_l-\boldsymbol{D}_l\boldsymbol{P}_l\boldsymbol{Y}_l\right\|_{\mathrm{F}}^2\right\}$$
$$\text{s.t. } \boldsymbol{d}_i^{\mathrm{T}}\boldsymbol{d}_i=1 \tag{10}$$

引入 $\boldsymbol{S}_l$ 和 $\boldsymbol{T}_l$ 辅助变量矩阵, $\boldsymbol{D}_l$ 可使用交替乘子(alternating direction method of multipliers, ADMM)方法[16]进行求解. $\boldsymbol{D}_l$ 的第 r+1 次迭代表达式为

$$\begin{cases}\boldsymbol{D}_l^{(r+1)}=\min\limits_{\boldsymbol{D}}\sum\limits_{l=1}^{c}\left\{\left\|\boldsymbol{X}_l-\boldsymbol{D}_l^{(r)}\boldsymbol{P}_l\boldsymbol{X}_l\right\|_{\mathrm{F}}^2+\right.\\ \quad\left.\left\|\boldsymbol{X}_l-\boldsymbol{D}_l^{(r)}\boldsymbol{P}_l\boldsymbol{Y}_l\right\|_{\mathrm{F}}^2+\rho\left\|\boldsymbol{D}_l^{(r)}-\boldsymbol{S}_l^{(r)}+\boldsymbol{T}_l^{(r)}\right\|_{\mathrm{F}}^2\right\}\\ \boldsymbol{S}_l^{(r+1)}=\min\limits_{\boldsymbol{S}}\sum\limits_{l=1}^{c}\rho\left\|\boldsymbol{D}_l^{(r+1)}-\boldsymbol{S}_l^{(r)}+\boldsymbol{T}_l^{(r)}\right\|_{\mathrm{F}}^2\\ \quad\text{s.t. } \left\|\boldsymbol{s}_i\right\|_2^2\leqslant 1,\\ \boldsymbol{T}_l^{(r+1)}=\boldsymbol{D}_l^{(r+1)}-\boldsymbol{S}_l^{(r+1)}+\boldsymbol{T}_l^{(r)}\end{cases} \tag{11}$$

(3) 固定 $\{\boldsymbol{D},\boldsymbol{P}\}$ 更新 $\boldsymbol{W}$, 目标式表示为

$$\min_{\boldsymbol{P}}\sum_{l=1}^{c}\left\{\eta\left(\left\|\boldsymbol{H}_l-\boldsymbol{W}_l\boldsymbol{P}_l\boldsymbol{X}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{W}_l\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{\mathrm{F}}^2\right)+\right.$$
$$\left.\gamma\left(\left\|\tilde{\boldsymbol{H}}_l-\boldsymbol{W}_l\boldsymbol{P}_l\boldsymbol{Y}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{W}_l\boldsymbol{P}_l\bar{\boldsymbol{Y}}_l\right\|_{\mathrm{F}}^2\right)\right\} \tag{12}$$

对 $\boldsymbol{W}_l$ 一阶求导, 可得 $\boldsymbol{W}_l$ 的更新表达式

$$\boldsymbol{W}_l^{*}=\left(\eta\boldsymbol{H}_l\boldsymbol{X}_l^{\mathrm{T}}\boldsymbol{P}_l^{\mathrm{T}}+\gamma\boldsymbol{H}_l\boldsymbol{Y}_l^{\mathrm{T}}\boldsymbol{P}_l^{\mathrm{T}}\right)\left(\eta\boldsymbol{P}_l\boldsymbol{X}_l\boldsymbol{X}_l^{\mathrm{T}}\boldsymbol{P}_l^{\mathrm{T}}+\right.$$
$$\left.\eta\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\bar{\boldsymbol{X}}_l^{\mathrm{T}}\boldsymbol{P}_l^{\mathrm{T}}+\gamma\boldsymbol{P}_l\boldsymbol{Y}_l\boldsymbol{Y}_l^{\mathrm{T}}\boldsymbol{P}_l^{\mathrm{T}}+\gamma\boldsymbol{P}_l\bar{\boldsymbol{Y}}_l\bar{\boldsymbol{Y}}_l^{\mathrm{T}}\boldsymbol{P}_l^{\mathrm{T}}\right)^{-1} \tag{13}$$

经过上述参数迭代, 可得参数 $\{\boldsymbol{D},\boldsymbol{P},\boldsymbol{W}\}$ 的最优解. 对于任意目标域样本 $\boldsymbol{x}$, 其第 l 类的重构系数表示为 $\boldsymbol{S}_l=\left(\boldsymbol{D}_l^{\mathrm{T}}\boldsymbol{D}_l\right)\boldsymbol{D}_l^{\mathrm{T}}\boldsymbol{x}$, 根据分类器 $\boldsymbol{W}_l$ 估计其类别标签 $h=\mathrm{sign}\left(\boldsymbol{W}_l\boldsymbol{S}_l\right)$, 最后, 将 $\boldsymbol{x}$ 判别为 h 中最大元素对应的类别.

2.3　算法描述和时间复杂度

本文方法具体步骤如下.

输入. 带标签的源域数据 $\tilde{\boldsymbol{X}}_{\mathrm{S}}$ 和目标域数据 $\tilde{\boldsymbol{X}}_{\mathrm{T}}$.

输出. 测试样本 $\boldsymbol{x}$ 的分类类别.

Step1. 由 $\tilde{\boldsymbol{X}}_{\mathrm{S}}$ 和 $\tilde{\boldsymbol{X}}_{\mathrm{T}}$ 构造新源域 $\tilde{\boldsymbol{X}}$ 和目标域 $\tilde{\boldsymbol{Y}}$.

Step2. 由式(1)初始化字典 $\boldsymbol{D}$;

For t<T do

Step2.1. 固定参数 $\boldsymbol{D}$ 和 $\boldsymbol{W}$, 由式(9)更新参数 $\boldsymbol{P}$;

Step2.2. 固定参数 $\boldsymbol{P}$ 和 $\boldsymbol{W}$, 由式(11)更新参数 $\boldsymbol{D}$;

Step2.3. 固定参数 $\boldsymbol{D}$ 和 $\boldsymbol{P}$, 由式(13)更新参数 $\boldsymbol{W}$.

end

Step3. 计算 $\boldsymbol{x}$ 的重构系数 $\boldsymbol{S}_l=(\boldsymbol{D}_l^{\mathrm{T}}\boldsymbol{D}_l)\boldsymbol{D}_l^{\mathrm{T}}\boldsymbol{x}$.

Step4. 计算 $\boldsymbol{x}$ 类别标签 $h=\mathrm{sign}(\boldsymbol{W}_l\boldsymbol{S}_l)$.

PRDDPL 方法的时间复杂度主要为更新参数 $\{\boldsymbol{P},\boldsymbol{D},\boldsymbol{W}\}$. 由式(9)更新参数 $\boldsymbol{P}$, 由于在更新过程中矩阵 $\boldsymbol{X}_l\boldsymbol{X}_l^{\mathrm{T}}$, $\boldsymbol{X}_l\boldsymbol{Y}_l^{\mathrm{T}}$, $\bar{\boldsymbol{X}}_l\bar{\boldsymbol{X}}_l^{\mathrm{T}}$ 和 $\bar{\boldsymbol{Y}}_l\bar{\boldsymbol{Y}}_l^{\mathrm{T}}$ 等矩阵的乘积可以预先求得且在更新过程中保持不变, 因此, 其时间复杂度为 $O(c^2\times K+K^2\times d+c^3+K\times d^2)$. 由式(11)更新参数 $\boldsymbol{D}$, 其时间复杂度为 $O(d^2\times(n+K)+n^2\times d+K^2\times d)$. 由式(13)更新参数 $\boldsymbol{W}$, 其时间复杂度为 $O(c\times K\times d+K^2\times d+K^3)$. 将这 3 种的时间复杂度相加, 考虑字典学习图像分类场景中 $c\ll n, c\ll d, c\ll K$ 且 $K<d$, PRDDPL 方法的时间复杂度为 $O(d^2\times K+n^2\times d)$.

3　实　验

3.1　数据集和实验设置

实验数据来自 2 个公共数据集 Caltech-256 和 Office[17], 它们均包括大量社交媒体图像. C(Caltech-256)数据集包含 256 个类别的 30 607 幅图像. Office 数据集包含亚马逊(Amazon, A)、数码单反(digital single-lens reflex camera, D)和网络摄像头(webcam, W)的 31 个对象共 4 652 幅图像. 图 2 列出了数据集 Caltech-256 和 Office 的示例图像, 其中第 1 列是 Caltech-256 数据集, 后 3 列分别是 Office 的子集 Amazon, DSLR 和 webcam. 在 4 个领域的 10 个类别图像开展对比实验, 分成单源域和多源域实验. 首先, 从单个领域选择一个作为源域, 从剩余的 3 个领域中选择一个作为目标域, 由此构成 12 组领域迁移图像识别实验, 如 D→A 跨领域实验中 DSLR 和 Amazon 分别是源域数据和目标域. 根据文献[18-19]的设置, 源域和目标域的每个类别分别随机选择 20 幅和 8 幅图像作为训练样本, 剩余的目标域样本作为测试样本. 其次, 多源域实验中源域来自 2 个数据集, 如 A, W→C 表示 Amazon 和 webcam 作为源域数据, Caltech-256 作为目标域数据. 参照文献[20], 实验中图像使用 Surf(speed up robust feature)特征[20]和由深度卷积 DeCAF 模型训练得到的深度特征[21], 图像的维数分别是 800 维和 4 096 维. 实验通过图像随机选择的方式重复 10 次, 这 10 次的平均分类准确率作为方法评价依据.

实验比较了 7 种领域适应方法: 低秩稀疏表示的判别迁移子空间学习(discriminative transfer subspace learning via low-rank and sparse representation, LRSR)[22]、潜在稀疏域迁移学习方法(latent sparse



图 2 Caltech-256 和 Office 数据集的示例图像

domain transfer learning, LSDT)[23]、基于相对距离比较的无监督迁移学习方法(unsupervised transfer learning via relative distance comparisons, UTRDC)方法[17]、核嵌入领域适应(geodesic kernel embedding distribution alignment for domain adaptation, GKDA)方法[24]、局部 Fisher 领域适应判别分析(locality Fisher discriminant analysis for conditional domain adaption, LFDA-CDA)方法[25]、基于集合与自然分类的稀疏描述(ensemble and nature inclined classification with sparse depiction, ENIC)方法[26]和基于式(2)的 PDR[15]方法. 所有方法均使用原文的默认参数设置, 其中 LFDA-CDA 方法中参数 λ 的选择范围为[0,1], 字典的大小设置为 $K\in[5,8,\cdots,26]\times$ 训练样本; 它们的正则化参数的选择范围均为 $\{10^{-3},10^{-2},\cdots,10^{3}\}$.

3.2 实验结果

表 1 所示为使用 Surf 特征时 12 个单源域实验的分类准确率, 其中, PRDDPL 方法在所有单源域实验上取得了最好的分类准确率. 例如, 在 A→D 数据集上, PRDDPL 的平均分类准确率比 LRSR 高 13.58 个百分点, 比次优方法 ENIC 高出 3.78 个百分点在 C→W 数据集上, PRDDPL 的平均分类准确率比 LRSR 高 12.80 个百分点, 比次优方法 PDR 高 2.28 个百分点. 表 2 所示为使用 Surf 特征时的多源域分类准确率. 从实验结果看, PRDDPL 方法在图像识别中是有效的. 对比方法中, LRSR 方法将源域数据和目标域数据投影到共享子空间, 每个目标域数据都使用源域数据进行重构. LSDT 方法是基于稀疏子空间聚类的稀疏编码方法, 在最优子空间中选择部分源域数据用于重构目标域数据. UTRDC 是一种基于核技术的迁移学习方法, 其使用相对距离比较约束来保存判别信息. GKDA 方法则利用测地核映射特征避免退化特征变换, 然后在降维过程中原则上调整跨域实例的权重, 最后构造一个新的特征来表示分布和无关实例的差异. LFDA-CDA 方法使用 Bregman 散度在嵌入式子空间中找到跨域的特征的线性组合. ENIC 是一种基于迁移学习的非负矩阵因子分解和亲和仿射方法. 实验结果表明, 这些方法对图像识别的效果都不如 PRDDPL. PRDDPL 方法结合数据重构和综合分析字典对学习技术, 数据重构保证了子空间中不同领域数据的对齐; 源域和目标域共享的综合字典则实现判别信息从源域到目标域的有效传递. 另外, 分析字典约束项和分类判别项提升了模型的判别能力. 因此, PRDDPL 方法对各类数据的识别率都较高, 在单源域实验上取得了令人满意的结果.

表 1 使用 Surf 特征单源域上各方法分类准确率(±标准差)比较 %

数据集	LRSR[22]	LSDT[23]	UTRDC[17]	GKDA[24]	LFDA-CDA[25]	ENIC[26]	PDR[15]	PRDDPL
C→A	40.01(±1.86)	43.73(±1.72)	45.39(±1.92)	46.31(±1.55)	47.26(±1.71)	48.97(±1.88)	49.33(±1.81)	**50.33**(±1.79)
C→W	38.75(±1.13)	42.47(±1.47)	44.01(±1.75)	45.78(±1.48)	47.34(±1.79)	49.02(±1.35)	49.27(±1.30)	**51.55**(±1.26)
C→D	43.67(±1.35)	45.99(±1.57)	47.97(±1.45)	48.72(±1.52)	49.56(±1.63)	52.11(±1.69)	52.70(±1.58)	**54.48**(±1.23)
A→C	36.56(±1.54)	38.14(±1.60)	40.43(±1.60)	42.11(±1.37)	43.24(±1.72)	44.93(±1.70)	45.85(±1.65)	**46.86**(±1.16)
A→W	32.08(±1.36)	36.84(±1.47)	36.49(±1.76)	37.33(±1.20)	39.10(±1.84)	40.86(±1.75)	41.31(±1.69)	**42.95**(±1.77)
A→D	37.96(±1.47)	41.55(±1.80)	42.71(±1.54)	45.11(±1.27)	45.28(±1.90)	47.76(±1.78)	47.25(±1.72)	**51.54**(±1.67)
W→C	37.39(±1.63)	41.99(±1.72)	43.06(±1.78)	44.47(±1.89)	45.04(±1.56)	47.01(±1.61)	47.98(±1.57)	**48.24**(±1.50)
W→A	34.39(±1.37)	40.36(±1.28)	41.38(±1.45)	42.55(±1.09)	42.56(±1.29)	43.97(±1.40)	44.12(±1.28)	**45.27**(±1.16)
W→D	76.62(±1.46)	80.28(±1.40)	82.15(±1.24)	83.18(±1.63)	82.28(±1.50)	83.83(±1.40)	84.16(±1.30)	**84.54**(±1.21)
D→C	34.23(±1.40)	38.01(±1.35)	39.41(±1.72)	42.10(±1.60)	44.46(±1.74)	47.00(±1.56)	47.55(±1.54)	**48.30**(±1.54)
D→A	38.65(±1.57)	41.67(±1.23)	42.94(±1.65)	44.74(±1.73)	45.40(±1.99)	47.26(±1.60)	48.73(±1.56)	**50.65**(±1.45)
D→W	75.60(±1.89)	77.22(±1.47)	78.96(±1.80)	82.77(±1.56)	84.69(±1.61)	84.70(±1.73)	85.12(±1.68)	**85.17**(±1.60)
平均分类精度	43.83	47.35	48.74	50.43	51.35	53.12	53.62	54.99

注. 粗体表示最优分类精度.

表 2　使用 Surf 特征多源域上各方法分类精度(±标准差)比较　　%

数据集	LRSR[22]	LSDT[23]	UTRDC[17]	GKDA[24]	LFDA-CDA[25]	ENIC[26]	PDR[15]	PRDDPL
C, D→A	43.98(±1.25)	46.49(±1.10)	47.87(±1.24)	49.51(±1.23)	49.54(±1.30)	51.35(±1.21)	52.48(±1.29)	**54.66**(±1.37)
C, D→W	41.76(±1.04	45.90(±1.45)	47.86(±1.26)	48.24(±1.20)	49.71(±1.23)	52.70(±1.47)	54.00(±1.32)	**54.20**(±1.23)
C, W→D	45.88(±1.32)	48.46(±1.28)	50.79(±1.32)	51.43(±1.20)	51.57(±1.19)	55.00(±1.24)	57.02(±1.29)	**58.21**(±1.33)
A, D→C	39.96(±1.34)	42.10(±1.27)	42.50(±1.32)	44.19(±1.11)	45.89(±1.09)	46.98(±1.22)	47.54(±1.08)	**49.76**(±1.03)
A, D→W	36.00(±1.19)	40.11(±1.22)	40.08(±1.30)	39.45(±1.26)	41.67(±1.23)	43.50(±1.30)	44.49(±1.19)	**45.95**(±1.20)
A, C→D	41.32(±1.20)	43.68(±1.14)	45.04(±1.26)	49.10(±1.36)	47.78(±1.43)	50.34(±1.37)	52.01(±1.27)	**55.35**(±1.35)
W, A→C	40.60(±1.34)	44.58(±1.26)	46.15(±1.40)	47.21(±1.34)	47.80(±1.28)	50.04(±1.32)	51.96(±1.22)	**53.70**(±1.09)
W, C→A	37.59(±1.32)	43.93(±1.22)	44.42(±1.84)	45.08(±1.36)	44.76(±1.72)	47.09(±1.61)	48.25(±1.46)	**49.39**(±1.21)
W, A→D	78.73(±1.36)	82.87(±1.38)	84.88(±1.26)	86.36(±1.55)	85.31(±1.28)	87.07(±1.42)	87.75(±1.37)	**88.13**(±1.30)
D, W→C	37.72(±1.41)	40.94(±1.35)	42.14(±1.68)	44.67(±1.32)	48.13(±1.59)	50.08(±1.30)	51.29(±1.32)	**52.54**(±1.34)
D, W→A	42.18(±1.35)	45.38(±1.55)	46.61(±1.27)	47.23(±1.28)	47.87(±1.36)	51.17(±1.32)	52.75(±1.30)	**54.08**(±1.30)
C, A→W	77.64(±1.03)	80.07(±1.12)	81.78(±1.18)	86.04(±1.23)	87.40(±1.17)	87.98(±1.20)	88.29(±1.24)	**88.75**(±1.26)
平均分类精度	46.95	50.38	51.68	53.21	53.95	56.11	57.32	58.64

注. 粗体表示最优分类精度.

表 3 和表 4 所示分别为使用深度特征时 12 个单源域和多源域实验的分类准确率. 与表 1 结果类似, PRDDPL 方法取了最佳的分类准确率, 在 Caltech-256 和 Office 数据集上具有明显的优势.

表 3　使用深度特征单源域上各方法分类准确率(±标准差)比较　　%

数据集	LRSR[22]	LSDT[23]	UTRDC[17]	GKDA[24]	LFDA-CDA[25]	ENIC[26]	PDR[15]	PRDDPL
C→A	77.04(±1.62)	79.17(±1.89)	82.47(±1.59)	86.44(±1.33)	86.40(±1.59)	85.22(±1.93)	88.87(±1.92)	**90.05**(±1.30)
C→W	77.40(±1.97)	77.53(±1.20)	83.52(±1.17)	80.71(±1.14)	84.13(±1.59)	85.84(±1.23)	86.88(±1.19)	**87.16**(±1.16)
C→D	78.18(±1.36)	78.58(±1.37)	82.74(±1.20)	82.23(±0.79)	84.20(±1.17)	85.81(±1.07)	87.37(±1.30)	**89.64**(±1.12)
A→C	79.48(±1.29)	74.22(±1.74)	76.04(±0.97)	80.63(±0.91)	84.17(±1.39)	85.47(±1.31)	84.34(±1.26)	**89.57**(±1.02)
A→W	74.95(±1.48)	72.43(±1.58)	77.31(±1.23)	80.20(±1.83)	79.63(±1.81)	80.89(±1.93)	82.00(±1.63)	**83.11**(±1.49)
A→D	84.07(±1.68)	84.10(±1.39)	84.46(±1.94)	85.49(±1.49)	87.98(±1.15)	92.19(±1.87)	92.67(±1.83)	**94.74**(±1.30)
W→C	78.24(±1.11)	81.57(±1.33)	80.67(±1.70)	81.47(±1.53)	80.44(±1.77)	84.51(±1.21)	86.20(±1.31)	**87.01**(±1.11)
W→A	84.80(±1.33)	86.67(±1.89)	84.10(±1.61)	88.44(±1.79)	92.12(±1.93)	91.87(±1.80)	92.62(±1.84)	**93.48**(±1.39)
W→D	82.20(±1.34)	85.52(±1.73)	85.42(±1.38)	87.56(±1.73)	88.57(±1.09)	90.55(±1.40)	90.66(±1.05)	**93.30**(±1.05)
D→C	87.73(±1.73)	91.19(±1.54)	91.73(±1.50)	95.02(±1.19)	94.06(±1.43)	92.67(±1.54)	93.41(±1.79)	**94.56**(±1.16)
D→A	78.64(±1.06)	79.67(±1.72)	80.82(±1.10)	83.93(±1.23)	84.69(±1.16)	86.32(±1.87)	89.50(±1.55)	**92.62**(±1.01)
D→W	82.49(±1.39)	85.49(±1.63)	85.19(±1.62)	88.27(±1.03)	88.32(±1.70)	90.49(±1.68)	92.78(±1.09)	**93.91**(±0.72)
平均分类精度	80.93	82.68	83.71	85.87	87.06	88.49	89.61	91.43

注. 粗体表示最优分类精度.

表 4　使用深度特征多源域上各方法分类精度(±标准差)比较　　%

数据集	LRSR[22]	LSDT[23]	UTRDC[17]	GKDA[24]	LFDA-CDA[25]	ENIC[26]	PDR[15]	PRDDPL
C, D→A	79.09(±1.24)	81.71(±1.27)	84.59(±1.59)	87.01(±1.33)	89.22(±1.59)	86.88(±1.93)	93.21(±1.92)	**94.54**(±1.95)
C, D→W	79.25(±1.27)	79.93(±2.20)	86.80(±1.17)	83.21(±2.04)	85.29(±1.59)	86.89(±2.23)	88.57(±1.19)	**90.00**(±1.16)
C, W→D	79.42(±1.36)	80.70(±1.37)	84.33(±1.20)	85.69(±0.79)	85.08(±2.17)	88.09(±2.07)	89.49(±1.97)	**90.66**(±1.25)
A, D→C	79.78(±1.49)	76.26(±0.78)	78.93(±1.10)	81.74(±1.53)	85.91(±1.78)	86.76(±0.58)	85.05(±1.10)	**90.28**(±0.99)
A, D→W	76.40(±2.00)	78.95(±1.47)	78.72(±0.53)	80.76(±0.90)	81.13(±1.20)	81.60(±0.99)	82.27(±0.98)	**84.06**(±1.04)
A, C→D	84.50(±1.45)	84.71(±0.53)	85.46(±1.41)	86.62(±1.56)	88.27(±1.50)	92.50(±0.71)	94.08(±1.27)	**95.87**(±0.95)
W, A→C	79.13(±1.30)	84.31(±2.04)	84.50(±2.89)	85.23(±1.11)	84.24(±1.74)	88.04(±1.29)	89.09(±0.71)	**90.82**(±0.71)
W, C→A	86.78(±1.85)	88.85(±1.41)	86.40(±1.29)	88.90(±2.50)	92.20(±1.15)	93.68(±1.05)	94.24(±1.69)	**95.68**(±0.84)
W, A→D	84.93(±1.05)	86.16(±1.54)	87.66(±2.12)	90.87(±0.57)	91.25(±2.81)	93.36(±1.67)	93.08(±2.34)	**95.35**(±1.99)
D, W→C	88.92(±1.25)	92.64(±2.12)	92.27(±1.59)	95.98(±1.46)	95.24(±0.88)	95.38(±1.28)	95.35(±2.12)	**96.85**(±1.01)
D, W→A	80.63(±1.00)	81.14(±1.46)	81.35(±1.53)	84.83(±1.14)	85.89(±1.67)	86.50(±1.18)	89.87(±1.67)	**92.96**(±1.03)
C, A→W	83.99(±1.74)	86.27(±1.65)	86.29(±1.24)	89.80(±1.31)	90.09(±1.68)	91.07(±1.80)	92.88(±1.42)	**94.90**(±1.05)
平均分类精度	81.90	83.47	84.78	86.72	87.82	89.23	90.60	92.66

注. 粗体表示最优分类精度.

PRDDPL 方法在跨领域图像识别上无须大量的样本, 通过对源域和目标域数据交叉重构就可以实现数据重构; 而 LRSR 和 LSDT 等重构方法在样本较少时数据重构效果不佳. 同时, PRDDPL 方法的分析字典充当投影矩阵, 综合字典充当源域和目标域之间判别信息的桥梁, 且考虑了字典原子与类信息间的关联, 而 PDR 不具备这一特点.

3.3 参数敏感性分析

通过式(7)可知, PRDDPL 方法需要寻优的参数有 λ, η 和 γ. 实验中固定其中 2 个参数, 采用网格搜索方法获得另一个参数的最优值. (1) 实验探索参数 λ 对模型性能的影响, λ 用于平衡字典约束项在目标函数中的作用. 实验中固定 $\eta=\gamma=1$, λ 从 $\{10^{-3},10^{-2},\cdots,10^{3}\}$ 中取值. 图 3 显示了 λ 在“D→A” “A→C” “A, D→W”和“C, D→A”数据集上的实验结果. 从图 3 可以看出, 当 λ 的值在区间 $[10^{-2},1]$ 时, PRDDPL 的分类性能较为稳定. 原因在于, λ 值过小时, 分析字典约束项在目标函数中的比重太小; λ 值过大时, 分析字典约束项在目标函数中的比重太大, 都不能很好地平衡此项与其他项之间的关系. (2) 实验探索参数 η 对模型性能的影响, η 用于平衡源域分类判别项在目标函数中的作用. 实验中固定 $\lambda=\gamma=1$, η 从 $\{10^{-3},10^{-2},\cdots,10^{3}\}$ 中取值. 图 4 显示了 η 在“D→A” “A→C” “A, D→W”和“C, D→A”数据集上的实验结果. 从图 4 以看出, $\eta<10$ 时, PRDDPL 的分类性能较为稳定. 当 η 的值>10 时, 源域分类判别项在目标函数中占比重过大, 无法学习到最优的综合字典 $\boldsymbol{D}$. (3) 实验探索参数 γ 对模型性能的影响, γ 用于平衡目标域分类判别项在目标函数中的作用. 图 5 显示了 γ 在“D→A” “A→C” “A, D→W”和“C, D→A”数据集上的实验结果. 图 5 的结果与图 4 类似, 当 γ 过大时, PRDDPL 的分类性能较低. 根据图 3~图 5 的实验可以看出, 不同的参数能影响 PRDDPL 方法性能, 因此采用网格搜索方法寻优是合适的.

3.4 消融实验

本节验证分析字典约束项 $\left\|\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{P}_l\bar{\boldsymbol{Y}}_l\right\|_{\mathrm{F}}^2$ (设置 $\lambda=0$)、新源域分类判别项 $\left\|\boldsymbol{H}_l-\boldsymbol{W}_l\boldsymbol{P}_l\boldsymbol{X}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{W}_l\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{\mathrm{F}}^2$ (设置 $\eta=0$)和新目标域分类判别项 $\left\|\tilde{\boldsymbol{H}}_l-\boldsymbol{W}_l\boldsymbol{P}_l\boldsymbol{Y}_l\right\|_{\mathrm{F}}^2+\left\|\boldsymbol{W}_l\boldsymbol{P}_l\bar{\boldsymbol{Y}}_l\right\|_{\mathrm{F}}^2$ (设置 $\gamma=0$)在 PRDDPL 方法中的作用. 表 5 所示为此 3 项在“D→A” “A→C” “A, D→W”和“C, D→A”数据集上的消融实验

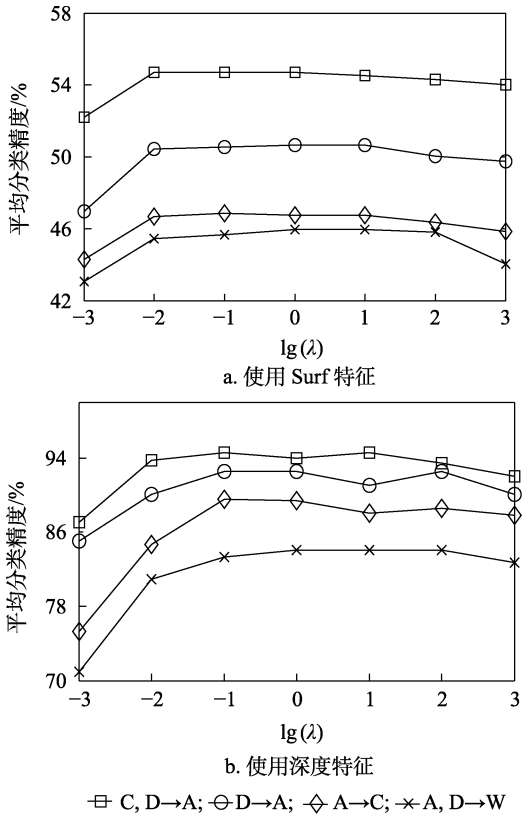


图 3 λ 参数敏感性分析

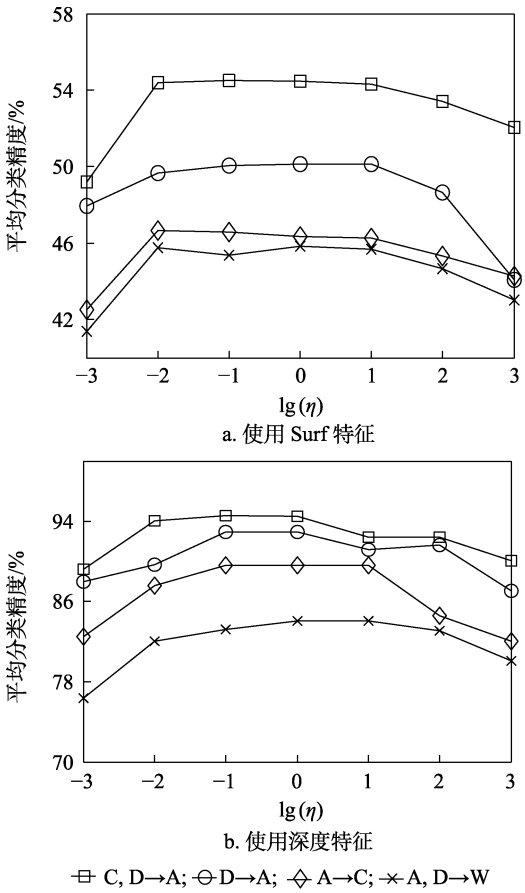


图 4 η 参数敏感性分析

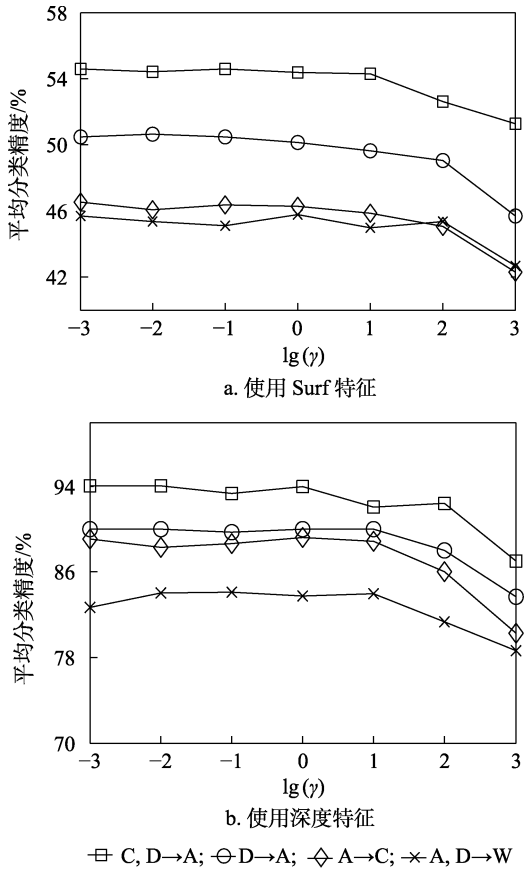


图 5　γ 参数敏感性分析

表 5　不同特征下 PRDDPL 方法消融实验分类精度

特征	数据集	分类精度/%		
		λ =0	η=0	γ =0
Surf 特征	D→A	49.08	48.27	48.31
	A→C	45.43	45.00	45.02
	A, D→W	44.14	43.56	43.47
	C, D→A	51.76	51.09	51.03
深度特征	D→A	91.24	88.65	88.48
	A→C	88.30	87.47	87.59
	A, D→W	82.27	80.41	80.17
	C, D→A	93.18	92.21	92.10

结果. 分析字典约束项的功能是提升每个分析子字典 $\boldsymbol{P}_l$ 的判别能力和类间差别性. 实验结果显示, 在不考虑此项的情况下, PRDDPL 的分类性能下降明显. 例如, 使用 Surf 特征时, 在单源域“D→A”和多源域“A, D→W”数据集上 λ =0 时, PRDDPL 的分类精度分别下降了 1.57 个百分点和 1.81 个百分点. 因此, 具有近似的块对角结构的 $\left\|\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{\mathrm{F}}^2$ 能增加模型的类别区分能力.

PRDDPL 使用最小二乘损失函数作为分类误差依据, 同时良好的分类器也会使 $\left\|\boldsymbol{W}_l\boldsymbol{P}_l\bar{\boldsymbol{X}}_l\right\|_{\mathrm{F}}^2$ 具有近似的块对角结构. PRDDPL 使用原始源域和目标域的交叉来重构新的源域和目标域, 以达到减少不同领域分布差异的目的. 从表 5 可知, 在领域适应分类问题上, 来自源域的类别判别信息对模型的构建起到了关键的作用.

PRDDPL 方法实验交叉重构构建了新的目标域, 习得的共享字典作为不同领域联系的桥梁, 具有较强的重构和判别能力. 从表 5 可知, 在单源域“D→A”和多源域“A, D→W”数据集上 γ =0 时, 使用深度特征时 PRDDPL 的分类精度分别下降了 4.14 个百分点和 3.89 个百分点. 因此, 目标域分类判别项也对模型的性能提升起到重要的作用.

4　结　论

本文提出了一种基于投影重构的领域适应字典对学习方法, 用于不同领域图像的分类. 通过引入投影重构技术和综合分析字典对, 可得到子空间投影对齐源域和目标域数据, 同时得到领域共享的判别字典; 通过分析字典约束项实现子字典的类间分离, 以提升模型的判别能力; 通过源域和目标域的分类器项, 得到判别的稀疏系数. 通过对社交媒体网站上图像的分类和识别实验, 通过与相关算法的对比体现了其在分类准确率上的优势. 在接下来的工作中, 将继续探索本文方法在其他领域中的应用; 将其扩展至多源域领域适应方法, 并根据源域在领域适应中的作用赋予权重. 另外, 将本文提出的领域适应机制用于深度字典学习框架, 以更有效地提取数据的内在特征结构, 也是未来工作的重点.

参考文献(References):

[1] Sun Y L, Shi G M, Dong W S, *et al*. MADPL-net: multi-layer attention dictionary pair learning network for image classification[J]. Journal of Visual Communication and Image Representation, 2023, 90: 103728

[2] Tang Hongzhong, Liu Ting, Zeng Shuying, *et al*. Guided dictionary learning algorithm with group sparse residual constraints for single image deraining[J]. Journal of Computer-Aided Design & Computer Graphics, 2020, 32(8): 1267-1277 (in Chinese)
(汤红忠, 刘婷, 曾淑英, 等. 群稀疏残差约束的引导字典学习算法及其单幅图像去雨[J]. 计算机辅助设计与图形学学报, 2020, 32(8): 1267-1277)

[3] Ni T G, Zhang C, Gu X Q. Transfer model collaborating metric learning and dictionary learning for cross-domain facial expression recognition[J]. IEEE Transactions on Computational Social Systems, 2021, 8(5): 1213-1222

[4] Zhang L, Gao X B. Transfer adaptation learning: a decade survey[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(1): 23-44

[5] Zhang L, Fu J R, Wang S S, *et al*. Guide subspace learning for unsupervised domain adaptation[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(9): 3374-3388

[6] Wang Junmin, Fan Yangyu, Li Zuhe. Texture image recognition based on deep convolutional neural network and transfer learning[J]. Journal of Computer-Aided Design & Computer Graphics, 2022, 34(5): 701-710(in Chinese)
(王军敏, 樊养余, 李祖贺. 基于深度卷积神经网络和迁移学习的纹理图像识别[J]. 计算机辅助设计与图形学学报, 2022, 34(5): 701-710)

[7] Wang S S, Zhang L, Zuo W M, *et al*. Class-specific reconstruction transfer learning for visual recognition across domains[J]. IEEE Transactions on Image Processing, 2020, 29: 2424-2438

[8] Wu S S, Yan Y, Tang H, *et al*. Structured discriminative tensor dictionary learning for unsupervised domain adaptation[J]. Neurocomputing, 2021, 442: 281-295

[9] Shekhar S, Patel V M, Nguyen H, *et al*. Coupled projections for adaptation of dictionaries[J]. IEEE Transactions on Image Processing, 2015, 24(10): 2941-2954

[10] Xu Z, Yuan P P, Zhang T, *et al*. HDA: cross-project defect prediction via heterogeneous domain adaptation with dictionary learning[J]. IEEE Access, 2018, 6: 57597-57613

[11] Cai Y Y, Li J F, Liu B D, *et al*. Shared dictionary learning via coupled adaptations for cross-domain classification[J]. Neural Processing Letters, 2023, 55(2): 1869-1888

[12] Shao S, Xu R, Liu W F, *et al*. Label embedded dictionary learning for image classification[J]. Neurocomputing, 2020, 385: 122-131

[13] Chen Z, Wu X J, Kittler J. Relaxed block-diagonal dictionary pair learning with locality constraint for image recognition[J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(8): 3645-3659

[14] Zhang Z, Sun Y L, Wang Y, *et al*. Twin-incoherent self- expressive locality-adaptive latent dictionary pair learning for classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(3): 947-961

[15] Han N, Wu J G, Fang X Z, *et al*. Projective double reconstructions based dictionary learning algorithm for cross-domain recognition[J]. IEEE Transactions on Image Processing, 2020, 29: 9220-9233

[16] Luo H, Zhang K B, Luo S, *et al*. Locality-adaptive structured dictionary learning for cross-domain recognition[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2022, 32(4): 2425-2440

[17] Sanodiya R K, Yao L. Unsupervised transfer learning via relative distance comparisons[J]. IEEE Access, 2020, 8: 110290-110305

[18] Razzaghi P, Razzaghi P, Abbasi K. Transfer subspace learning via low-rank and discriminative reconstruction matrix[J]. Knowledge-Based Systems, 2019, 163: 174-185

[19] Saray S N, Tahmoresnezhad J. Joint distinct subspace learning and unsupervised transfer classification for visual domain adaptation[J]. Signal, Image and Video Processing, 2021, 15(2): 279-287

[20] Na Y, Liao M M, Jung C. Super-speed up robust features image geometrical registration algorithm[J]. IET Image Processing, 2016, 10(11): 848-864

[21] Fang X Z, Jiang L, Han N, *et al*. Cross-domain recognition via projective cross-reconstruction[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2022, 52(12): 7366-7377

[22] Xu Y, Fang X Z, Wu J, *et al*. Discriminative transfer subspace learning via low-rank and sparse representation[J]. IEEE Transactions on Image Processing, 2016, 25(2): 850-863

[23] 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

[24] Pan D, Yang H. Geodesic kernel embedding distribution alignment for domain adaptation[J]. Journal of Computational Methods in Sciences and Engineering, 2020, 20(4): 1325-1338

[25] Zandifar M, Tahmoresnezhad J. Locality Fisher discriminant analysis for conditional domain adaption[J]. Iran Journal of Computer Science, 2021, 4(1): 17-34

[26] Prabhakar S K, Lee S W. ENIC: ensemble and nature inclined classification with sparse depiction based deep and transfer learning for biosignal classification[J]. Applied Soft Computing, 2022, 117: 108416