

基于最大均值差异多源域迁移学习的 湿式球磨机负荷参数软测量

阎高伟¹, 贺敏¹, 汤健^{2†}, 韩东升¹

(1. 太原理工大学 信息工程学院, 太原 030024; 2. 北京工业大学 信息部, 北京 100124)

摘要: 针对湿式球磨机工况改变时, 实时数据与建模数据分布不一致, 不满足数据同分布的假设, 传统软测量模型难以适应数据分布变化, 造成模型性能恶化的问题, 有针对性地引入迁移学习策略, 并通过多源域集成机制提高模型的鲁棒性, 实现多工况下湿式球磨机负荷参数测量. 首先, 对多工况数据进行预处理并提取频谱特征, 经过联合分布适配对多工况数据进行边缘、条件分布适配; 然后, 使用最大均值差异对适配后的数据进行分布度量并为源域构建的回归器加权; 最后, 对目标域数据进行负荷预测. 通过对比实验与交叉实验表明了模型的实用性和有效性.

关键词: 湿式球磨机负荷; 最大均值差异; 联合分布适配; 多源域; 软测量; 迁移学习

中图分类号: TP29

文献标志码: A

Soft sensor of wet ball mill load based on maximum mean discrepancy multi-source domain transfer learning

YAN Gao-wei¹, HE Min¹, TANG Jian^{2†}, HAN Dong-sheng¹

(1. College of Information Engineering, Taiyuan University of Technology, Taiyuan 030024, China; 2. Information Department, Beijing University of Technology, Beijing 100124, China)

Abstract: When the working condition of a wet ball mill is changed, the distribution of real-time data and modeling data is inconsistent. It is difficult to accurately measure the load parameters by using the traditional soft sensor algorithm based on historical data. Therefore, a transfer learning strategy is introduced, and the robustness of the model is improved by the multi domain mechanism. The process is to preprocess and extract the characteristics of multi working conditions data, and the distribution of the edge and the conditional distribution is obtained by joint distribution fitting. Then the maximum mean discrepancy is used to measure the distribution of adaptive data, and the calculated results are applied to the regression weighted. Finally, the target domain data is used for load forecasting. The practicability and effectiveness of the model are illustrated by comparing experiments and cross experiments.

Keywords: wet ball mill load; maximum mean discrepancy; joint distribution adaptation; multi source domain; soft sensor; transfer learning

0 引言

湿式球磨机是磨矿、电力、冶金等领域中广泛使用的基础设备, 其耗电量达到厂用电的30%~70%, 是用电大户, 同时也是节能大户^[1]. 准确测量磨机内部的充填率(Charge volume ratio, CVR), 料球比(Material to ball volume ratio, MBVR), 磨矿浓度(Pulp density, PD)等负荷参数, 是及时调整磨机的装球量及

给料量, 使磨机稳定运行在最佳负荷点, 避免饱磨、空磨及堵磨现象并实现节能降耗的关键. 但是受限于设备旋转特性以及参数非线性、时变性、机理复杂、大时滞及随机干扰大等特性, 其关键参数不能直接实时监测^[2].

近年来, 软测量理论技术的发展为上述问题提供了一个有效的解决方案. 广泛用于软测量的算法有

收稿日期: 2017-05-23; 修回日期: 2017-09-07.

基金项目: 国家自然科学基金项目(61450011, 61573364); 山西省自然科学基金项目(2015011052); 山西省煤基重点攻关项目(MD 2014-07).

责任编辑: 侯忠生.

作者简介: 阎高伟(1970—), 男, 教授, 博士, 从事智能信息处理、多传感器信息融合等研究; 汤健(1974—), 男, 教授, 博士, 从事工业自动化、数据驱动软测量建模等研究.

†通讯作者. E-mail: tjian001@126.com

BP神经网络方法^[3]、支持向量机(SVM)^[4]方法、偏最小二乘回归(PLSR)方法^[5]以及汤健等^[6]针对单一模型在多参数测量时精度欠佳等问题而提出的选择性集成软测量模型. 工况稳定时这些算法性能良好,但是磨机在运行过程中会因为钢球的磨损以及物料材质的变化,导致特性漂移. 针对历史数据构建的模型在特性缓慢漂移情况下性能下降的问题,文献[7]提出使用在线主成分分析(On-line principal component analysis, OLPCA)、文献[8]提出在线核偏最小二乘(On-line kernel partial least squares, OLKPLS)、文献[9]结合局部学习框架和在线支持向量机,提出了多模态软测量建模方法.

上述软测量建模方法建立在建模数据和测试数据同分布假设的基础上. 实际工业过程中,经常会出现突然添加钢球、物料成分变化以及运行任务改变而导致工况发生较大变化的情况. 此时,实时数据和历史建模数据分布差异较大,造成传统软测量模型预测性能恶化,而重新收集所需的训练数据再次训练模型代价昂贵且实际中是不可行的. 鉴于上述情况,本文有针对性地引入迁移学习策略来解决因工况变化引起数据分布失配而导致的模型失准的问题;并采用多源域集成学习机制充分利用多个相关建模领域数据来提高模型的鲁棒性.

1 相关算法介绍

1.1 最大均值差异

最大均值差异(Maximum mean discrepancy, MMD)最早提出时是用于双样本检测问题,用于判断两个分布是否相同^[10]. MMD的原理如下所述:假设存在一个满足 P 分布的源领域 $X^{(s)} = [x_1^{(s)}, \dots, x_{n_s}^{(s)}]$ 和一个满足 Q 分布的目标领域 $X^{(t)} = [x_1^{(t)}, \dots, x_{n_t}^{(t)}]$. 令 H 为再生核希尔伯特空间(Reproducing kernel Hilbert space, RKHS), $\phi(\cdot) : X \rightarrow H$ 表示原始特征空间映射到RKHS的映射函数,当 $n_s, n_t \rightarrow \infty$ 时 $X^{(s)}$ 和 $X^{(t)}$ 在RKHS中的最大均值差异(MMD)为

$$f(X^{(s)}, X^{(t)}) = \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \phi(x_i^{(s)}) - \frac{1}{n_t} \sum_{j=1}^{n_t} \phi(x_j^{(t)}) \right\|_H. \quad (1)$$

MMD度量源域数据与目标域数据的总体均值差异,可用于表示源域与目标域之间的分布差异,并广泛地应用于迁移学习中^[11-12].

1.2 联合分布适配

多工况情况下,传统软测量模型恶化的原因是实时数据与训练数据的概率分布失配,如果通过一种变换方法使得不同工况的数据在新的空间达到边缘

分布和条件分布适配,则可以将源领域的模型或知识迁移到新的工况. 联合分布适配(Joint distribution adaptation, JDA)^[13]用于在降维过程中共同适应源域(已知标签的建模数据)与目标域(标签未知的待测数据)的边缘分布与条件分布,但是对于分布差异较大的情况并不能使其分布完全适配. 鉴于此,本文综合各个工况下数据分布的差异、适配后的数据分布差异,提出使用最大均值差异-联合分布适配的多源域迁移学习方法.

1.2.1 特征变换

主成分分析(Principal component analysis, PCA)通过最小化输入数据的重构误差而获得一种新的特征表示. 其中: $X = [x_1, \dots, x_n] \in \mathbf{R}^{m \times n}$ 是输入数据矩阵; $H = I - \frac{1}{n} \mathbf{1} \mathbf{1}^T$ 是中心矩阵, $n = n_s + n_t$ 是源域和目标域样本数之和, $\mathbf{1}$ 是 $n \times n$ 的全1矩阵. 协方差矩阵可用 XHX^T 计算,PCA的学习目标是得到一个正交变换矩阵 $A \in \mathbf{R}^{m \times k}$,使得内嵌数据方差最大,可由下式表示:

$$\max_{A^T A = I} \text{tr}(A^T X H X^T A), \quad (2)$$

$\text{tr}(\cdot)$ 表示矩阵的迹. 最优问题可通过对 $XHX^T A = A\Phi$ 进行特征分解加以计算,其中 $\Phi = \text{diag}(\phi_1, \dots, \phi_k) \in \mathbf{R}^{k \times k}$ 是 k 个最大特征,可通过 $Z = [z_1, \dots, z_n] = A^T X$ 得到其 k 维特征表示.

1.2.2 边缘分布适配

通过PCA降维后的数据,并未消除域间数据分布差异. 为了减小 $P_s(X_{(s)})$ 和 $P_t(X_{(t)})$ 的分布差异,这里采用扩展非参数最大均值差异(Extend maximum mean discrepancy, EMMD)来计算源域和目标域 k 维内嵌数据样本之间的距离^[13],即

$$\left\| \frac{1}{n_s} \sum_{i=1}^{n_s} A^T x_i - \frac{1}{n_t} \sum_{j=n_s+1}^{n_s+n_t} A^T x_j \right\|^2 = \text{tr}(A^T X M_0 X^T A). \quad (3)$$

其中 M_0 是EMMD矩阵,可由下式计算得到:

$$(M_0)_{ij} = \begin{cases} \frac{1}{n_s n_s}, & x_i, x_j \in D_s; \\ \frac{1}{n_t n_t}, & x_i, x_j \in D_t; \\ -\frac{1}{n_s n_t}, & \text{Otherwise.} \end{cases} \quad (4)$$

通过最小化式(4)使得式(3)最大化,域间的边缘分布在新特征表示下更加相近.

1.2.3 条件分布适配

目标域中存在大量的无标签数据,导致条件分布 $Q_s(y_s|x_s)$ 和 $Q_t(y_t|x_t)$ 不能直接建模. 通过源域数

据建立的模型可以构建出目标域对应的伪标签, 根据伪标签, 可以近似匹配预测空间 Y 中每一标签 $c \in \{1, 2, \dots, C\}$ 的条件分布 $Q_s(x_s|y_s=c)$ 与 $Q_t(x_t|y_t=c)$. 通过EMMD来测量条件分布的距离

$$\left\| \frac{1}{n_s^{(c)}} \sum_{x_i \in D_s^{(c)}} A^T x_i - \frac{1}{n_t^{(c)}} \sum_{x_j \in D_t^{(c)}} A^T x_j \right\|^2 = \text{tr}(A^T X M_c X^T A). \quad (5)$$

其中

$$(M_c)_{ij} = \begin{cases} \frac{1}{n_s^{(c)} n_t^{(c)}}, & x_i, x_j \in D_s^{(c)}; \\ \frac{1}{n_t^{(c)} n_t^{(c)}}, & x_i, x_j \in D_t^{(c)}; \\ \frac{-1}{n_s^{(c)} n_t^{(c)}}, & \begin{cases} x_i \in D_s^{(c)}, x_j \in D_t^{(c)}; \\ x_j \in D_s^{(c)}, x_i \in D_t^{(c)}; \end{cases} \\ 0, & \text{Otherwise.} \end{cases} \quad (6)$$

通过最小化式(6)使得式(5)最小, 在新的特征表示下域间的条件分布更加接近.

1.2.4 最优化问题

为了提高JDA的迁移学习有效性和鲁棒性, 需要同时最小化领域间的边缘分布和条件分布, 因此JDA的最优化问题为

$$\min_{A^T X H X^T A = I} \sum_{c=0}^C \text{tr}(A^T X M_c X^T A) + \lambda \|A\|_F^2, \quad (7)$$

其中 λ 为正则化参数.

1.2.5 特征变换

解决联合分布适配最优化问题采用拉格朗日乘子法, 取拉格朗日乘子为 $\Phi = \text{diag}(\phi_1, \dots, \phi_k)$, 则式(7)的拉格朗日函数为

$$L = \text{tr}\left(A^T \left(X \sum_{c=0}^C M_c X^T + \lambda I\right) A\right) + \text{tr}\left((I - A^T X H X^T A) \Phi\right). \quad (8)$$

令 $\partial L / \partial A = 0$, 得到广义特征值分解

$$\left(X \sum_{c=0}^C M_c X^T + \lambda I\right) A = X H X^T A \Phi. \quad (9)$$

最后, 求解最优适应矩阵 A 的过程可以简化为求解式(9)的 k 个最小的特征向量.

2 基于最大均值差异多源域迁移学习的湿式球磨机负荷参数软测量

原矿石通过球磨机破碎后得到粒度合格的矿浆, 为后续作业提供原料. 矿浆浓度(PD)、充填率(CVR)以及料球比(MBVR)可以准确地反映出磨机内部的工作状态以及磨机负荷^[14]. 湿式球磨机会因为突然添加钢球或者物料材质改变而工况改变, 导致传统软测量模型性能恶化而不能准确检测磨机负荷. 考虑到工况改变后的数据分布差异, 以及多工况之间的潜在关联关系^[15], 本文结合联合分布适配迁移学习策略及最大均值差异可以准确度量分布差异的特性, 提出基于最大均值差异多源域集成迁移学习(Maximum mean discrepancy-joint distribution adaptation, MMD-JDA)的湿式球磨机负荷参数软测量.

基于MMD-JDA的磨机负荷参数软测量模型的策略如图1所示. 首先将 n 个经过预处理的工况数据(源域) $\{x_i^s, y_i^s\}_{i=1}^n$ 合并成一个大的源域数据集 $\{X^s, Y^s\}$, 并与预处理后的待测工况数据(目标域) $\{X^t\}$ 通过下式减小域间分布差异:

$$(X'^s X'^t) = \text{JDA}(X^s, Y^s, X^t). \quad (10)$$

其中: $\text{JDA}(\cdot)$ 为联合分布适配算法, X'^s 为域适应后的源域数据, X'^t 为域适应后的目标域数据. 随后将 X'^s 分解成单源域表示形式 $\{x_i'^s, y_i'^s\}_{i=1}^n$, 每一对源域数据建立一个回归模型 $f_i(\cdot), i \in [1, n]$.

JDA并不能使多个已知工况和待测工况的数据分布完全适应, 因此使用MMD分别度量各个已知工况与待测工况的分布, 可用下式表示:

$$d_i = \frac{1}{\text{MMD}(x_i'^s, X'^t)}, \quad i \in [1, n]. \quad (11)$$

其中: $\text{MMD}(\cdot)$ 表示式(1)的计算过程, $x_i'^s$ 为第 i 个分

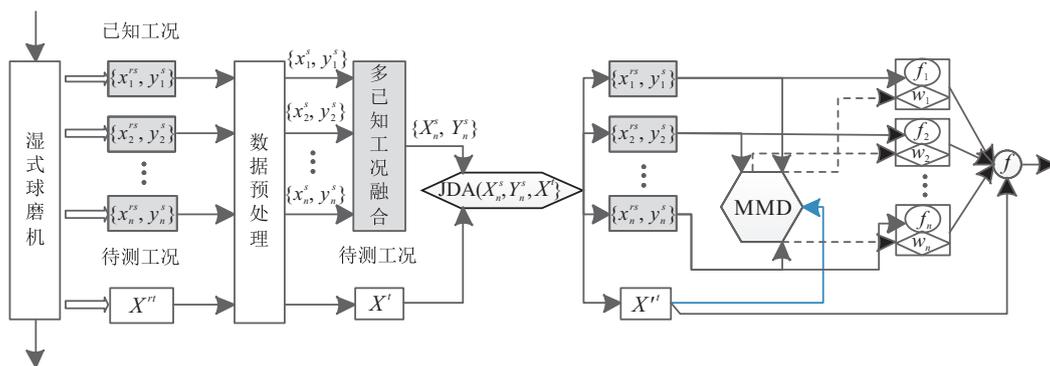


图1 基于MMD-JDA的湿式球磨机负荷参数软测量策略

布适配后的源域, X^t 为目标域数据, d_i 为第 i 个域适应后的源域数据与目标域数据的最大均值差异值的倒数.

通过下式计算得到每个回归器的权值:

$$w_i = \frac{d_i}{\sum_{i=1}^n d_i}, i \in [1, n]. \quad (12)$$

集成回归模型 $f(\cdot)$ 可以表示为

$$f = w_1 f_1 + w_2 f_2 + \dots + w_n f_n. \quad (13)$$

最后 X^t 通过式 (13) 得出的集成模型进行负荷参数预测.

3 基于实验湿式球磨机的实验研究

3.1 实验数据处理

实验在容积为 200 L 的小型湿式球磨机上进行, 采用功率为 4 kW 的三相电机驱动. 为了模拟实际工业中工况的变化, 实验中采取了分别固定介质充填率的 3 组实验方案 (介质充填率分别为 0.3、0.4、0.5, 分别定义为工况 1、工况 2、工况 3), 即每组实验都固定相应的筒内球的质量和水的量, 通过改变物料的质量来得到不同的负荷参数. 为保证负荷参数的高分辨率, 不同的工况都做充分的试验. 磨机筒体振动信号由现场同步采集, 对每个工况下每次实验都进行振动信号采集, 最终获得 329 组振动信号数据. 然后将每组振动信号平均分为 20 个样本, 对每个样本进行快速傅里叶变化 (Fast Fourier transformation, FFT), 将时域数据转化至频域.

分别对 3 个工况数据通过等距映射 (IsoMap) 降维, 降维结果的散点图如图 2 所示. 可以看出, 工况改变后数据分布不一致.

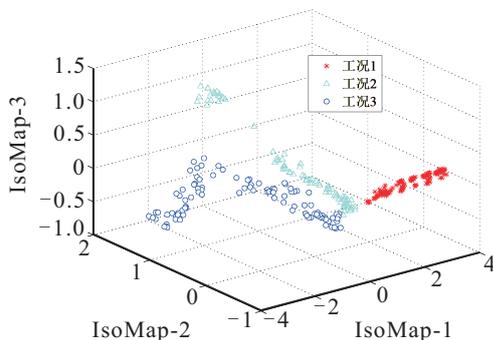


图 2 3 个不同工况的数据分布图

3.2 算法评估标准介绍

为了评价所提出方法的预测能力, 并考虑到有多个磨机负荷参数的问题, 本文使用均方根误差 (Root mean square error, RMSE) 和标准均方根误差 (Normalized root mean square error, NRMSE) 作为衡量模型预测性能的评价标准, 其计算公式分别为

$$RMSE = \sqrt{\frac{1}{T} \sum_{i=1}^T (\hat{y}_i - y_i)^2}, \quad (14)$$

$$NRMSE = \frac{RMSE}{y_{\max} - y_{\min}}. \quad (15)$$

其中: y_i 和 \hat{y}_i 表示第 i 个样本的实际值和估计值, T 为测试样本个数.

3.3 实验结果与分析

为了说明湿式球磨机工况发生改变时引入迁移学习策略的必要性, 首先使用最小二乘支持向量机 (Least squares support vector machines, LSSVM) 分别对工况 1~工况 3 建模, 并用其他工况进行测试, 结果如表 1 所示.

表 1 未使用迁移学习浓度预测结果

建模工况	评价指标	工况 1	工况 2	工况 3
工况 1	RMSE	0.0184	0.125 1	0.550 7
	NRMSE	0.0047	0.371 7	1.098 5
工况 2	RMSE	0.1094	0.0110	0.232 2
	NRMSE	0.266 2	0.0327	0.463 2
工况 3	RMSE	0.185 8	0.141 9	0.0069
	NRMSE	0.452 1	0.421 6	0.0138

图 3 是使用 LSSVM 建模的结果, 其中虚线表示真实值, 实线表示预测值, 子图标题 $i-j$ 表示工况 i 建模, 工况 j 测试, 每个子图横坐标为样本数, 纵坐标为浓度值.

由图 3 中可以看出, 在一个工况下构建的模型在同一工况下进行测试, 模型具有很好的预测能力, 当工况发生改变时, 会因为工况间数据分布不一致而模型性能恶化. 因此有必要引入迁移学习策略.

对上文建立的 MMD-JDA 模型进行 Matlab 仿真. 文中使用 LSSVM 作为回归器, 分别使用 LSSVM、JDA、MMD-JDA 三种算法对工况 2 和工况 3 进行磨机负荷参数预测的交叉实验, 预测结果如表 2 所示. 其中: LSSVM[K] 表示使用第 K 个工况作为源域并使用 LSSVM 算法进行预测, JDA 也用同样的形式表示, M-J 表示目标域外的所有数据通过 MMD-JDA 进行集成学习.

图 4 给出了工况 2 浓度的预测结果. 其中: 图 4(a) 和图 4(b) 分别表示对工况 1 和工况 3 使用 LSSVM 建模, 对工况 2 测试的结果; 图 4(c) 和图 4(d) 为分别使用工况 1、工况 3 作为源域, 通过 JDA 迁移学习算法对工况 2 进行浓度预测的结果; 图 4(e) 是工况 1 和工况 3 通过 MMD-JDA 集成学习对工况 2 浓度的预测结果.

由图 4 可以看出, 当工况发生改变时, 模型性能恶化, 使用 JDA 单源域迁移学习预测精度有所提升, 可以为实际工业过程提供一定的参考信息, 而 MMD-JDA 结合迁移学习策略和多源域集成学习机制, 充分

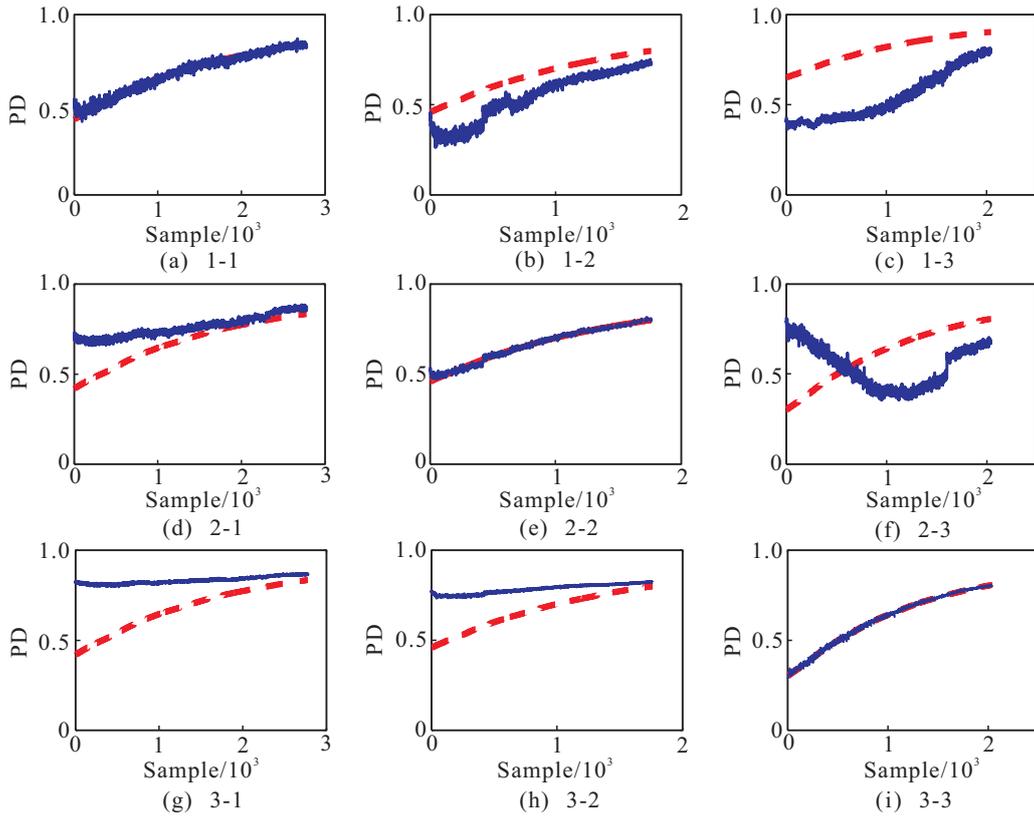


图3 3个不同工况的数据分布图

表2 不同方法对不同工况负荷参数预测结果

预测指标	评价指标	工况2为目标域					工况3为目标域				
		LSSVM[1]	LSSVM[3]	JDA[1]	JDA[3]	M-J	LSSVM[1]	LSSVM[2]	JDA[1]	JDA[2]	M-J
PD	RMSE	0.1251	0.1519	0.0540	0.0763	0.0218	0.5507	0.2322	0.1200	0.0994	0.0427
	NRMSE	0.3717	0.4216	0.1604	0.2266	0.0648	1.0985	0.4632	0.2393	0.1983	0.0851
MBVR	RMSE	0.4947	0.5396	0.4663	0.4266	0.0785	1.6682	0.9246	0.7266	0.3689	0.2628
	NRMSE	0.2683	0.2927	0.2529	0.2314	0.0426	1.0761	0.5964	0.4687	0.2380	0.1695
CVR	RMSE	0.4045	0.1987	0.0776	0.0556	0.0241	0.3524	0.1434	0.0752	0.0386	0.0134
	NRMSE	1.4436	0.7091	0.2769	0.1984	0.0860	1.1966	0.4869	0.2553	0.1310	0.0455

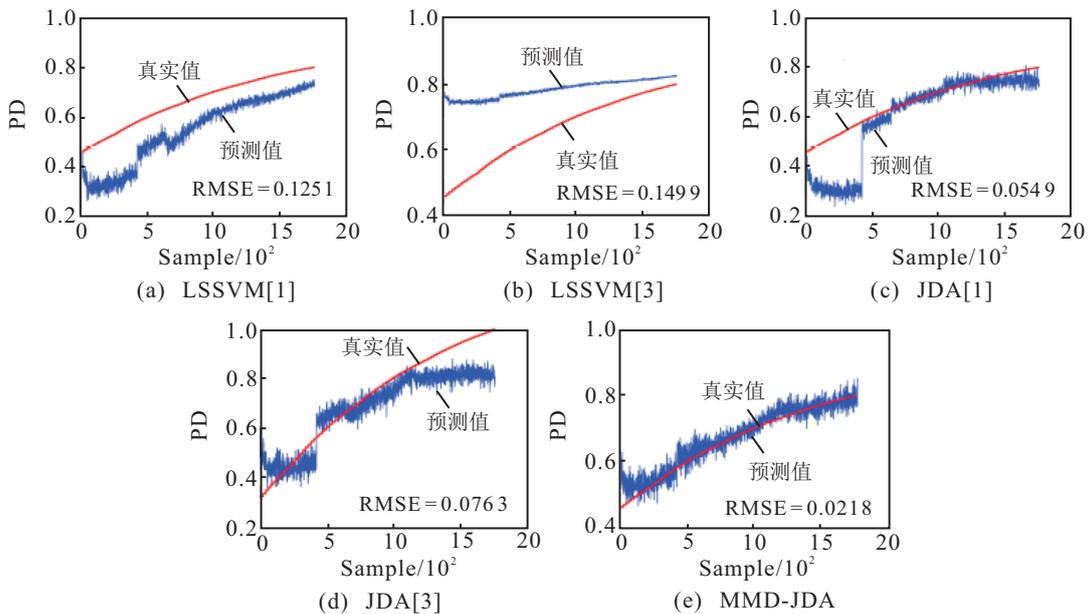


图4 不同方法对工况2浓度预测结果

考虑了建模数据的丰富度以及域间的关联关系,提高了模型的鲁棒性。

图5以柱状图形式给出了当工况发生改变时未使用迁移学习、使用JDA迁移学习以及使用MMD-JDA集成学习的RMSE对比图。可以看出,工况变化未使用迁移学习有较大的误差,通过JDA迁移学习,可以有效地提高模型的预测能力。采用MMD-JDA集成学习后模型的预测精度均有所提高,从而可以验证该模型的有效性。

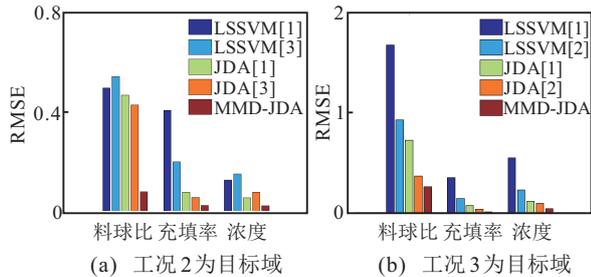


图5 不同方法对工况2浓度预测结果柱形图

4 结论

针对湿式球磨机工况改变导致数据不再服从独立同分布且原有模型失准的问题,本文引入迁移学习策略以及多源域集成学习机制,提出了一种基于最大均值差异的多源域迁移学习方法。首先,对预处理后的多工况数据进行联合分布适配,并用最大均值差异度量适配后的分布差异;随后,根据适配后的源域分别构建回归器,并利用度量结果给回归器加权从而构建集成模型。通过实验可知,在磨机工况改变时,引入迁移学习策略并通过多源域集成学习机制,可以提高测量结果的可信性与准确度。

参考文献(References)

- [1] 王恒, 贾民平, 陈左亮. 基于LS-SVM和机理模型的球磨机料位软测量[J]. 电力自动化设备, 2010, 30(7): 92-95.
(Wang H, Jia M P, Chen Z L. Soft measurement based on mechanism model and LS-SVM for fill level of ball mill[J]. Electric Power Automation Equipment, 2010, 30(7): 92-95.)
- [2] Zhou P, Chai T Y, Wang H. Intelligent optimal-setting control for grinding circuits of mineral processing process[J]. IEEE Trans on Automation Science & Engineering, 2009, 6(4): 730-743.
- [3] Tian H, Mao Z, Wang S, et al. Application of genetic algorithm combined with BP neural network in soft sensor of molten steel temperature[C]. The 6th World Congress on Intelligent Control and Automation. Dalian: IEEE, 2006: 7742-7745.
- [4] Tang J, Zhao L, Yu W, et al. Soft sensor modeling of ball mill load via principal component analysis and support vector machines[J]. Lecture Notes in Electrical Engineering, 2010, 67(67): 803-810.
- [5] 汤健, 郑秀萍, 赵立杰, 等. 基于频域特征提取与信息融合的磨机负荷软测量[J]. 仪器仪表学报, 2010, 31(10): 2161-2167.
(Tang J, Zheng X P, Zhao L J, et al. Soft sensing of mill load based on frequency domain feature extraction and information fusion[J]. Chinese J of Scientific Instrument, 2010, 31(10): 2161-2167.)
- [6] 汤健, 柴天佑, 丛秋梅, 等. 基于EMD和选择性集成学习算法的磨机负荷参数软测量[J]. 自动化学报, 2014, 40(9): 1853-1866.
(Tang J, Chai T Y, Cong Q M, et al. Soft sensor approach for modeling mill load parameters based on EMD and selective ensemble learning algorithm[J]. Acta Automatica Sinica, 2014, 40(9): 1853-1866.)
- [7] Tang J, Yu W, Chai T, et al. On-line principal component analysis with application to process modeling[J]. Neurocomputing, 2012, 82(1): 167-178.
- [8] 汤健, 柴天佑, 刘卓, 等. 基于更新样本智能识别算法的自适应集成建模[J]. 自动化学报, 2016, 42(7): 1040-1052.
(Tang J, Chai T Y, Liu Z, et al. Adaptive ensemble modelling approach based on updating sample intelligent identification[J]. Acta Automatica Sinica, 2016, 42(7): 1040-1052.)
- [9] Jin H, Chen X, Yang J, et al. Multi-model adaptive soft sensor modeling method using local learning and online support vector regression for nonlinear time-variant batch processes[J]. Chemical Engineering Science, 2015, 131: 282-303.
- [10] Gretton A, Borgwardt K M, Rasch M, et al. A kernel method for the two-sample-problem[C]. Conf on Advances in Neural Information Processing Systems. Vancouver: MIT Press, 2007: 513-520.
- [11] 姜海燕, 刘昊天, 舒欣, 等. 基于最大均值差异的多标记迁移学习算法[J]. 信息与控制, 2016(4): 463-470.
(Jiang H Y, Liu H T, Shu X, et al. Multi-label transfer learning via maximum mean discrepancy[J]. Information and Control, 2016(4): 463-470.)
- [12] Foulds J R, Frank E. Revisiting multiple-instance learning via embedded instance selection[J]. Australian Joint Conf on Artificial Intelligence, 2008, 5360(12): 300-310.
- [13] Long M, Wang J, Ding G, et al. Transfer feature learning with joint distribution adaptation[C]. Int Conf on Computer Vision. New York: IEEE, 2013: 2200-2207.
- [14] 汤健. 基于频谱数据驱动的旋转机械设备负荷软测量[M]. 北京: 国防工业出版社, 2015: 23-50.
(Tang J. Soft sensing of rotating machinery equipment load based on spectrum data drive[J]. Beijing: National Defense Industry Press, 2015: 23-50.)
- [15] Sun S, Shi H, Wu Y. A survey of multi-source domain adaptation[J]. Information Fusion, 2015, 24(C): 84-92.

(责任编辑: 孙艺红)