

控制与决策

Control and Decision

基于跨域流形正则化特征域适应的浮选工况识别

安迪, 王姝, 关展旭, 刘尧, 张林

引用本文:

安迪, 王姝, 关展旭, 刘尧, 张林. 基于跨域流形正则化特征域适应的浮选工况识别[J]. *控制与决策*, 2023, 38(9): 2597–2605.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.1593>

您可能感兴趣的其他文章

Articles you may be interested in

基于深度时序特征迁移的轴承剩余寿命预测方法

Remaining useful life prediction of bearing based on deep temporal feature transfer

控制与决策. 2021, 36(7): 1699–1706 <https://doi.org/10.13195/j.kzyjc.2019.1809>

基于广义主成分分析的重构故障子空间建模方法

Reconstructed fault subspace modelling method based on generalized principal component analysis

控制与决策. 2021, 36(4): 808–814 <https://doi.org/10.13195/j.kzyjc.2019.0818>

基于图像随机分布模型的电熔镁炉工况识别

Conditions recognition of fused magnesia furnace based on dynamic characteristics of B-spline network

控制与决策. 2021, 36(11): 2735–2742 <https://doi.org/10.13195/j.kzyjc.2020.0570>

基于DLSR的归纳式迁移学习

DLSR based inductive transfer learning method

控制与决策. 2021, 36(12): 2982–2990 <https://doi.org/10.13195/j.kzyjc.2020.0703>

基于互信息操作变量曲线参数化的间歇过程批内修正优化

Intra-batch correction optimization of batch process with manipulated variable trajectory parameterization based on mutual information

控制与决策. 2021, 36(1): 234–240 <https://doi.org/10.13195/j.kzyjc.2019.0825>

基于跨域流形正则化特征域适应的浮选工况识别

安迪, 王 姝[†], 关展旭, 刘 尧, 张 林

(东北大学 信息科学与工程学院, 沈阳 110819)

摘要: 针对浮选过程的故障工况信息不足难以建立准确识别模型, 导致调整浮选生产工况不及时, 从而无法正常稳定运行的问题, 提出一种基于跨域流形正则化特征域适应方法. 该方法将已有相似完备浮选过程积累的丰富工况信息作为源域迁移至未建模的不完备浮选过程的目标域中, 首先, 通过最大域内类密度和局部流形正则化约束分别保留原始判别信息和维持域内邻域结构信息不变, 从而提取完备工况与不完备工况域间的特征并投影至公共子空间; 然后, 由最大均值差异缩小源域与目标域间分布差异, 建立分类识别模型, 再结合 D-S 证据理论, 融合浮选过程泡沫的静态特征与动态特征信息, 提高对不完备浮选过程工况识别的泛化能力, 保证得到较好的识别分类效果; 最后, 通过仿真实验验证所提出方法的有效性.

关键词: 铜浮选过程; 迁移学习; 流形正则化; D-S 理论; 工况识别

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.1593

引用格式: 安迪, 王姝, 关展旭, 等. 基于跨域流形正则化特征域适应的浮选工况识别[J]. 控制与决策, 2023, 38(9): 2597-2605.

Identification of flotation working condition based on feature domain adaptation of cross-domain manifold regularization

AN Di, WANG Shu[†], GUAN Zhan-xu, LIU Yao, ZHANG Lin

(College of Information Science and Engineering, Northeastern University, Shenyang 110819, China)

Abstract: Aiming at the problem that the flotation process is difficult to establish an accurate identification model due to insufficient fault condition information, which leads to the delay in adjusting the flotation production conditions and the failure to run statically in the normal state, this paper proposes a feature transfer learning method based on cross-domain manifold regularization (CDMRFTL). In this method, the rich and complete working condition information accumulated by the existing similar complete flotation process is transferred as the source domain to the target domain of the incomplete unmodeled flotation process. First, the common features between the complete working conditions and the incomplete working conditions are extracted and are mapped to the common subspace through the largest domain class density and partial manifold regularization, to constraint discriminant information and retain the original unchanged in neighborhood domain structure information. Then, narrowing the difference of distribution between source domain and target domain by the largest average differences, the classification and recognition model is established. Next, D-S evidence theory is combined to fuse the apparent characteristics and depth characteristics of the foam in the flotation process to improve the generalization ability of incomplete flotation process condition recognition and ensure better recognition and classification effect. Finally, the effectiveness of the proposed method is verified by simulation experiments.

Keywords: copper flotation; transfer learning; manifold regularization; D-S theory; condition identification

0 引言

浮选是矿物加工处理过程中对物质进行精选分离的常用方法, 作为非线性、耦合性强、多变量的复杂工业过程, 在实际工业浮选中, 仍然处于依靠经验丰富的工人肉眼观察表面泡沫视觉信息来完成浮选

操作的阶段^[1-2]. 随着计算机科学和自动化等领域的进步, 浮选领域广泛采用图像处理技术对浮选工况识别, 通过利用机器视觉技术获取浮选泡沫图像视觉特征, 并根据图像特征参数结合浮选工艺先验知识准确识别工况, 为浮选过程控制提供依据^[3].

收稿日期: 2021-09-13; 录用日期: 2022-03-15.

基金项目: 国家重点研发计划项目(2021YFF0602404); 国家自然科学基金项目(61873053, 61621004).

责任编辑: 阳春华.

[†]通讯作者. E-mail: wangshu@ise.neu.edu.cn.

早先对浮选槽泡沫层的图像特征进行提取,大都采用数字图像处理技术和人工神经网络方法,提取浮选泡沫静态特征(气泡尺寸、颜色、纹理、稳定性、速率)等参数,通过分析这些表面视觉特征与浮选工况间的对应关系建立分类识别模型,探索出有效的控制策略,提高浮选的自动化水平和生产效率,但其中存在不同特征参数相互重叠问题,导致分类准确率较低^[4-6]. 针对此问题,王红平等^[7]利用主成分分析法对特征参数进行降维处理,解决了泡沫各纹理参数的相互重叠问题,最后结合神经网络进行工况识别分类;任传成^[8]采用多层聚类结合Lasso方法对图像颜色和纹理特征参数降维,然后利用相关系数阈值法辅助软测量模型的建立;何明芳等^[9]采用HSV颜色空间与人眼视觉特征相似性和模块匹配算法提取泡沫图像颜色和速度特征,最后结合模糊支持向量机进行疏浮选工况识别. 然而,上述研究均是基于有足够多的浮选过程图像数据的假设,对于一个不完备浮选工艺过程或新工况,难以建立准确分类识别模型. 因此,考虑到相似过程的普遍性和可迁移性,采用某种策略将有用的过程数据信息迁移至不完备工艺过程中,有助于过程的建模,提高建模效率和准确率^[10].

迁移学习(transfer learning)^[11],或称领域适应(domain adaption)的目的是应用已有知识(称之为源域)以更好地解决新问题. 研究初期,迁移学习应用于计算机视觉中,在目标识别领域,标签信息显得十分重要,人们希望利用相关源域大量可用的标记数据以训练目标域的准确分类器^[12-13]. 目前已有一些学者将迁移学习在图像分类和目标识别中进行了探索,Pan等^[14]和Long等^[15]主要是以缩小分布差异为目标进行迁移,忽略了原始数据的判别信息. 对此,又有文献分别考虑原始数据的判别信息和局部结构信息^[16-17]. 经过上述研究分析,若要更好地解决新目标域识别问题,仅考虑缩小源域与目标域分布差异已不能达到目的,需要同时将原始数据判别信息和局部邻域结构信息考虑进内,才能够保证较好的目标学习分类效果.

本文主要解决浮选工艺工况识别的问题,由于不完备浮选工艺过程的故障工况信息不足,含少量标签甚至无标签信息,不足以建立准确的分类模型. 针对上述问题,提出一种跨域流形正则化特征域适应方法. 首先考虑到源域与目标域含有不同的数据分布,经过缩小二者分布差异的同时,集成维持原始数据的判别信息和局部领域结构的约束,通过特征转移矩阵

映射至公共特征空间内,随后建立分类识别模型. 最后通过3组常用域适应数据集和铜浮选过程验证所提出方法的有效性. 主要内容如下.

1) 提出一种新的特征迁移学习方法,通过最大域内类密度保持原始数据的判别信息,使得源域和目标域同类样本经此方法投影后密度更近,不同类别显著分开,新学到特征的判别能力更强,并利用了目标域无标记样本的伪标签信息.

2) 提出一种基于流形正则化项保持局部邻域结构信息,考虑到源域与目标域可能处于不同的流形中,在特征迁移中,域内的局部流形结构信息得以完整保持,有效解决了分布差异过大导致的负迁移问题,更好地学习判别表征.

3) 按照对泡沫浮选图像特征提取方式的不同,分为静态特征和动态特征两部分,分别对每部分应用所提出CDMRFTL方法进行迁移学习,再将分类结果所对应的概率值运用D-S理论实现多特征融合,得到最终的分类识别结果.

1 相关算法

1.1 最大均值差异

针对跨域适应问题,特征迁移学习的首要目标是缩小源域与目标域的分布差异. 本文采用最大均值差异(maximum mean discrepancy, MMD)^[18-19]方法,其首次被提出运用于解决双样本检测问题,以判断2个分布的差异,并成为目前迁移学习领域应用较多的一种度量准则. 其原理如下:假设存在一个源领域 $\mathbf{X}^s = [\mathbf{x}_1^s, \mathbf{x}_2^s, \dots, \mathbf{x}_{n_s}^s] \in R^{f \times n_s}$ 满足 Q 分布和一个目标域 $\mathbf{X}^t = [\mathbf{x}_1^t, \mathbf{x}_2^t, \dots, \mathbf{x}_{n_t}^t] \in R^{f \times n_t}$ 满足 R 分布, n_s 和 n_t 分别为源域和目标域所含样本的个数. 通过 $X \rightarrow H$ 将原始特征空间映射至再生核希尔伯特空间,度量在 H 空间中2个分布的距离,表述如下:

$$D_{IS}(\mathbf{X}^s, \mathbf{X}^t) = \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} A^T \mathbf{x}_i^s - \frac{1}{n_t} \sum_{j=1}^{n_t} A^T \mathbf{x}_j^t \right\|_H^2 = \text{Tr}(A^T \mathbf{X} \mathbf{M}_0 \mathbf{X}^T A). \quad (1)$$

其中: $\mathbf{X} = [\mathbf{X}^s, \mathbf{X}^t] \in R^{f \times (n_s + n_t)}$, A 为特征转移矩阵, \mathbf{M}_0 为

$$(\mathbf{M}_0)_{ij} = \begin{cases} \frac{1}{n_s n_s} \mathbf{x}_i^s, \mathbf{x}_j^s \in \mathbf{X}^s; \\ \frac{1}{n_t n_t} \mathbf{x}_i^t, \mathbf{x}_j^t \in \mathbf{X}^t; \\ \frac{-1}{n_s n_t}, \text{ otherwise.} \end{cases} \quad (2)$$

1.2 最大域内类密度

上述最大均值差异只是最小化源域与目标域的分布差异, 还要保持原始样本的判别信息, 使得源域与目标域相同类别的样本特征投影后更加紧凑. 分别提取源域与目标域中同类别标签的特征分布散度, 投影至公共特征空间后, 满足同类别密度很近, 不同类别显著分开, 通过计算相对位置的成对样本距离, 并将源域样本与目标域样本在投影空间对齐. 定义类密度矩阵如下:

$$S = \frac{1}{n_s + n_t} \sum_{i,j=1}^{n_s+n_t} W_{ij}(\mathbf{x}_i - \mathbf{x}_j)(\mathbf{x}_i - \mathbf{x}_j)^T. \quad (3)$$

其中: n_s 和 n_t 分别为源域样本数和目标域样本数; W_{ij} 为权值矩阵, 其取值需要判别 \mathbf{x}_i 与 \mathbf{x}_j 是否同类别来确定. 源域本身是含标签的, 但目标域无标签样本信息, 因此需要引入伪标签信息 \hat{y}_t , 可由源域训练的基分类器获得并迭代优化^[15]. 令 S_w 和 S_b 分别为源域和目标域中不同类别密度矩阵和同类别密度矩阵, 对应的不同类、同类权值矩阵 W_{ij}^w 和 W_{ij}^b 分别为

$$W_{ij}^w = \begin{cases} \frac{1}{n_s + n_t} - \frac{1}{n_{sm} + n_{tm}}, & \text{same table } m; \\ \frac{1}{n_s + n_t}, & \text{otherwise.} \end{cases} \quad (4)$$

$$W_{ij}^b = \begin{cases} \frac{1}{n_{sm} + n_{tm}}, & \text{same table } m; \\ 0, & \text{otherwise.} \end{cases} \quad (5)$$

其中 n_{sm} 、 n_{tm} 分别为源域与目标域同属于类别 m 的样本数. 为促使投影后, 域内同类别密度更近, 不同类别密度更远, 需同时满足以下两式:

$$\max \text{Tr}(A^T S_b A) = \max \cdot \text{Tr}(A^T X L_b X^T A), \quad (6)$$

$$\min \text{Tr}(A^T S_w A) = \min \cdot \text{Tr}(A^T X L_w X^T A), \quad (7)$$

其中 L_b 和 L_w 分别为同类别密度和不同类别密度对应的拉普拉斯矩阵.

1.3 局部流形正则化约束

在满足上述两种约束的同时, 为保持投影至新特征空间中原始本质信息, 还需进一步挖掘潜在的数据结构信息, 避免负迁移的发生. 根据流形假设, 高维空间的数据处于一个低维流形上, 因此采用流形正则化 (MR)^[20-21] 方法提取高维空间中数据流形结构信息, 使其局部领域结构相对稳定, 目标约束如下:

$$\min \frac{1}{2} \sum (z_i - z_j)^2 P^{ij}. \quad (8)$$

其中: z_i 和 z_j 为投影后的样本; P^{ij} 为样本的相似度, 通常采用 K 近邻方法计算两样本间的相似度. 通过局部高斯核函数^[22] 计算各点与 \mathbf{x}_i 的权值, 如下式所示:

$$P^{ij} = \begin{cases} \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / \sigma_i \sigma_j), & \|\mathbf{x}_i - \mathbf{x}_j\|^2 < \varepsilon; \\ 0, & \text{otherwise.} \end{cases} \quad (9)$$

其中: ε 为局部近邻半径; σ_i 、 σ_j 为第 i 、 j 样本点分别与其第 k 个近邻点的距离, 表述如下:

$$\sigma_i = \|\mathbf{x}_i - \mathbf{x}_k\|, \quad \sigma_j = \|\mathbf{x}_j - \mathbf{x}_k\|. \quad (10)$$

矩阵 P 包含样本间的连接关系, 若 z_i 和 z_j 为近邻样本则其分配的权重较大, 当超过局部近邻半径则分配权重为 0, 化简目标函数如下式所示:

$$\min \text{Tr}(A^T X L(X)^T A), \quad (11)$$

其中 L 为 Laplacian 矩阵, $L = D - P$, D 为对角矩阵, 对角线值为 $D_j = \sum_{i=1}^n P^{ij}$.

在跨域适应问题中, 源域和目标域数据通常来自不同的分布, 导致它们可能处于不同的流形上, 对此同时保持源域和目标域的局部邻域结构信息, 最大程度地避免负迁移. 基于式 (11) 分别对源域和目标域构造拉普拉斯矩阵 L^s 和 L^t , 化简目标函数如下:

$$\min \text{Tr}(A^T X^s L^s (X^s)^T A) + \text{Tr}(A^T X^t L^t (X^t)^T A). \quad (12)$$

1.4 D-S 证据理论

D-S (dempster-shafer) 理论又称为信念函数理论, 是处理不确定信息的有效工具^[23]. 证据理论能够整合来自不同信息源的证据, 获得对被测对象的一致性描述, 是信息融合的重要方法.

定义 1 对于一个具体的识别框架 Ω , 其基本概率分配函数 (basic probability assignment, BPA) 可设为 $m: 2^\Omega \rightarrow [0, 1]$, BPA 在 B 上的取值称为 B 的基本置信指派函数, 以 $m(B)$ 表示, 并满足以下条件约束:

$$\begin{aligned} m(\emptyset) &= 0, \\ \sum_{A \in 2^\Omega} m(B) &= 1. \end{aligned} \quad (13)$$

定义 2 已知 m_1 和 m_2 的 2 个基本概率分配, D-S 证据理论的组合规则如下所示:

$$m(B) = \begin{cases} 0, & B = \emptyset; \\ \frac{1}{1-K} \sum_{B \cap C=A} m_1(C) m_2(D), & B \neq \emptyset. \end{cases} \quad (14)$$

$$K = \sum_{C \cap D = \emptyset} m_1(C) m_2(D). \quad (15)$$

其中: C 和 D 也是识别框架 Ω 下的假设; K 为冲突系数, 当 $K = 0$ 时, m_1 与 m_2 间无冲突, 而当 $K = 1$ 时, m_1 与 m_2 完全冲突, 则不能通过 D-S 理论直接融合.

2 跨域流形正则化特征域适应建模

为提高对目标域分类识别效果,通过缩小源域与目标域分布差异的同时,还需保持原始数据的判别信息和局部邻域结构信息,综合这些优化目标统一至共同的特征学习中,并推导求解如下:

$$\begin{aligned} \mathcal{L}(A, \beta, \lambda) &= \text{MMD}^{\text{dis}} + \beta F(\mathbf{X}) + \lambda L(\mathbf{X}), \\ \arg \max_A &(\beta \text{Tr}(A^T \mathbf{X} \mathbf{L}_b \mathbf{X}^T A)) / (\lambda \text{Tr}(A^T \mathbf{X}^s \times \\ &\mathbf{L}^s (\mathbf{X}^s)^T A + A^T \mathbf{X}^t \mathbf{L}^t (\mathbf{X}^t)^T A) + \\ &\beta \text{Tr}(A^T \mathbf{X} \mathbf{L}_w \mathbf{X}^T A) + \text{Tr}(A^T \mathbf{X} \mathbf{M}_0 \mathbf{X}^T A). \end{aligned} \quad (16)$$

其中: MMD^{dis} 为迁移成分分析; $F(\mathbf{X})$ 为最大域内类密度; $L(\mathbf{X})$ 为局部邻域结构保持; A 为特征转移矩阵; \mathbf{M}_0 为最大均值差异矩阵; \mathbf{L}_b 和 \mathbf{L}_w 分别为同类别密度和不同类别密度对应的拉普拉斯矩阵; \mathbf{L}^s 和 \mathbf{L}^t 分别为保持源域和目标域结构对应的拉普拉斯矩阵, $\mathbf{X} = [\mathbf{X}^s, \mathbf{X}^t]$ 为原始数据矩阵, 上标 s, t 分别为源域数据和目标域数据; β, λ 为平衡因子.

首先由于式(16)中目标函数对于特征转移矩阵 A 具有缩放不变性, 引入单位矩阵 I_r , 将式(16)改写为如下优化问题:

$$\begin{aligned} \max_A &\text{Tr}(A^T \beta \mathbf{X} \mathbf{L}_b \mathbf{X}^T A); \\ \text{s.t.} &\text{Tr}(A^T (\lambda (\mathbf{X}^s \mathbf{L}^s (\mathbf{X}^s)^T + \mathbf{X}^t \mathbf{L}^t (\mathbf{X}^t)^T) + \\ &\beta \mathbf{X} \mathbf{L}_w \mathbf{X}^T + \mathbf{X} \mathbf{M}_0 \mathbf{X}^T) A) = I_r. \end{aligned} \quad (17)$$

然后引入拉格朗日乘子 τ , 对应的拉格朗日函数为

$$\begin{aligned} J(A, \tau) &= \\ &\text{Tr}(A^T \beta \mathbf{X} \mathbf{L}_b \mathbf{X}^T A) - \tau (\text{Tr}(A^T (\lambda (\mathbf{X}^s \mathbf{L}^s (\mathbf{X}^s)^T + \\ &\mathbf{X}^t \mathbf{L}^t (\mathbf{X}^t)^T) + \beta \mathbf{X} \mathbf{L}_w \mathbf{X}^T + \mathbf{X} \mathbf{M}_0 \mathbf{X}^T) A) - I_r). \end{aligned} \quad (18)$$

再对特征转移矩阵 A 进行求导, 得到

$$\begin{aligned} \frac{\partial J(A, \tau)}{\partial A} &= \\ &\beta \mathbf{X} \mathbf{L}_b \mathbf{X}^T A - \tau (\lambda (\mathbf{X}^s \mathbf{L}^s (\mathbf{X}^s)^T + \mathbf{X}^t \mathbf{L}^t (\mathbf{X}^t)^T) + \\ &\beta \mathbf{X} \mathbf{L}_w \mathbf{X}^T + \mathbf{X} \mathbf{M}_0 \mathbf{X}^T) A. \end{aligned} \quad (19)$$

最后令 $\frac{\partial J(A, \tau)}{\partial A}$ 为0, 得到

$$\begin{aligned} (\lambda (\mathbf{X}^s \mathbf{L}^s (\mathbf{X}^s)^T + \mathbf{X}^t \mathbf{L}^t (\mathbf{X}^t)^T) + \beta \mathbf{X} \mathbf{L}_w \mathbf{X}^T + \\ \mathbf{X} \mathbf{M}_0 \mathbf{X}^T)^{-1} (\beta \mathbf{X} \mathbf{L}_b \mathbf{X}^T) A = \tau A. \end{aligned} \quad (20)$$

这是一个广义特征值求解问题, $\{\tau_k\}_{k=1}^r$ 为特征值按照降序排列所得, 即 $\tau_{k_1} \geq \tau_{k_2} \geq \dots \geq \tau_{k_r}$, w_1, w_2, \dots, w_r 为对应的特征向量, 则可得到特征转移矩

阵 A 的最优解为

$$A = [w_1, w_2, \dots, w_r]. \quad (21)$$

因此, A 是由最大的 r 个特征值对应的特征向量组成, 确定特征转移矩阵后, 代表着任一原始样本均可通过此矩阵投影至新公共特征空间中, 表示如下:

$$\mathbf{X}_{\text{new}} = A^T \mathbf{X}.$$

源域数据和目标域数据通过跨域流形正则化特征域适应方法, 不仅保持着原始数据的判别信息(即同类别密度经过投影映射后, 更加紧凑, 不同类别显著分开), 还保证局部邻域结构不变(即映射过程中仍然维持域内几何流形结构不受跨域特征迁移的破坏, 同时缩小了源域与目标域分布距离). 综合上述, 约束投影至公共特征空间原理如图1所示, 具体算法步骤如下.

输入: 源域、目标域样本 $\mathbf{L}(\mathbf{X})$, 源域标签 y_s , 核函数 $\mathbf{K}(\mathbf{x}_i, \mathbf{x}_j)$, 平衡系数 β, λ ;

输出: 目标域标签 y_t .

step 1: 由式(2)构造最大均值差异矩阵 \mathbf{M}_0 ;

step 2: 根据源域数据, 迭代优化训练分类器, 获得目标域伪标签 \hat{y}_t , 然后由式(6)和(7)求得同类别密度和不同类别密度对应的拉普拉斯矩阵 \mathbf{L}_b 和 \mathbf{L}_w ;

step 3: 由式(12)分别求得源域和目标域结构对应的拉普拉斯矩阵 \mathbf{L}^s 和 \mathbf{L}^t ;

step 4: 求解式(21)描述的广义特征值问题, A 由最大的 r 个特征值对应的特征向量构成;

step 5: 获得特征转移函数: $\mathbf{X}_{\text{new}} = A^T \mathbf{X}$;

step 6: 源域数据投影至公共特征空间为 $\mathbf{X}_{\text{new}}^s = A^T \mathbf{X}^s$, 目标域数据投影至公共特征空间为 $\mathbf{X}_{\text{new}}^t = A^T \mathbf{X}^t$;

step 7: 根据投影至公共特征空间的源域数据及其源域标签构建KNN分类识别模型;

step 8: 将目标域投影至公共特征空间的数据代入KNN分类识别模型, 得到预测标签.

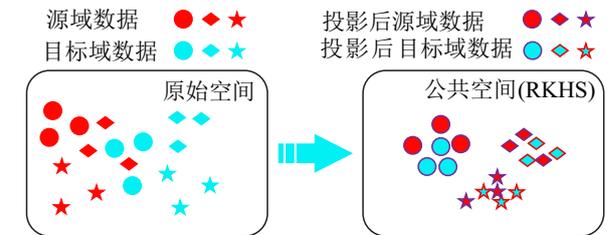


图1 跨域流形正则化域适应原理

3 基于CDMRFTL+D-S的工况识别方法

浮选工程作为复杂工业过程, 基于图像处理的铜浮选工况识别问题, 人们已经展开了大量研究, 大多

数研究者通过提取泡沫图像静态特征^[24-25](如颜色、尺寸、形状、纹理、承载率等),此外还有通过光流法等提取图像动态特征^[26](如泡沫流速和泡沫稳定度等),分析这些特征与浮选工况间的对应关系以实现监测. 针对浮选工艺过程运行时间短、泡沫图像故障数据有限的问题,同时提取泡沫图像的静态特征和动态特征,运用所提出方法特征迁移,将已有相似完

备浮选过程积累的丰富完备工况信息作为源域迁移至未建模的不完备浮选过程的目标域中,建立准确的KNN分类识别模型,由每类特征对应的概率值,通过D-S证据理论,从而实现多特征融合,得到最终的分

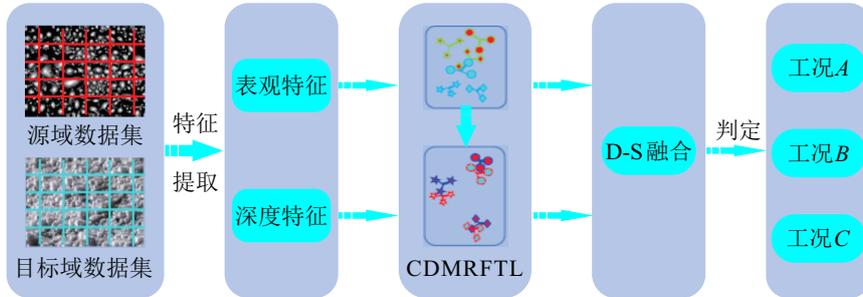


图2 CDMRFTL+D-S浮选工况识别模型

针对当前样本 X , 代入已构建的KNN分类模型, 计算其相对3类工况的距离度量值 l_A 、 l_B 和 l_C . 首先对提取的静态特征, 计算概率值如下式所示:

$$\begin{cases} m_s(A) = l_{sA}/(l_{sA} + l_{sB} + l_{sC}), \\ m_s(B) = l_{sB}/(l_{sA} + l_{sB} + l_{sC}), \\ m_s(C) = l_{sC}/(l_{sA} + l_{sB} + l_{sC}). \end{cases} \quad (22)$$

其中 l_{sA} 、 l_{sB} 和 l_{sC} 分别为样本在静态特征中对应3类工况的距离度量值. 同理, 对提取的动态特征, 计算概率值如下式所示:

$$\begin{cases} m_d(A) = l_{dA}/(l_{dA} + l_{dB} + l_{dC}), \\ m_d(B) = l_{dB}/(l_{dA} + l_{dB} + l_{dC}), \\ m_d(C) = l_{dC}/(l_{dA} + l_{dB} + l_{dC}). \end{cases} \quad (23)$$

其中 l_{dA} 、 l_{dB} 和 l_{dC} 分别为样本在动态特征中对应3类工况的距离度量值. 然后按照第2节D-S融合规则, 以工况A为例, 求得融合后的概率值为

$$m_{DS}(A) = m_s(A) \oplus m_d(A). \quad (24)$$

4 算法评估及应用

本节首先使用3组域适应领域常用的数据集^[27], 在目标识别、图像分类等任务进行广泛的实验, 并与前人所提出的方法作对比, 以评价和验证所提出CDMRFTL方法的有效性. 最后结合D-S证据理论应用于实际的铜浮选过程, 进一步表明所提出方法的有效性.

4.1 常用数据集仿真

4.1.1 常用数据集描述

本文与之前多种域适应方法设置一样, 在3种数据集中进行特征迁移任务. 具体信息如表1所示.

表1 数据集描述

数据集	样本类型	样本数	特征数	类别数
Office+Caltech 10	物体	1410+1123	800	10
COIL 20	物体	1440	1024	10
USPS+MNIST	字符	1800+2000	256	10

4.1.2 实验设置

为验证所提出跨域流形正则化域适应算法的有效性, 与前文所提出的4种域适应方法^[14-17]以及近两年文献方法^[28-30]进行比较, 这些方法以及所提出方法均是将源域和目标域数据投影至公共特征空间, 然后训练KNN分类器, 最终将目标域数据代入预测标签. 首先对模型中各参数对算法性能影响作出研究, 寻求最优参数组合, 其模型中各参数候选范围如表2所示, 性能分析结果如图3所示.

表2 参数的候选范围

参数	可调范围	参数意义
β	0.001, 0.01, 0.1, 1, 10	判别平衡因子
λ	0.001, 0.01, 0.1, 1, 10	结构平衡因子
σ	0.01, 0.05, 0.1, 1, 10	高斯核函数宽度
d	20, 30, ..., 100	投影特征空间维度
K	5, 10, 15, ..., 50	K 近邻的邻居数

由图3可以分析出, 模型中的各参数过大或过小时, 准确率均未能取得最优结果, 本文主要研究判别平衡因子 β 和结构平衡因子 λ , 其一代表原始数据的判别信息, 二是代表着原始数据的结构信息. 当平衡因子 β 过大而平衡因子 λ 过小时, 便会过度考虑域内类密度信息, 无法兼顾考虑原始数据结构信息, 影响判别新特征样本的能力, 参数组合对所提出方法性能影响较大, 因此通过网络搜索法, 寻求平衡两者的最优参数组合, 具体如图3(f)所示.

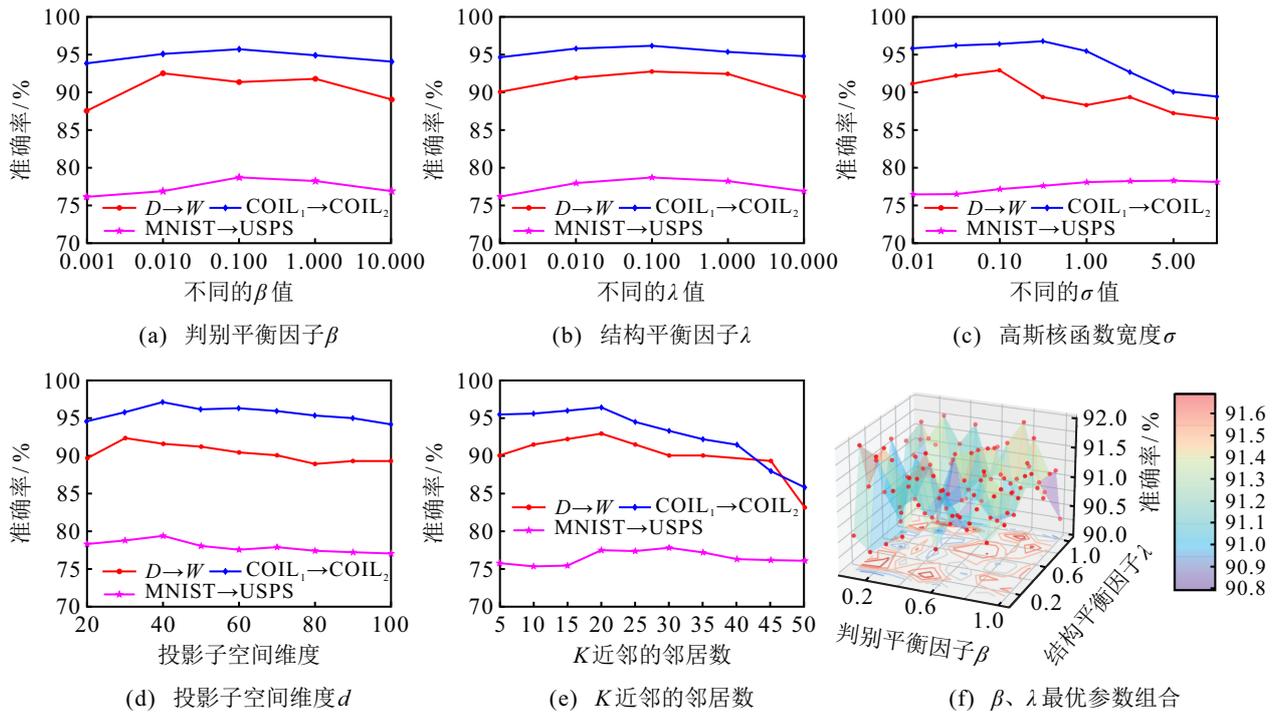


图3 参数性能分析

4.1.3 实验结果

本文在 Office+Caltech 10、COIL 20、USPS+MNIST 三个不同数据集上进行实验,对比不同方法

的分类性能,其分类准确率结果如表3所示,表中粗字体表示最优结果.

表3 3组不同数据集的分类结果

数据集	任务/方法	TCA	JDA	ACTCA	MEDA	SP-UDA	文献[29]	SSDTS	CDMRFTL
Office+Caltech 10	$C \rightarrow A$	38.60	44.78	54.72	56.5	52.3	52.86	48.8	58.26
	$C \rightarrow W$	39.34	42.50	53.26	53.9	48.2	45.72	52.2	57.83
	$C \rightarrow D$	45.96	45.36	56.18	50.3	46.8	49.78	52.7	53.48
	$A \rightarrow C$	42.25	38.24	45.15	43.9	41.3	42.64	43.8	47.85
	$A \rightarrow W$	40.23	38.75	49.52	53.2	38.2	42.57	47.1	48.14
	$A \rightarrow D$	35.72	42.62	47.34	45.9	39.4	45.62	49.5	50.32
	$W \rightarrow C$	31.56	33.81	33.57	34.0	32.6	32.19	33.6	35.84
	$W \rightarrow A$	30.57	29.74	32.40	42.7	42.3	36.48	38.1	41.63
	$W \rightarrow D$	91.10	92.45	92.40	88.5	89.8	89.23	73.4	90.65
	$D \rightarrow C$	33.56	31.26	36.23	34.9	32.9	34.36	37.6	38.64
	$D \rightarrow A$	32.82	34.53	38.62	41.2	34.2	36.89	47.5	39.53
	$D \rightarrow W$	87.46	89.20	90.57	87.5	93.6	89.64	79.9	92.88
average		45.76	47.02	52.49	52.7	49.3	49.84	50.5	54.58
COIL 20	$COIL_1 \rightarrow COIL_2$	85.62	88.43	90.23	92.30	91.23	93.86	91.9	96.85
	$COIL_2 \rightarrow COIL_1$	84.88	89.56	91.65	92.47	93.46	94.19	91.0	94.69
	average	85.25	88.99	90.94	92.39	92.35	94.02	91.5	95.77
US-MNIST	MNIST \rightarrow USPS	56.28	68.43	60.23	62.30	65.34	62.65	68.4	69.85
	USPS \rightarrow MNIST	51.26	59.22	60.65	68.47	63.15	78.92	74.2	78.69
	average	53.77	63.83	60.44	65.38	64.25	70.78	71.3	74.27

根据表3分析,相较于其他域适应方法,所提出算法在全部任务上平均准确率超越其余7种算法.多数任务中,所提出算法取得最优性能,在3个任务的比例分别为6/12、2/2、2/2,平均准确率较其余7种

方法得到的最优结果提高了1.88%、2.22%和8.89%,综合分析,所提出方法能够实现较高的分类准确率,验证了所提出算法的有效性.

综上所述,所提出的跨域流形正则化特征域适应

方法,弥补了现有域适应方法未能充分考虑原始数据的判别信息以及结构信息的不足,且充分利用了目标域无标签信息. 大多情况下取得优越结果,具体实现了以下目标: 1) 最小化源域与目标域的分布差异; 2) 充分保持了原始数据的判别信息,通过最大域内类密度,利用迭代优化的基分类器所得目标域伪标签信息,使得源域和目标域同类别密度更紧凑,不同类别显著分开; 3) 维持原始数据局部邻域结构信息,利用局部流形正则化方法,同时维持源域和目标域在跨域适应迁移时结构不被完全破坏,避免负迁移的发生,保证较好的目标域分类识别效果.

4.2 铜浮选过程的仿真

4.2.1 浮选过程描述

本文选取浮选过程3种工况下的浮选泡沫图像进行工况识别,从相似完备浮选过程中获取大量已训练的图像过程信息,含有工况标签,应用所提出方法,迁移至不完备浮选过程,从而建立分类识别模型. 这3种工况具体情况如表4所示,对应图像如图4所示.

表4 铜浮选3种典型工况

工况类型	特点
工况A	药剂欠添加,尺寸较大,分布不均,泡沫较虚,承载率小
工况B	药剂正常,尺寸合适,分布均匀,颜色发亮,泡沫实
工况C	药剂过量,气泡承载的矿物粒子过饱和,使大量泡沫破碎,造成塌陷



工况A



工况B



工况C

图4 3种工况下的泡沫图像

4.2.2 实验结果及分析

为验证所提出方法在浮选过程识别的有效性,本文构造了源域和目标域样本占不同比例的6组实验,这样构造的另一方面原因,还可验证随着目标域样本的逐渐增多对其分类识别准确率的影响. 可划分为两大类: 1) 从源域数据集中选取包含3类工况的600个样本,从目标域数据集中逐个选取30、60、100个样本作为1~3组实验,此外可从新浮选工艺再收集对应30个已知标签的样本,用上述第1~3组实验建立最优的分类识别模型以测试分类识别效果并绘图. 2) 从源域数据集中选取包含3类工况的900个样本,从目标域数据集中逐个选取30、60、100个样本作为4~6组实验,此外可从新浮选工艺再收集对应30个

已知标签的样本,用上述4~6组实验得到建立的最优分类识别模型以测试分类识别效果. 实验分组情况如表5所示.

表5 实验分组情况

源域样本数	组别	目标域样本数
600	1	30
	2	60
	3	100
900	4	30
	5	60
	6	100

首先对每类特征应用跨域流形正则化特征域适应方法,验证所提出方法在浮选工况识别中的有效性,由第3组别的原始数据进行仿真分析并tsne特征可视化,如图5所示.

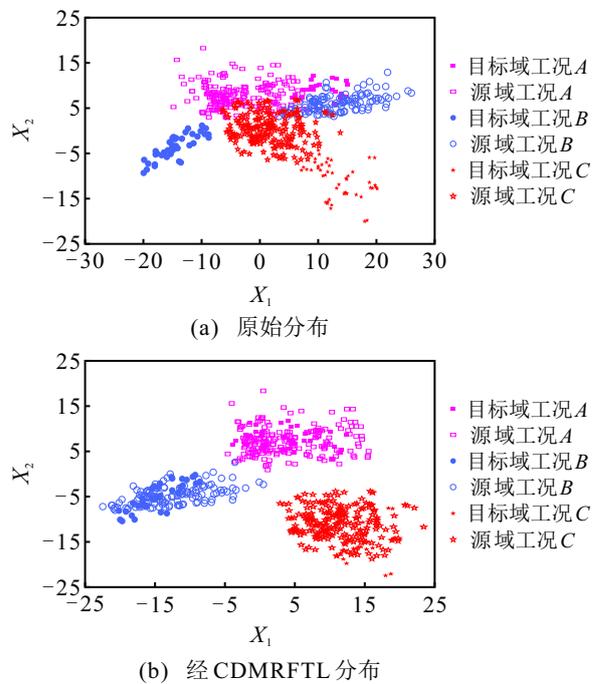


图5 源域和目标域特征分布可视化

由图5(a)可见,域内特征不可分,分布差异大,图5(b)经过跨域流形正则化后,其域内最大化类密度,使其同类的更紧凑,不同类别分开,且保持其原有的局部邻域结构,使得源域与目标域的分布差异减小,可判别性增强,从而得到较好的分类效果. 对源域和目标域样本提取的每一类特征均运用跨域流形正则

表6 各特征以及融合后的分类准确率

实验组别	静态特征/%	动态特征/%	D-S融合/%
1	88.36	92.77	93.13
2	89.25	93.56	93.34
3	91.58	95.62	96.23
4	87.26	90.22	91.65
5	89.49	93.38	94.28
6	92.27	96.84	96.68

化特征域适应方法进行分类识别,识别效果有好有坏,但是通过D-S理论对这两种特征识别结果标签进行融合后,最终得到的结果基本接近这两类单独识别最理想效果,具有较高的分类识别准确率.如表6所示.

由表6可见,运用CDMRFTL算法单独对动态特征识别较静态特征的准确率有明显提高,这是因为动态特征所提取到的信息具有更强的表达能力,可促进分类识别能力的提升.运用CDMRFTL算法结合D-S理论融合的分类结果又比对单一特征的效果有了提升,可见D-S理论能够有效提高分类识别的准确率.另外从表6还可得出,随着目标域样本的逐渐增多,其分类准确率也会随之增加,这是由于随着目标域样本增多,其所含目标域信息投影至公共特征空间也越来越多,目标域特征也越精确,从而判别新特征样本能力增强.

另外再收集30个已知标签的样本,结合D-S理论融合进行浮选工况分类识别,结果如图6所示,其中测试样本1~10属于工况A,测试样本11~20属于工况B,测试样本21~30属于工况C.

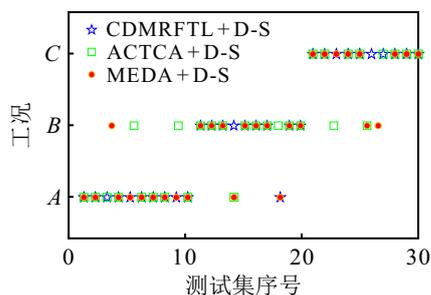


图6 不同跨域适应方法结合D-S识别结果

图6表明所提出方法结合D-S理论后比ACTCA、MEDA与D-S融合后的分类识别效果更好,进一步验证了所提出方法的有效性.

5 结论

本文针对浮选工艺过程缺失故障工况信息无法建立有效准确的工况识别模型问题,提出一种新的基于跨域流形正则化特征域适应方法,通过最大化域内类密度保持原始数据的本质信息,并充分利用目标域的伪标签信息,判别能力得以增强,又通过流形正则化保持域内局部邻域结构不变,避免负迁移的发生,在保证以上两种约束的同时,缩小源域与目标域的分布差异并投影至公共特征空间中,建立分类识别模型,随后运用于处理浮选泡沫图像所提取的静态特征和动态特征,结合D-S理论对其识别标签信息进行融合,得到最终分类结果.将所提出方法应用于浮选过程工况识别,首先在几组常见的域适应领域数据

集仿真,验证了所提出CDMRFTL算法的有效性和性能;然后应用于实际铜浮选过程中,在收集少量不完备浮选工艺过程数据的基础上,充分利用已有相似完备浮选过程的数据信息,将提取到的静态特征和动态特征信息,结合D-S理论融合,进一步提高分类识别效果.实验结果表明了所提出方法的可行性和有效性.如何解决多源域以及源域和目标域异构问题是需要进一步研究的问题.

参考文献(References)

- [1] D. W. 莫尔曼. 在浮选厂中数据图象处理与主机联机监测泡沫[J]. 国外金属矿选矿, 1996, 33(7): 41-49. (D. W. Morman. Data image processing and mainframe on-line monitoring of foam in flotation plant [J]. Metal Ore Dusting Abroad, 1996, 33(7): 41-49.)
- [2] Moolman D W, Eksteen J J, Aldrich C, et al. The significance of flotation froth appearance for machine vision control[J]. International Journal of Mineral Processing, 1996, 48(3/4): 135-158.
- [3] 桂卫华, 阳春华, 徐德刚, 等. 基于机器视觉的矿物浮选过程监控技术研究进展[J]. 自动化学报, 2013, 39(11): 1879-1888. (Gui W H, Yang C H, Xu D G, et al. Machine-vision-based online measuring and controlling technologies for mineral flotation—A review[J]. Acta Automatica Sinica, 2013, 39(11): 1879-1888.)
- [4] Sadr-Kazemi N, Cilliers J J. An image processing algorithm for measurement of flotation froth bubble size and shape distributions[J]. Minerals Engineering, 1997, 10(10): 1075-1083.
- [5] Moolman D W, Aldrich C, Schmitz G P J, et al. The interrelationship between surface froth characteristics and industrial flotation performance[J]. Minerals Engineering, 1996, 9(8): 837-854.
- [6] Wang W X, Stephansson O. A robust bubble delineation algorithm for froth images[C]. Proceedings of the 2nd International Conference on Intelligent Processing and Manufacturing of Materials. Honolulu, 1999: 471-476.
- [7] 王红平, 齐春, 李金标, 等. 基于主成分分析的矿物浮选泡沫图像分类与识别[J]. 矿冶, 2005, 14(3): 79-82. (Wang H P, Qi C, Li J B, et al. Classification and recognition of mineral flotation froth images based on principal component analysis[J]. Mining and Metallurgy, 2005, 14(3): 79-82.)
- [8] 任传成. 基于彩色图像处理的硫化铜精矿泡沫特征与品位分析研究[D]. 徐州: 中国矿业大学, 2014. (Ren C C. Relationship between froth features and grade of copper sulfide concentrate based on color image processing[D]. Xuzhou: China University of Mining and Technology, 2014.)
- [9] 何明芳, 阳春华, 王晓丽, 等. 基于模糊支持向量机的硫浮选工况识别[J]. 中国有色金属学报, 2013, 23(12): 3478-3483. (He M F, Yang C H, Wang X L, et al. Performance

- recognition of sulfur flotation based on fuzzy support vector machine[J]. *The Chinese Journal of Nonferrous Metals*, 2013, 23(12): 3478-3483.)
- [10] Lu J D, Yao K, Gao F R. Process similarity and developing new process models through migration[J]. *AIChE Journal*, 2009, 55(9): 2318-2328.
- [11] Pan S J, Yang Q. A survey on transfer learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2010, 22(10): 1345-1359.
- [12] Hua W, Nie F P, Heng H, et al. Dyadic transfer learning for cross-domain image classification[C]. *International Conference on Computer Vision*. Barcelona 2011: 551-556.
- [13] Guillaumin M, Ferrari V. Large-scale knowledge transfer for object localization in imagenet[C]. *IEEE Conference on Computer Vision and Pattern Recognition*. Providence, 2012: 3202-3209.
- [14] 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.
- [15] Long M S, Wang J M, Ding G G, et al. Transfer feature learning with joint distribution adaptation[C]. *IEEE International Conference on Computer Vision*. Sydney, 2013: 2200-2207.
- [16] Gheisari M, Baghshah M S. Unsupervised domain adaptation via representation learning and adaptive classifier learning[J]. *Neurocomputing*, 2015, 165: 300-311.
- [17] Wang J D, Feng W J, Chen Y Q, et al. Visual domain adaptation with manifold embedded distribution alignment[C]. *Proceedings of the 26th ACM International Conference on Multimedia*. Seoul, 2018: 402-410.
- [18] Gretton A, Borgwardt K M, Rasch M J, et al. A kernel two-sample test[J]. *Cambridge MA: JMLR*, 2012, 13(3): 723-773.
- [19] Ormándi R, Hegedűs I, Farkas R. Opinion mining by transformation-based domain adaptation[C]. *Text, Speech and Dialogue*. Heidelberg, 2010: 157-164.
- [20] Belkin M, Niyogi P, Sindhwani V. Manifold regularization: A geometric framework for learning from labeled and unlabeled examples[J]. *Journal of Machine Learning Research*, 2006, 7(1): 2399-2434.
- [21] Lee T, Choi M, Yoon S. Manifold regularized deep neural networks using adversarial examples[J/OL]. 2015, arXiv: 1511.06381.
- [22] Guan N Y, Tao D C, Luo Z G, et al. Manifold regularized discriminative nonnegative matrix factorization with fast gradient descent[J]. *IEEE Transactions on Image Processing*, 2011, 20(7): 2030-2048.
- [23] Jiang W, Hu W W. An improved soft likelihood function for Dempster-Shafer belief structures[J]. *International Journal of Intelligent Systems*, 2018, 33(6): 1264-1282.
- [24] 刘金平, 桂卫华, 牟学民, 等. 基于Gabor小波的浮选泡沫图像纹理特征提取[J]. *仪器仪表学报*, 2010, 31(8): 1769-1775.
(Liu J P, Gui W H, Mu X M, et al. Flotation froth image texture feature extraction based on Gabor wavelets[J]. *Chinese Journal of Scientific Instrument*, 2010, 31(8): 1769-1775.)
- [25] 王勇, 胡士强. 基于混沌特征的运动模式分割和动态纹理分类[J]. *自动化学报*, 2014, 40(4): 604-614.
(Wang Y, Hu S Q. Chaotic features for motion pattern segmentation and dynamic texture classification[J]. *Acta Automatica Sinica*, 2014, 40(4): 604-614.)
- [26] Kaartinen J, Hätönen J, Hyötyniemi H, et al. Machine-vision-based control of zinc flotation—A case study[J]. *Control Engineering Practice*, 2006, 14(12): 1455-1466.
- [27] Gong B Q, Shi Y, Sha F, et al. Geodesic flow kernel for unsupervised domain adaptation[C]. *IEEE Conference on Computer Vision and Pattern Recognition*. Providence, 2012: 2066-2073.
- [28] Liu H F, Shao M, Ding Z M, et al. Structure-preserved unsupervised domain adaptation[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2019, 31(4): 799-812.
- [29] Wang C, Tuo H Y, Wang J X, et al. Discriminative transfer learning via local and global structure preservation[J]. *Signal, Image and Video Processing*, 2019, 13(4): 753-760.
- [30] 陶洋, 杨雯, 翁善, 等. 基于迁移子空间的半监督领域自适应方法[J]. *计算机工程与设计*, 2021, 42(8): 2308-2315.
(Tao Y, Yang W, Weng S, et al. Semi-supervised domain adaptation via transfer subspace[J]. *Computer Engineering and Design*, 2021, 42(8): 2308-2315.)

作者简介

安迪(1997—), 男, 硕士生, 从事复杂工业过程故障监测与诊断的研究, E-mail: 1046721580@qq.com;

王姝(1979—), 女, 副教授, 博士, 从事复杂工业过程故障监测、故障诊断与预测等研究, E-mail: wangshu@ise.neu.edu.cn;

关展旭(1995—), 男, 硕士生, 从事数据融合、贝叶斯网络、故障诊断的研究, E-mail: 1304071518@qq.com;

刘尧(1997—), 男, 硕士生, 从事故障诊断及预测、迁移学习以及贝叶斯网络的研究, E-mail: ly13840453397@126.com;

张林(1998—), 男, 硕士生, 从事深度学习、故障诊断及自愈控制的研究, E-mail: 1379212199@qq.com.