

基于流形正则化域适应随机权神经网络的 湿式球磨机负荷参数软测量

贺敏¹ 汤健² 郭旭琦¹ 阎高伟¹

摘要 针对湿式球磨机多工况运行过程中标签样本难以获取和工况改变导致的原测量模型失准问题, 本文引入域适应随机权神经网络 (Domain adaptive random weight neural network, DARWNN), 实现待测工况中少量标签样本与原工况样本共同进行迁移学习. DARWNN 网络解决了不同工况间难以共同进行机器学习的问题, 但其只考虑经验风险, 而未考虑结构风险, 从而泛化性能较差, 预测精度较低. 在此基础上, 本文引入流形正则化, 并构建基于流形正则化的域适应随机权神经网络 (Domain adaptive manifold regularization random weight neural network, DAMRRWNN), 以保持数据几何结构, 提高相应模型性能. 实验结果表明, 所提方法可以有效提高 DARWNN 的学习精度, 解决多工况情况下湿式球磨机负荷参数软测量问题.

关键词 迁移学习, 域适应, 磨机负荷, 流形正则化, 软测量

引用格式 贺敏, 汤健, 郭旭琦, 阎高伟. 基于流形正则化域适应随机权神经网络的湿式球磨机负荷参数软测量. 自动化学报, 2019, 45(2): 398–406

DOI 10.16383/j.aas.2018.c170289

Soft Sensor for Ball Mill Load Using DAMRRWNN Model

HE Min¹ TANG Jian² GUO Xu-Qi¹ YAN Gao-Wei¹

Abstract The problem of misalignment of the original measurement model is caused by the difficulty in obtaining the labeled sample and the change of working condition during the operation of the wet-type ball mill. In this paper, we introduce a domain adaptive random weight neural network (DARWNN), thus a small number of labeled samples in the working condition combined with the original working condition samples can be used to implement transfer learning. The DARWNN network can solve the problem of machine learning in different working conditions, however it considers only the empirical risk but not the structural risk. Thus the generalization performance is poor and the prediction accuracy is low. On this basis, we propose a domain adaptive manifold regularization random weight neural network (DAMRRWNN) in terms of manifold regularization to maintain data geometry structure, so as to improve the performance of the corresponding model. Experimental results indicate that the performance of the proposed methods is superior to or at least comparable with the existing benchmarking methods and that the proposed methods can effectively improve the learning accuracy of DARWNN and solve the problem of soft sensor for wet ball mill load parameters under multiple loading conditions.

Key words Transfer learning, domain adaption, mill load, manifold regularization, soft sensor

Citation He Min, Tang Jian, Guo Xu-Qi, Yan Gao-Wei. Soft sensor for ball mill load using DAMRRWNN model. *Acta Automatica Sinica*, 2019, 45(2): 398–406

收稿日期 2017-05-26 录用日期 2017-08-29
Manuscript received May 26, 2017; accepted August 29, 2017
国家自然科学基金 (61450011, 61573364), 山西省自然科学基金 (2015011052), 山西省煤基重点科技攻关项目 (MD 2014-07)
Supported by National Natural Science Foundation of China (61450011, 61573364), Natural Science Foundation of Shanxi Province of China (2015011052), and Key Project of Coal Based Science and Technology in Shanxi Province (MD 2014-07)

本文责任编辑 贺威

Recommended by Associate Editor HE Wei

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

1. College of Information Engineering, Taiyuan University of Technology, Taiyuan 030024 2. Information Department, Beijing University of Technology, Beijing 100124

磨机负荷 (Mill load, ML) 是指磨机中球、料、水的总和, 是选矿行业磨矿过程的重要参数^[1]. 准确检测 ML 是实现磨矿过程优化控制、节能降耗及提高磨矿效率、磨矿产品质量的关键. 但由于球磨机物理条件限制及其多变量、强耦合和非线性等特性使得负荷参数的监测难度大、性能不稳定、精度低, 从而制约了这类基础设备自动化水平的提高.

湿式球磨机负荷检测主要针对能够准确表征 ML 的磨机内部参数 (料球比 (Material to ball volume ratio, MBVR)、矿浆浓度 (Pulp density, PD)、充填率 CVR (Charge volume ratio, CVR))^[2]. 文献

[3]对不同研磨工况下的实验球磨机筒体振动信号进行了分析,并建立了基于主元分析(Principal component analysis, PCA)和最小二乘支持向量机的磨机负荷参数软测量模型,但支持向量机训练时需要求解凸二次规划问题,当样本规模较大时,需要较多的训练时间和存储空间.近年来,众多学者将随机学习思想应用于训练不同结构的神经网络,并提出多种类型的随机权神经网络(Random weight neural network, RWNN)模型,如单隐含层前馈神经网络^[4]、多隐含层前馈神经网络^[5]、随机权递归神经网络^[6]等.文献[7]将RWNN用于软测量建模,有效提高算法学习速度及泛化能力.文献[8]提出磨机负荷参数在线集成建模方法,以解决单一模型存在的信息融合不充分或信息冗余导致的泛化性能差、精度低问题.但是,钢球磨损或物料材质改变导致设备特性缓慢漂移问题依然存在.文献[9]针对多工况系统存在的非线性及工况漂移导致的预测精度下降问题,提出基于即时学习的自适应软测量方法,从而使软测量模型能够一定程度适应工况变化.

然而上述软测量建模方法均要求建模与测试样本数据基本满足独立同分布假设.在实际工业过程中,运行任务与设定值变化、原料及环境变化、设备重组等情况,容易导致系统工况发生突变,工况间数据分布不一致、系统具有多模态特性.对这样的多工况系统建模需要解决模态数据差异性,并考虑如何使模型具有适应模态变化、数据漂移的能力.因此本文有针对性的引入迁移学习(Transfer learning)^[10]策略,通过迁移原有工况下的知识结构和模型解决待测工况仅有少量标记样本,且待测工况与原有工况数据分布不同的问题.

文献[11]对RWNN模型进行改进,并提出域适应随机权神经网络(Domain adaptive random weight neural network, DARWNN),将其用于解决因传感器特性漂移引起的分类器性能恶化问题.但对数据的空间结构变化并未予以关注,且RWNN的权值随机初始化会使数据产生非线性结构,因此在软测量建模的回归问题中结果并不理想.

本文引入DARWNN,针对未建模的新工况,迁移源域所建模型的知识结构,从而完成或改进新工况的建模任务,实现待测工况负荷参数的测量,同时采用可以保持数据几何结构的流形正则化算法^[12-13]建立软测量模型.

综上,本文采用基于流形正则化的域适应随机权神经网络(Domain adaptive manifold regularization random weight neural network, DAMR-RWNN),解决工况变化引起的模型失准问题.通过

玉米样品的近红外光谱数据集和实验室球磨机数据进行实验验证,表明建立的软测量模型具有良好的适应性和较高的测量精度.

1 相关理论与算法

1.1 域适应随机权神经网络(DARWNN)^[11]

域适应随机权神经网络是一种基于单隐含层前馈神经网络(Single-hidden layer feed forward network, SLFN)的学习算法^[14].常用的单隐层随机权神经网络数学描述如下:

设训练集样本为 $\{\mathbf{x}^{(i)}, \mathbf{t}^{(i)}\}_{i=1}^M$, RWNN的隐含层单元个数为 n_h ,则RWNN模型的输出为:

$$\mathbf{t}^{(i)} = \sum_{j=1}^{n_h} \beta_j \phi(\mathbf{w}_j \mathbf{x}^{(i)} + \mathbf{b}_j), \quad i = 1, \dots, M \quad (1)$$

整理矩阵形式为:

$$H\beta = T \quad (2)$$

式中, β 为输出权值矩阵, w 为输入权值矩阵, b 为偏置.在随机权神经网络中, w 和 b 均随机选取, β 通过求解线性方程(3)计算获得,有效解决了基于梯度类学习算法训练速度慢、泛化性能差等问题^[15]:

$$\beta = H^\dagger T = (H^T H)^{-1} H^T T \quad (3)$$

式中, H^\dagger 表示矩阵 H 的Moore-Penrose广义逆.文献[16-17]分别在式(3)中添加L1、L2正则项来提高随机权神经网络的泛化性能,改善输出的鲁棒性.

为便于描述多模态问题,以下分别用下标 S 和 T 表示源域和目标域数据(在实际工业过程中分别代表原建模工况及待测工况).假设所有源域数据均有标签,目标域数据少部分有标签.DARWNN旨在通过源域所有标签样本及目标域少量标签样本训练得到模型参数,目标函数如下:

$$\min_{\beta, \xi_S^i, \xi_T^i} \left(\frac{1}{2} \|\beta\|^2 + C_S \frac{1}{2} \sum_{i=1}^{N_S} \|\xi_S^i\|^2 + C_T \frac{1}{2} \sum_{i=1}^{N_T} \|\xi_T^i\|^2 \right) \quad (4)$$

$$\text{s.t.} \begin{cases} \mathbf{H}_S^i \beta = \mathbf{t}_S^i - \xi_S^i, & i = 1, \dots, N_S \\ \mathbf{H}_T^j \beta = \mathbf{t}_T^j - \xi_T^j, & j = 1, \dots, N_T \end{cases} \quad (5)$$

其中, $\mathbf{H}_S^i \in \mathbf{R}^{1 \times L}$, $\xi_S^i \in \mathbf{R}^{1 \times m}$, $\mathbf{t}_S^i \in \mathbf{R}^{1 \times m}$ 分别表示源域的隐含层输出,预测误差及其第 i 个训练样本标签; $\mathbf{H}_T^j \in \mathbf{R}^{1 \times L}$, $\xi_T^j \in \mathbf{R}^{1 \times m}$, $\mathbf{t}_T^j \in \mathbf{R}^{1 \times m}$ 分别表示目标域的隐含层输出、预测误差及第 j 个训练

样本标签; $\beta \in \mathbf{R}^{L \times m}$ 表示所求输出权重; N_S, N_T 分别表示源域样本个数和目标域少部分有标签样本的个数; C_S, C_T 表示由带标签的源域训练样本及部分带标签的目标域训练样本分别训练所得预测误差的惩罚系数.

由式 (4) 和 (5) 可知, 通过目标域的少量标签样本可以使 β 具有可迁移性. M 个目标域的 DARWNN 架构如图 1 所示:




图 1 M 个目标域 DARWNN 算法结构

Fig.1 M target domain DARWNN algorithm structure

图 1 中实线箭头表示用源域训练数据 D_S 进行学习, 虚线表示用目标域有标签数据 D_T^l 进行模型训练, D_T^u 是目标域无标签数据.

通过拉格朗日算子对式 (4) 进行优化, 得:

$$\beta = (I + C_S H_S^T H_S + C_T H_T^T H_T)^{-1} \times (C_S H_S^T t_S + C_T H_T^T t_T) \quad (6)$$

其中, I 是维度为 L 的单位阵.

1.2 流形正则化

软测量建模的回归任务与分类任务所依赖的“聚类假设”有所不同, 需要保持源领域和目标领域的数据结构信息, 从而使源领域建立的模型能够适用于目标领域数据的预测. 流形正则化^[18]的本质思想是使数据在新的投影空间 (这里指决策空间)

中能够保持其在原特征空间 (这里指 DARWNN 特征空间) 中的局部几何结构^[19-20]. 该目标函数可以表示如下:

$$\min : \frac{1}{2} \sum_{ij} \omega_{ij} \|y_i - y_j\|_2^2 \quad (7)$$

其中, y_i 和 y_j 分别是样本 z_i 和 z_j 的输出预测向量 (在 DARWNN 结构中, y_i 是决策层输出向量, z_i 是隐含层输出向量), ω_{ij} 表示 z_i 和 z_j 的相似度. 通常采用 K 近邻方法计算两个样本间的相似度, 通过高斯核函数计算各点与 z_i 的权值, $\omega_{ij} = \exp(-\|z_i - z_j\|_2^2 / \rho)$, 相应的相似度矩阵 $W = [\omega_{ij}]_{N \times N}$.

最小化式 (7) 中的目标函数相当于最小化下述函数:

$$\min : \text{tr}(Y^T L Y) \quad (8)$$

其中, $\text{tr}(\cdot)$ 表示矩阵的迹, Y 是所有训练样本的输出预测向量构成的矩阵, 矩阵 L 表示拉普拉斯矩阵, 即 $L = D - W$, D 为一个对角阵, 其中元素:

$$D_{ii} = \sum_{j=1}^N W_{ij} \quad (9)$$

2 软测量策略及实现

综合上述分析可知, 为解决建模数据与待测数据不满足独立同分布假设, 并且分布差异较大的问题, 需要引入域适应算法. 同时, 在模型建立过程中要求保持数据几何结构相对稳定. 因此, 本文采用基于流形正则化的域适应随机权神经网络, 其在算法上融合了流形结构保持及领域自适应思想, 以克服 RWNN 算法将数据从原始特征空间随机映射到 RWNN 特征空间时, 数据分布差异过大, 且可能使数据在 RWNN 特征空间中呈现出某种难以预测的非线性分布的问题. 软测量策略如图 2 所示.




图 2 基于流形正则化域适应随机权神经网络的软测量策略

Fig.2 Soft sensor strategy based on DAMRRWNN

以 DARWNN 特征空间作为出发点, 不同工况下的数据具有不同的内在结构, 假设各工况数据分布在该高维特征空间中的一个低维流形上, 这种数据的几何结构需要通过上述流形学习的方法加以挖掘, 只有保持数据的内在结构才能更好地使迁移学习用于回归任务, 所以, 这里将式 (8) 引入到 DARWNN 目标函数式 (4) 中, 则 DAMRRWNN 的目标函数如下所示:

$$\min_{\hat{\beta}, \xi_S^i, \xi_T^i} \left(\frac{1}{2} \|\hat{\beta}\|^2 + C_S \frac{1}{2} \sum_{i=1}^{N_S} \|\xi_S^i\|^2 + C_T \frac{1}{2} \sum_{i=1}^{N_T} \|\xi_T^i\|^2 + C_g \frac{1}{2} \text{tr}(Y^T L Y) \right) \quad (10)$$

式中, 各参数定义与式 (4) 相同, C_g 为流形正则项惩罚系数, 拉普拉斯矩阵 L 是由特征空间中的样本求得, 目标函数中第 4 项的意义是添加流形正则约束项使得在 DARWNN 的特征空间中相似度较大的数据在决策空间中的距离较小, 即在决策空间中保持数据原有的几何性质. 目标函数 (10) 可以表示为:

$$\min : \frac{1}{2} \|\hat{\beta}\|^2 + C_S \frac{1}{2} \sum_{i=1}^{N_S} \|\mathbf{t}_S^i - \mathbf{H}_S^i \hat{\beta}\|^2 + C_T \frac{1}{2} \sum_{i=1}^{N_T} \|\mathbf{t}_T^i - \mathbf{H}_T^i \hat{\beta}\|^2 + C_g \frac{1}{2} \text{tr}(\hat{\beta}^T \mathbf{H}_S^T L \mathbf{H}_S \hat{\beta}) \quad (11)$$

对式 (11) 求导可得:

$$\nabla = \hat{\beta} - C_S \mathbf{H}_S^T (\mathbf{t}_S - \mathbf{H}_S \hat{\beta}) - C_T \mathbf{H}_T^T (\mathbf{t}_T - \mathbf{H}_T \hat{\beta}) + C_g \mathbf{H}_S^T L \mathbf{H}_S \hat{\beta} \quad (12)$$

令 $\nabla = 0$, 有:

$$\hat{\beta} = (\mathbf{I} + C_S \mathbf{H}_S^T \mathbf{H}_S + C_T \mathbf{H}_T^T \mathbf{H}_T + C_g \mathbf{H}_S^T L \mathbf{H}_S)^{-1} \times (C_S \mathbf{H}_S^T \mathbf{t}_S + C_T \mathbf{H}_T^T \mathbf{t}_T) \quad (13)$$

DAMRRWNN 算法流程如算法 1 所示.

算法 1. DAMRRWNN 算法流程

输入. 源域数据 $\{\mathbf{x}_i, \mathbf{y}_i\}_{i=1}^n$, 目标域无标签数据 $\{\mathbf{x}_j\}_{j=1}^r$ 少量有标签数据 $\{\mathbf{x}_l, \mathbf{y}_l\}_{k=1}^m$, RWNN 的隐含层节点数 l , 惩罚系数 C_S, C_T, C_g

输出. 输出权值 $\hat{\beta}$, 预测标签 \mathbf{y}_j

步骤 1. 数据预处理.

步骤 2. 模型参数初始化.

for $i = 1 \rightarrow n$

根据 RWNN 算法训练源域模型, 根据式 (3) 输出权值 β_0 .

for $l = 1 \rightarrow m$

使用目标域标签数据迁移源域模型, 根据式 (6) 计算输出权值 β .

for $j = 1 \rightarrow r$

对目标域无标签数据, 根据式 (13) 计算预测输出 $\hat{\beta}$.

end for

end for

end for

3 算法评估及应用

3.1 算法评估标准介绍

为了量化各种方法的预测性能, 将均方根误差 (Root mean square error, RMSE)、标准均方根误差 (Normalized root mean squared error, NRMSE) 作为衡量模型预测性能的评价标准, 如式 (14) 和式 (15) 所示:

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

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

式中, y_i 和 \hat{y}_i 分别表示第 i 个样本的实际值和估计值, N_t 为测试样本的个数.

3.2 公开数据集

实验采用了玉米样品的近红外光谱数据集验证 DAMRRWNN 算法的有效性 (<http://www.eigenvector.com/data/Corn/>). 光谱数据集包含了 3 台不同的光谱仪 (分别命名为 m5、mp5、mp6) 上测得的 80 个玉米样品的近红外光谱, 其波长范围是 1100~2498 nm. 同时包含 80 个玉米样本的 4 种组成成分: 水分、油、蛋白质和淀粉量的参考值. 图 3 给出了经 PCA 降维后数据的散点图, 表明不同光谱仪测量的数据存在较大的分布差异.




图 3 不同设备的数据分布差异图

Fig. 3 Data distribution diagram for different devices

将设备 m5 的数据随机分成 75% 的训练集和 25% 的测试集, 分别采用随机神经网络 (RWNN)、集成学习方法 (Bagging)、即时学习 (Just in time learning, JITL) 对油脂含量进行满足数据同分布情况下的预测, 结果如表 1 所示。

表 1 m5 油脂含量预测结果

Table 1 Prediction result of oil content in m5

评价标准	RWNN	Bagging	JITL
RMSE	0.0490	0.1615	0.0803
NRMSE	0.0655	0.2171	0.1079

迁移学习实验中假设光谱仪 m5 所产生的数据为源域数据, 令光谱仪 mp5、mp6 产生的数据为目标域数据, 分别对数据集中的油脂含量和淀粉含量进行预测。本文引入 RWNN、Bagging、JITL 以及 DARWNN 与本文所建立的流形正则化域适应随机神经网络 (DAMRRWNN) 预测结果进行对比。DAMRRWNN 实验中通过 SSA (Sample selection algorithm) 方法^[11] 选取 25 个目标域有标签数据, n_h, C_S, C_T, C_g 分别设置为 500, 1×10^{-4} , 1×10^3 , 0.3。结果如图 4 和表 2 所示。

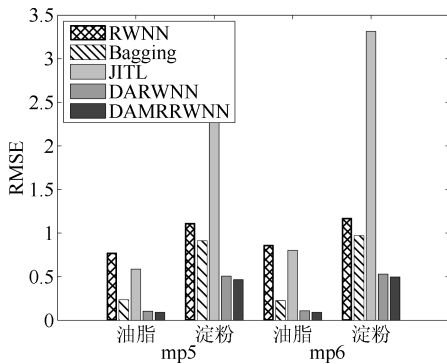


图 4 光谱数据集实验结果对比

Fig. 4 Comparison of experimental results for spectral data sets

表 2 m5 为源域的不同算法实验结果对比

Table 2 Comparison of experimental results of different algorithms for m5 as source domain

方法	mp5 为目标域				mp6 为目标域			
	油脂含量		淀粉含量		油脂含量		淀粉含量	
	RMSE	NRMSE	RMSE	NRMSE	RMSE	NRMSE	RMSE	NRMSE
RWNN	0.7723	1.0380	1.1142	0.3056	0.8612	0.1575	1.1701	0.3209
Bagging	0.2346	0.3153	0.9127	0.2503	0.2253	0.3028	0.9707	0.2662
JITL	0.5866	0.7844	2.7080	0.7427	0.8021	1.0781	3.3141	0.9090
DARWNN	0.1047	0.1407	0.5066	0.1389	0.1090	0.1465	0.5294	0.1452
DAMRRWNN	0.0908	0.1220	0.4660	0.1278	0.0911	0.1224	0.4958	0.1360

根据同分布情况下近红外光谱数据集上的实验结果 (表 1) 可知, 数据在满足独立同分布的前提下, 传统的机器学习算法可以满足测量精度要求, 获得较为理想的预测精度。结合表 1 和表 2 的实验结果可以看出, 当数据独立同分布前提不满足时, 建立在传统机器学习算法上的软测量方法存在较大的误差。

从表 2 和图 4 中可以看出 DARWNN 比传统随机神经网络及其他算法的预测精度显著提高, 说明迁移学习策略在数据分布不同时有效。同时可以看出引入流形正则框架后形成的 DAMRRWNN 在玉米样品近红外光谱数据集上拥有更理想的预测结果, 可以有效提高数据分布不同情况下模型的预测精度, 降低数据分布不同对软测量结果的影响。

3.3 湿式球磨机实验

3.3.1 数据预处理

实际工业过程中介质充填率 (Medium filling rate, MFR) 在 0.3~0.5 之间变化, 为了模拟实际工业过程中的工况变化, 对实验室小型湿式球磨机进行负荷参数软测量实验研究, 实验采取了分别固定介质充填率的 5 组实验方案数据, 即每组实验都固定相应的磨机滚筒内钢球和水的质量, 通过改变物料的质量以获得不同的负荷参数。对不同工况分别同步采集球磨机筒体振动信号, 各工况实验次数如表 3 所示。

在此基础上将每次实验采集的振动信号平均分为 28 个样本 (每个样本覆盖球磨机旋转 1 周以上的数据), 对每个样本以 $w = 1024$ 的窗口进行不重叠滑动, 每个窗口进行快速傅立叶变化 (Fast Fourier transformation, FFT), 最后将每个窗口的变化结果取均值, 完成特征值提取过程^[21]。具体处理流程如图 5 所示。

3.3.2 实验结果与分析

为了验证基于流形正则化的域适应随机权神

神经网络 (DAMRRWNN) 的有效性, 同样将随机权神经网络 (RWNN)、集成学习 (Bagging)、即时学习 (JITL) 以及域适应随机权神经网络 (DARWNN) 作为对比方法, 分别对料球比 MBVR、矿浆浓度 PD、充填率 CVR 三种磨机负荷参数进行预测实验. 在磨机负荷参数的软测量建模中, 均以工况 1 作为源域, 以其他 4 种工况分别作为目标域, 测试结果分别用 1-2、1-3、1-4、1-5 表示.

表 3 不同工况振动信号采集次数

Table 3 Acquisition times of vibration signals under different working conditions

MFR	0.3	0.35	0.4	0.45	0.5
次数	139	103	88	95	102




图 5 数据预处理流程

Fig. 5 Data preprocessing process

表 4 为不同预测模型软测量结果的均方根误差 RMSE 值, 表中 1-1 表示训练集测试集数据均来源

表 4 磨机负荷参数预测结果对比 (RMSE)

Table 4 Comparison of prediction results of mill load parameters (RMSE)

建模算法	负荷参数	1-1	1-2	1-3	1-4	1-5
RWNN	MBVR	0.0279	0.6219	1.0044	1.2182	1.1312
	PD	0.0040	0.1546	0.0656	0.1763	0.2541
	CVR	0.0021	0.0817	0.3063	0.2516	0.3607
Bagging	MBVR	0.0923	0.1618	0.3379	0.3919	0.2346
	PD	0.0157	0.0470	0.0897	0.0880	0.1263
	CVR	0.0086	0.0808	0.1270	0.1395	0.2012
JITL	MBVR	0.0829	0.3688	0.4490	0.7043	0.9147
	PD	0.0138	0.0695	0.1149	0.3406	0.3467
	CVR	0.0094	0.0908	0.1428	0.1777	0.2471
DARWNN	MBVR	—	0.1349	0.0854	0.0843	0.0709
	PD	—	0.0270	0.0170	0.0153	0.0178
	CVR	—	0.0159	0.0114	0.0084	0.0081
DAMRRWNN	MBVR	—	0.1058	0.0693	0.0457	0.0365
	PD	—	0.0219	0.0149	0.0120	0.0162
	CVR	—	0.0141	0.0108	0.0074	0.0072

于工况 1, 可以看出 RWNN、Bagging 以及 JITL 在数据满足独立同分布时, 均能获得理想的预测精度, 相较于其他预测模型, DAMRRWNN 在工况发生改变的情况下对三种磨机负荷参数的预测误差均能达到最低. 图 6 表示目标域为工况 2 情况下分别采用 RWNN 及 DAMRRWNN 建模时各磨机负荷参数的预测结果. 根据预测结果可知, 引入迁移学习可有效解决工况变化带来的数据分布失配情况下的软测量建模问题. 图 7 表示三种对比算法, 集成学习、即时学习以及域适应随机权神经网络分别在目标域为工况 2 时对浓度的预测结果.

结合图 6 中浓度预测结果可知, DAMRRWNN 算法在三种负荷参数软测量实验中均可获得最佳预测结果, DARWNN 预测结果与 DAMRRWNN 的预测结果对比可以看出, 引入流形约束后, 预测结果更加稳定且误差降低, 图 8 表示以工况 1 为源域进行域适应学习的三种磨机负荷参数的预测结果.

图 9 表示目标域为工况 2 条件下各建模方法对三种磨机负荷参数的预测误差对比, 图 10 表示对磨机负荷参数进行预测时, 各建模方法预测误差对比 (图例与图 9 相同). 实验证明, 湿式球磨机工况发生变化时, 历史数据建立的软测量模型性能急速下降. 为解决工况改变引起的软测量模型失准, 引入域适应随机权神经网络对源域数据构建的模型进行知识结构迁移, 从而提高模型适应能力. 由图 9、图 10 对比结果可以看出, 进一步引入流形正则化后, DAMRRWNN 模型的泛化性能及预测精度较 DARWNN 模型均有所提高, 从而可以验证该方法的有效性.

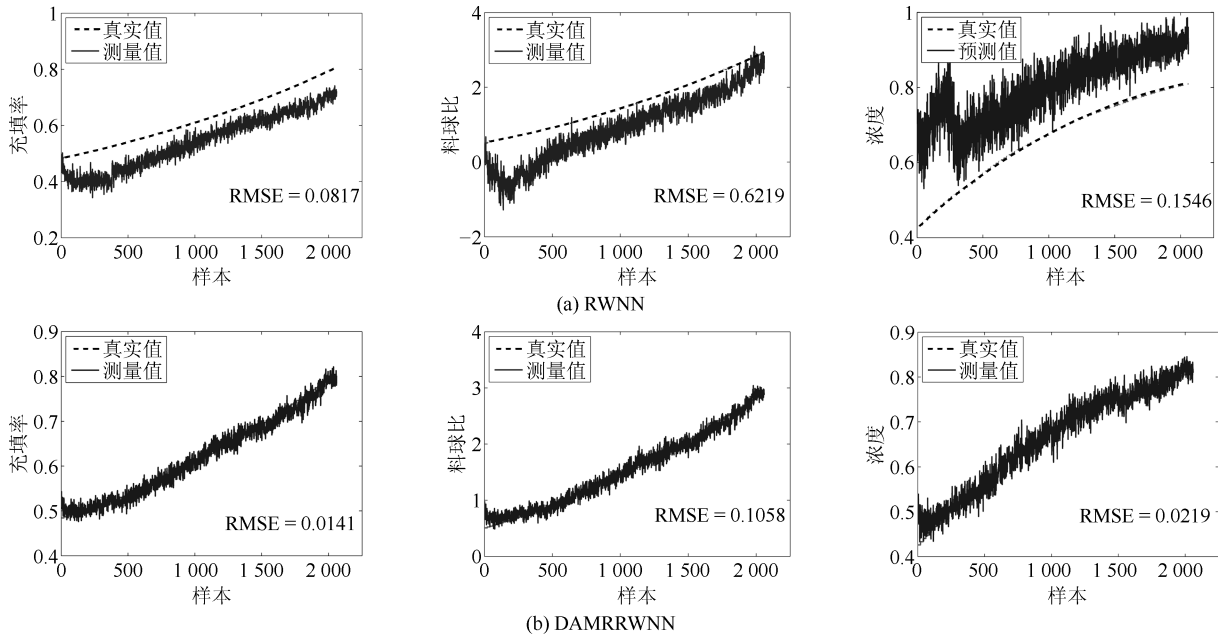


图6 目标域为工况2时RWNN和DAMRRWNN的负荷参数预测结果

Fig. 6 Prediction results of RWNN and DAMRRWNN on load parameter, when the condition 2 is the target domain


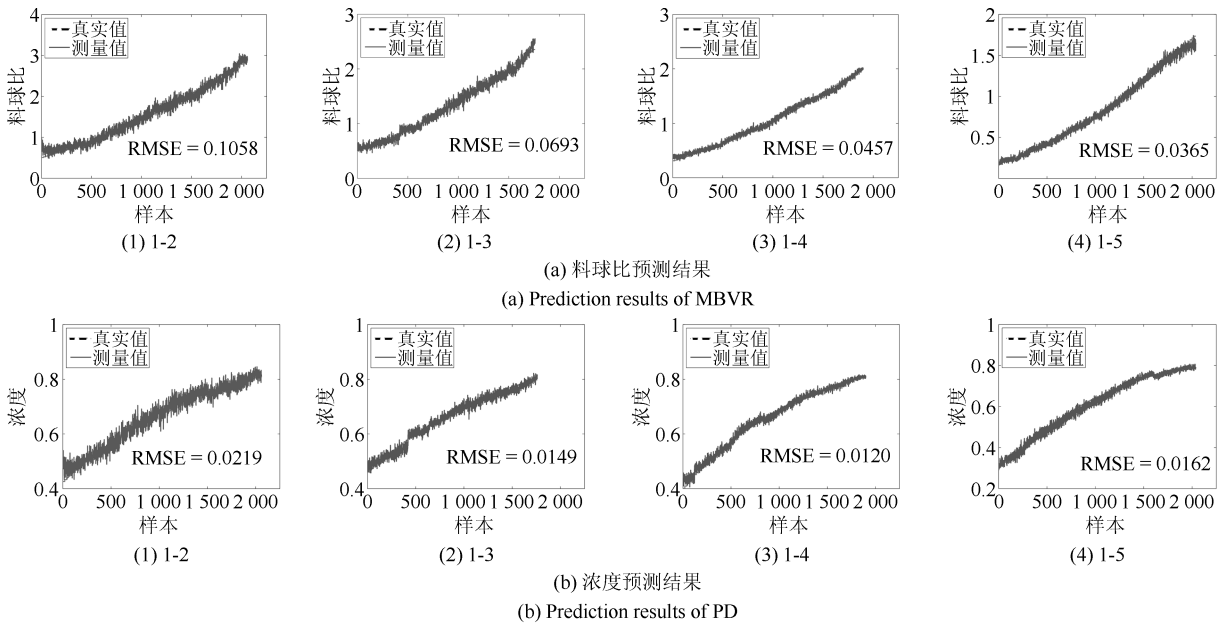
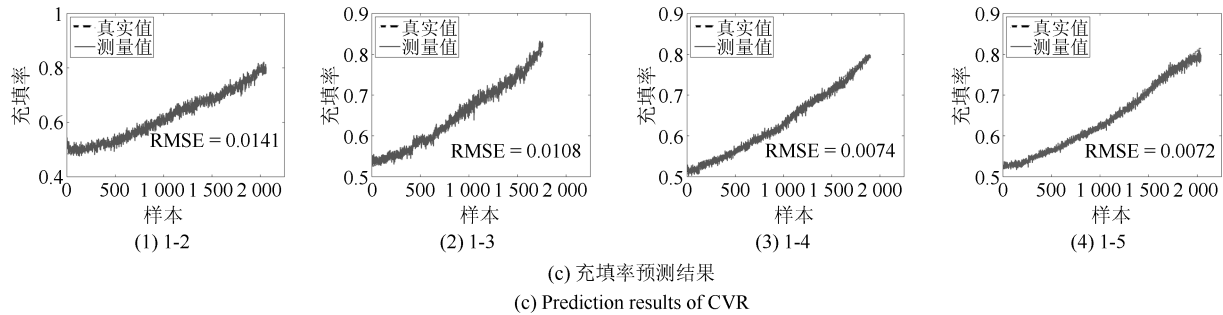


图7 目标域为工况2时三种对比算法对负荷参数浓度的预测结果

Fig. 7 Prediction results of three algorithms on load parameter PD, when the condition 2 is the target domain



(b) 浓度预测结果
(b) Prediction results of PD



(c) 充填率预测结果

(c) Prediction results of CVR

图 8 DAMRRWNN 负荷参数预测结果

Fig. 8 DAMRRWNN load parameter prediction results

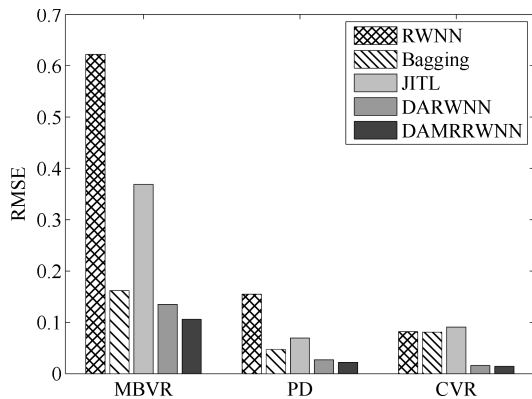


图 9 目标域为工况 2 时建模方法对比

Fig. 9 The target domain is the working condition 2 and the prediction results are compared




图 10 三种负荷参数预测误差对比

Fig. 10 Comparison of prediction errors of three load parameters

4 结论

为解决湿式球磨机工作过程中, 由于工况突然变化造成的实时数据与历史数据不再满足传统建模方法要求的概率同分布问题, 本文引入迁移学习策略, 建立了一种基于流形正则化域适应随机神经网络 (DAMRRWNN) 的湿式球磨机负荷参数软测量模型. 对预处理后的特征数据, 首先通过域适应随

机神经网络进行迁移学习, 然后添加流形正则约束项保持数据结构, 实现变工况情况下湿式球磨机负荷参数回归预测. 实验结果表明, 磨机工况发生改变时, 引入迁移学习策略, 能够充分利用原有数据, 降低数据收集成本, 有效提高模型的泛化能力, 并且该方法引入的流形正则化约束能够一定程度上降低结构风险, 提高预测结果的准确性和可信性.

References

- Tang Jian, Zhao Li-Jie, Chai Tian-You, Yue Heng. On-line soft-sensing modelling of mill load based on vibration spectrum. *Information and Control*, 2012, **41**(1): 123–128 (汤健, 赵立杰, 柴天佑, 岳恒. 基于振动频谱的磨机负荷在线软测量建模. *信息与控制*, 2012, **41**(1): 123–128)
- Tang Jian, Tian Fu-Qing, Jia Mei-Ying, Li Dong. *Soft Sensing of Rotating Machinery Equipment Load Based on Spectrum Data Drive*. Beijing: National Defense Industry Press, 2015. (汤健, 田福庆, 贾美英, 李东. 基于频谱数据驱动的旋转机械设备负荷软测量. 北京: 国防工业出版社, 2015.)
- Tang Jian, Zhao Li-Jie, Yue Heng, Chai Tian-You. Analysis of vibration signal of wet ball mill shell and soft sensing for mill load. *Journal of Northeastern University (Natural Science)*, 2010, **31**(11): 1521–1524 (汤健, 赵立杰, 岳恒, 柴天佑. 湿式球磨机筒体振动信号分析及负荷软测量. *东北大学学报 (自然科学版)*, 2010, **31**(11): 1521–1524)
- Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications. *Neurocomputing*, 2006, **70**(1–3): 489–501
- Tang J, Deng C, Huang G B. Extreme learning machine for multilayer perceptron. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, **27**(4): 809–821
- Maass W. Liquid state machines: motivation, theory, and applications. *Computability in Context: Computation and Logic in the Real World*. Hackensack, NJ: Imperial College Press, 2009. 275–296
- Zhang M, Liu X G, Zhang Z Y. A soft sensor for industrial melt index prediction based on evolutionary extreme learning machine. *Chinese Journal of Chemical Engineering*, 2016, **24**(8): 1013–1019
- Tang Jian, Chai Tian-You, Yu Wen, Zhao Li-Jie. On-line KPLS algorithm with application to ensemble modeling parameters of mill load. *Acta Automatica Sinica*, 2013, **39**(5):

- 471–486
(汤健, 柴天佑, 余文, 赵立杰. 在线 KPLS 建模方法及在磨机负荷参数集成建模中的应用. 自动化学报, 2013, **39**(5): 471–486)
- 9 Shao W M, Tian X M, Wang P. Supervised local and non-local structure preserving projections with application to just-in-time learning for adaptive soft sensor. *Chinese Journal of Chemical Engineering*, 2015, **23**(12): 1925–1934
- 10 Pan S J, Yang Q. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 2010, **22**(10): 1345–1359
- 11 Zhang L, Zhang D. Domain adaptation extreme learning machines for drift compensation in E-nose systems. *IEEE Transactions on Instrumentation and Measurement*, 2015, **64**(7): 1790–1801
- 12 Tenenbaum J B, de Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction. *Science*, 2000, **290**(5000): 2319–2323
- 13 Liu B, Xia S X, Meng F R, Zhou Y. Manifold regularized extreme learning machine. *Neural Computing and Applications*, 2016, **27**(2): 255–269
- 14 Schmidt W F, Kraaijveld M A, Duin R P W. Feedforward neural networks with random weights. In: Proceedings of the 11th IAPR International Conference on Pattern Recognition Vol. II Conference B: Pattern Recognition Methodology & Systems. The Hague, Netherlands: IEEE, 1992. 1–4
- 15 Liu X, Lin S B, Fang J, Xu, Z B. Is extreme learning machine feasible? A theoretical assessment (Part I). *IEEE Transactions on Neural Networks and Learning Systems*, 2014, **26**(1): 7–20
- 16 Han Min, Li De-Cai. A norm 1 regularization term ELM algorithm based on surrogate function and Bayesian framework. *Acta Automatica Sinica*, 2011, **37**(11): 1344–1350
(韩敏, 李德才. 基于替代函数及贝叶斯框架的 1 范数 ELM 算法. 自动化学报, 2011, **37**(11): 1344–1350)
- 17 Deng W Y, Zheng Q H, Chen L. Regularized extreme learning machine. In: Proceedings of the 2009 IEEE Symposium on Computational Intelligence and Data Mining, 2009. CIDM'09. Nashville, TN, USA: IEEE, 2009. 389–395
- 18 Tomar V S, Rose R C. Manifold regularized deep neural networks. In: Proceedings of the 15th Annual Conference of the International Speech Communication Association. Singapore: ISCA, 2014. 348–352
- 19 Guan N Y, Tao D C, Luo Z G, Yuan B. Manifold regularized discriminative nonnegative matrix factorization with fast gradient descent. *IEEE Transactions on Image Processing*, 2011, **20**(7): 2030–2048
- 20 Xu Jia-Ming, Zhang Wei-Qiang, Yang Deng-Zhou, Liu Jia, Xia Shan-Hong. Manifold regularized extreme learning machine for language recognition. *Acta Automatica Sinica*, 2015, **41**(9): 1680–1685
(徐嘉明, 张卫强, 杨登舟, 刘加, 夏善红. 基于流形正则化极限学习机的语种识别系统. 自动化学报, 2015, **41**(9): 1680–1685)

- 21 Amar M, Gondal I, Wilson C. Vibration spectrum imaging: a novel bearing fault classification approach. *IEEE Transactions on Industrial Electronics*, 2015, **62**(1): 494–502



贺敏 太原理工大学硕士研究生. 主要研究方向为工业大数据应用, 机器学习, 数据驱动软测量建模与迁移学习.
E-mail: hemin0215@link.tyut.edu.cn
(**HE Min** Master student at Taiyuan University of Technology. His research interest covers industrial large data applications, machine learning, data-driven soft sensor modeling, and transfer learning.)



汤健 北京工业大学信息部教授, 博士, 主要研究方向为数据驱动软测量, 工业自动化控制.
E-mail: tjian001@126.com
(**TANG Jian** Ph.D., professor in the Information Department of Beijing University of Technology. His research interest covers data-driven soft sensor modeling and industrial automatic control.)



郭旭琦 太原理工大学硕士研究生, 主要研究方向为智能信息处理, 数据驱动软测量建模, 迁移学习.
E-mail: guoxuqi0330@link.tyut.edu.cn
(**GUO Xu-Qi** Master student at Taiyuan University of Technology. Her research interest covers intelligent information processing, data-driven soft sensor modeling, and transfer learning.)



阎高伟 太原理工大学信息工程学院教授, 博士. 主要研究方向为复杂工业控制系统, 智能控制理论及其应用, 智能信息处理等. 本文通信作者.
E-mail: yangaowei@tyut.edu.cn
(**YAN Gao-Wei** Ph.D., professor at the College of Information Engineering of Taiyuan University of Technology. His research interest covers complex industrial control system, intelligent control theory and application, and intelligent information processing. Corresponding author of this paper.)