

DOI: 10.13382/j.jemi.2017.08.025

# 基于改进 AdaBoost 的油井动液面自适应集成建模\*

王通<sup>1</sup> 段泽文<sup>1</sup> 李琨<sup>2</sup>

(1. 沈阳工业大学电气工程学院 沈阳 110870; 2. 渤海大学工学院 锦州 121013)

**摘要:**针对单一模型软测量算法在动液面预测应用过程中存在泛化能力弱、自适应性差等问题,提出利用 AdaBoost 集成学习的思想,突出预测误差在建模样本权重及弱学习机权重中的作用,使之更加适合回归模型预测。针对油井工况动态多变导致软测量模型随生产进行逐渐失效的问题,提出利用油田生产过程中定期巡检的少量动液面数据评估原有集成模型,利用相似度原理在保留原有模型信息的基础上增加新信息,并在此基础上根据新样本权重更新弱学习机模型,集成为强学习机模型以动态适应新的油田生产工况。通过对油田生产现场实际数据验证结果表明,该方法对油田生产波动的自适应能力强,能够提高动液面软测量模型的泛化能力及预测精度。

**关键词:** 集成学习算法; 自适应建模; 误差率; 动液面; 泛化能力

中图分类号: TQ063 文献标识码: A 国家标准学科分类代码: 120.30

## Adaptive ensemble modeling for dynamic liquid level of oil well based on improved AdaBoost method

Wang Tong<sup>1</sup> Duan Zewen<sup>1</sup> Li Kun<sup>2</sup>

(1. School of Electrical Engineering, Shenyang University of Technology, Shenyang 110870, China;  
2. College of Engineering, Bohai University, Jinzhou 121013, China)

**Abstract:** When the single soft sensor model is used for the dynamic liquid level prediction, there are many shortcomings such as poor generalization ability, weak adaptive ability, etc. In order to solve these problems, a soft sensor modeling method based on AdaBoost ensemble learning algorithm is proposed in this paper. The proposed method focuses on effects of the prediction error to the weight of the modeling samples and weak learning machine, therefore which is more suitable for the regression model prediction. In practical production, dynamic and changing working conditions during operations may lead to failure of the soft sensor model. In order to solve this problem, a small amount of patrol-measuring data of the dynamic liquid level is used to evaluate the original model, and then the similarity principle is used to add new data on the basis of the original model. And on this basis the weight of the new data is used to update the weak learning machine to become the strong learning machine model to dynamically adapt to the new production conditions. The simulation results using the real operation data of the oil well show that the proposed method has strong adaptive ability for fluctuation in production and can improve the generalization ability and the prediction accuracy of the soft sensor model.

**Keywords:** ensemble learning algorithm; dynamic modeling; error rate; dynamic liquid level; generalization ability

## 0 引言

油田生产过程中地下环境复杂,传统传感器无法得

到有效应用,以至于动液面数据无法实时准确测量,导致油田生产过程中措施调整滞后,油井长期处在非最佳工作状态,工程人员利用井下静态参数、示功图数据、井口压力等可测参数结合机理过程计算动液面,但过程中无

法确定的参数太多,得到准确的动液面数值难度极大,随着基于数据驱动的软测量技术的发展,将其应用到动液面预测过程中的算法逐渐增多<sup>[1-3]</sup>,上述方法均在现场应用过程中起到了一定的成果,但油井工况复杂,不同油井之间地质环境差异较大,常规的动液面软测量所采用的单一模型算法适应性差,由历史数据建立的全局模型训练时间长,泛化能力弱,易出现过拟合等现象,严重制约了其技术在生产过程中的实际运用,同时油田生产工况动态多变,模型需要在其预测过程中根据生产情况进行自适应更新。针对软测量模型的泛化能力及自适应更新问题,刘佳等人<sup>[4]</sup>以迁移学习算法对工况进行划分,采用多模型方式预测裂解炉收率。周丽春等人<sup>[5]</sup>结合即时学习方式,提出局部递推岭参数极限学习机在线建模方法,解决单一全局模型受限问题。赵超等人<sup>[6]</sup>根据样本拟合误差,结合改进的指数分布赋权规则,自适应地为每个建模样本分配不同的权值,降低随机误差对模型性能的影响。集成学习算法近年来是机器学习的研究热点,其通过多个基学习器构成一个精度较高的强学习器,该方法优于通过单一模型的输出结果。孙茂伟等人<sup>[7]</sup>基于改进 Bagging 算法建立高斯过程集成软测量模型,根据基学习器输出的方差自适应选择基学习器集成输出。夏陆岳等人<sup>[8]</sup>提出一种用于化工过程软测量的核主元分析-bagging 集成神经网络建模方法。AdaBoost 算法是集成学习算法中最具有代表性的方法之一,被广泛成功应用于实际工程中。文献[9]提出采用改进的 AdaBoost 算法来估计天气对配电系统的影响。文献[10]将肤色分割与 AdaBoost 算法相结合应用于人脸检测中。文献[11]提出利用小波包分析进行特征提取并基于 BP\_AdaBoost 算法实现了机载燃油泵故障诊断。目前 AdaBoost 算法的应用研究主要集中在上述分类等相关问题<sup>[12-13]</sup>上,对于回归预测研究较少。

本文提出利用 AdaBoost 集成学习模型的框架思想,在原有训练弱学习机的基础上,对样本权重及弱学习机权重计算进行改进,将样本预测误差加入样本权重的更新中,替代传统的两值区分,弱学习机权重中增加模型整体预测误差指标,使之更加适合回归模型预测的应用,针对油井工况动态多变导致软测量模型随生产进行预测误差逐渐增多等问题,提出利用油田生产过程中定期巡检的少量动液面数据评估原有集成模型,利用相似度原理在保留原有模型信息的基础上增加新信息,基于样本权重训练新的弱学习机,集成模型构建强学习机以动态适应新的油田生产工况。

## 1 AdaBoost 组合集成算法

AdaBoost 是一种迭代算法,最初提出的是应用于分

类过程中,将训练集样本  $(\mathbf{x}_i, y_i), i = 1, 2, \dots, n, n$  为样本个数,训练成不同的弱分类器  $f_i: \mathbf{x}_i \rightarrow y_i$ ,然后把把这些弱分类器集成起来,构成一个最终的强分类器  $F(\mathbf{x})$ 。在每次迭代弱分类器后,根据预测误差率  $\varepsilon_t = \sum_{f_i(\mathbf{x}_i) \neq y_i} D_t(i)$  ( $D_t(i)$  为第  $t$  次迭代后第  $i$  个样本权重)采用式(1)的方式更新样本的权重。

$$D_{t+1}(i) = \frac{D_t(i)}{Z} \times \begin{cases} e^{-\alpha_t} f_i(\mathbf{x}_i) = y_i \\ e^{\alpha_t} f_i(\mathbf{x}_i) \neq y_i \end{cases} \quad (1)$$

式中:  $\alpha_t = \frac{1}{2} \ln\left(\frac{1 - \varepsilon_t}{\varepsilon_t}\right)$  为分类器权重,  $Z$  为归一化参数。在下次训练弱分类器的时候,分类错误的样本能够得到更多的训练机会,当预测误差率大于 0.5 时舍弃当前弱分类器,重新训练。最终得到一个强分类器为:

$$F(\mathbf{x}) = \operatorname{argmax}\left(\sum_{i=1}^T \alpha_i f_i\right) \quad (2)$$

对于 AdaBoost 算法在回归预测研究中的应用,文献[14]通过建立 BP-AdaBoost 模型对光纤陀螺零偏记忆性预测补偿,文献[15]通过几何关系将电力负荷预测回归问题转化为两类分类问题,应用置信度 AdaBoost 算法得到最优集成分类面,从而有效提高电力负荷预测精度。文献[16]结合 AdaBoost 集成学习算法的思想,将增量学习思想引入到集成学习中,提出适用于软测量建模的增量学习集成算法。上述方法在各自的领域均取得一定程度的应用,能够在一定程度上解决单一模型泛化能力不足,易过拟合等问题,但算法现有的应用基本实现过程还是源于最初的分类实现,在权重变更等环节上以预测的误差率为主,对于样本偏差大小没有考虑,训练过程中,在不合格样本中,样本权重无法体现出差异性,建模提取训练集效果不理想。而弱学习机权重以样本预测超限个数为主,对于模型整体预测效果不做评估,导致权重分配不理想失败率较高。

## 2 改进的 AdaBoost 集成算法

鉴于 AdaBoost 集成算法在样本权重更新及弱学习机权重更新中以统计样本预测误差率为基础,在软测量回归建模预测的过程中效果并不理想。本文提出利用样本预测的相对误差,判断是否超出误差指标阈值,但对于超出误差指标的样本不统一对待,通过预测误差的偏离程度对样本进行权值更新,更新方式如下:

$$w_{t+1}(i) = w_t(i) \times e^{ARE_t(i)} \quad (3)$$

式中:  $w_t(i)$  为第  $t$  个弱学习机的第  $i$  个建模样本权值,  $ARE_t(i)$  为第  $t$  个弱学习机模型的第  $i$  个建模样本的预测误差。这样使误差大的样本必然能够得到锻炼的机会在弱学习机的权重上,设计新的弱学习机权重,即预测水平指标  $\beta_t$ ,将模型整体误差加权到传统的预测水平指标

上,这样能够加强表明样本集对于弱学习的适应程度,改进方式如下:

$$\beta_i = e^{\lambda/\alpha} \times \log \frac{1 - \varepsilon_i}{\varepsilon_i} \quad (4)$$

式中:  $\alpha = \sqrt{(H_i(x_i) - y_i)^2/m}$  为弱学习机模型训练样本的均方根误差,  $\lambda$  为模型调整因子,  $\varepsilon_i$  为预测误差率指标。算法步骤如下。

初始样本集选取为每组样本  $(x_i, y_i), i = 1, 2, \dots, n$ ,  $x_i$  为辅助变量向量,  $y_i$  为主导变量。分配初始样本权值  $w_1(i) = 1/m$ , 其中  $m$  为数据集样本个数。为增加模型泛化能力,将初始化样本集分为训练子集和测试子集,分别确定其数量。选取建模算法确定算法相关参数,弱学习机个数  $T$ , 误差指标阈值  $e_0$ , 模型预测误差指标阈值  $\varepsilon_0$ 。

1) 计算样本权重:

$$D_i(i) = \frac{w_i(i)}{\sum_{i=1}^m w_i(i)} \quad (5)$$

根据  $D_i(i)$  对样本集进行排序,选择误差大的样本作为训练子集  $TR_i$  和误差小的作为测试子集  $TE_i$  ( $TR_i + TE_i = m$ )。

2) 利用训练集训练模型,得软测量模型  $H_i: x \rightarrow y$ 。

3) 计算模型  $H_i$  样本在  $TR_i$  和  $TE_i$  上的预测误差:

$$ARE_i(i) = \left| \frac{H_i(x_i) - y_i}{y_i} \right| \quad (6)$$

4) 计算预测误差率指标  $\varepsilon_i$ :

$$\varepsilon_i = \sum_{ARE_i < \varepsilon_i > e_0} D_i(i) \quad (7)$$

对于每个样本通过该模型进行测试,将误差超标的样本的权重进行累计。若  $\varepsilon_i > \varepsilon_0$ , 舍弃当前训练模型  $H_i$ , 返回步骤2)重新训练。否则继续执行。

5) 计算预测水平指标  $\beta_i$ ; 更新样本权值  $w_{i+1}(i) = w_i(i) \times e^{ARE_i(i)}$ ; 判断子模型数量是否满足要求,如不满足返回步骤1), 否则执行步骤6)。

6) 计算集成回归模型:

$$F(x) = \frac{\sum_i \beta_i \times H_i}{\sum_i \beta_i} \quad (8)$$

### 3 油井动液面自适应集成建模方法

在一段时期内,动液面及相关参数统计特性未发生改变的情况下,能够通过训练模型构成一个具有较高精度的集成预测模型,但油田生产过程中,随着生产的动态运行其原有模型预测效果会逐渐变差,为提高模型的动态性能,必须对其进行更新,而在生产过程中油井动液面会定期进行巡检,但由于油井数量众多,现场工作人员不可能对每口油井每日进行测量,通常情况下这个周期为一个月甚至更长,在没有巡检的时期,动液面数据以最近

期巡检数据为参考,但其不能代表当前动液面数值,无法准确描述当前油井状态。文献[17]将 Adaboost 算法与增量学习方法相结合,动态更新模型及权重,但计算量较大,且由于生产参数统计特性的改变,导致仅改变前期模型的权重的方式对当前模型的输出的贡献不大,甚至会在一定程度上降低预测输出精度。本文提出在多个弱学习机集成强学习机的基础上,根据巡检数据样本判断集成模型中各子模型的适应程度,保留优秀的,淘汰效果差的,对不适合当前工况的模型重新根据样本权重进行训练,结合油田定期巡检数据,根据样本相似度的原理替换在历史数据中选择相似数据,部分替换效果不好模型训练集,自适应油田生产工况,提高预测精度。自适应集成建模算法流程如图1所示。

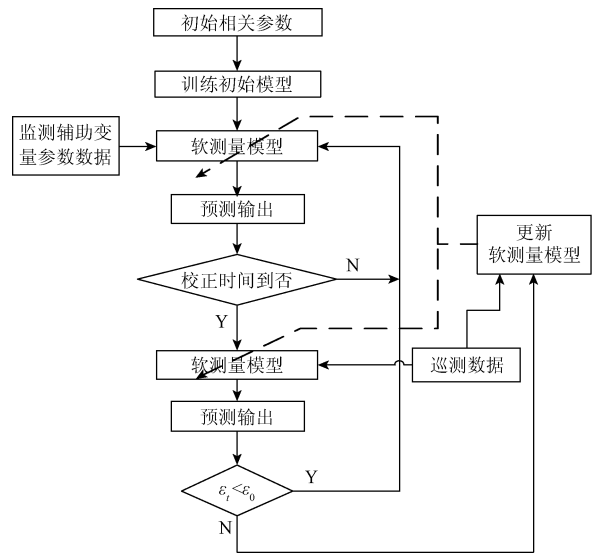


图1 自适应集成建模方法流程

Fig. 1 Flowchart of the adaptive ensemble modeling method

由图1可知,系统先根据改进 AdaBoost 集成算法训练初始集成模型,其中弱学习机建模方法采用最小二乘支持向量机 (least squares support vector machine, LSSVM) 算法, LSSVM 算法相关参数采用黑洞算法 (black hole algorithm, BH) 进行全局搜索<sup>[18]</sup>,该算法自身不需设置任何参数,降低了优化算法本身对软测量模型的影响,且寻优精度高,收敛速度快,又不易陷入局部极值。监测系统采集的辅助变量通过动液面软测量模型输出动液面数据。油田生产过程中会定期巡检动液面,每次测量 2~3 组数据,可利用该巡检数据  $(x'_j, y'_j)$ , 对软测量模型进行评估。通过软测量集成模型预测输出,计算预测误差率指标,判断是否适合当前工况,如适合则继续使用模型,否则舍弃该模型,重新训练弱学习机,更新软测量集成模型。

更新软测量集成模型算法如图2所示,在历史数据

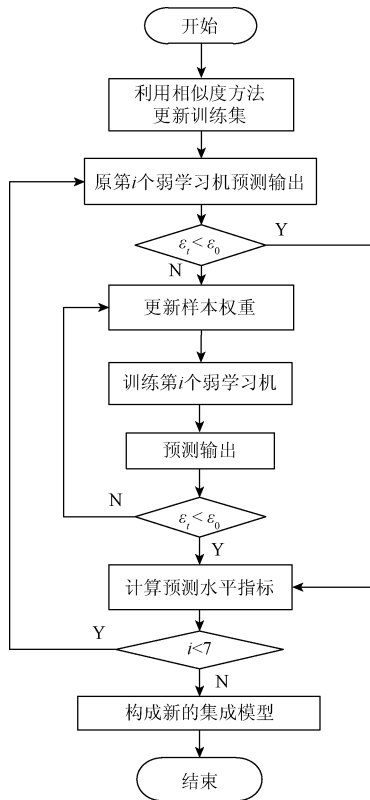


图 2 更新模型算法流程

Fig. 2 Flowchart of update model algorithm

中寻找相似数据构成更新样本子集,相似数据采用考虑样本间距离和角度信息<sup>[19]</sup>来描述,即监测数据  $x'_j$  与历史样本集  $x_i$  相似度可采用式(9)计算。

$$s_{ij} = \rho \|x_i - x'_j\| + (1 - \rho) \cos(\theta_{ij}) \quad (9)$$

分别对各个弱学习机模型进行测试,如测试结果符合要求,计算该弱学习机权重,即预测水平指标  $\beta_i$ 。如预测误差率指标  $\varepsilon_i$  超限,则根据此次训练过程更新样本权重,重新训练弱学习机模型,直到符合要求。所有弱学习机均满足指标后,根据各自权重集成输出强学习机动液面软测量模型。

### 4 仿真实验

本仿真数据来源于辽河油田某油井生产数据,采用本文提出的基于改进 AdaBoost 的油井动液面软测量自适应集成建模方法对动液面数据进行预测,根据井下工况机理分析及专家论证决定采用油井套压、流量、泵效作为建模辅助变量<sup>[20]</sup>。选取现场历史数据 200 组作为第一阶段的样本数据训练初始集成软测量模型,训练子集  $TR_i$  为 150 组和测试子集  $TE_i$  为 50 组,弱学习机个数为 7,误差指标阈值  $e_0 = 0.03$ ,模型预测误差指标阈值  $\varepsilon_0 = 0.5$ 。

首先,验证本文提出的权重改进方法的有效性,通过选取前后相邻两次弱学习机样本测试效果可以看出传统以式(1)为基础的样本选取方法对于误差超出阈值的样本均加大相同训练机会,但对样本不做区分,会导致预测误差较大的样本训练机会不如误差较小的样本,如图 3 所示。而已改进的权值更新方法不会出现该情况,如图 4 所示。可以看出改进后的权重对训练样本的选取更加合理。

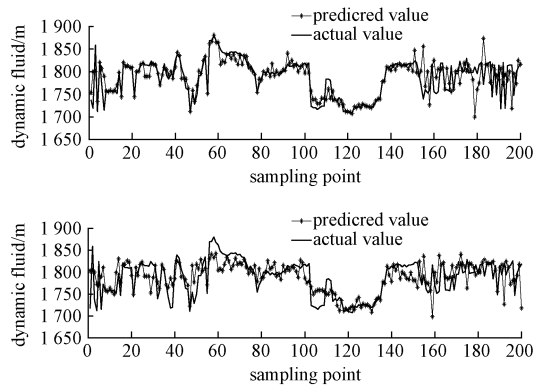


图 3 弱学习机预测输出

Fig. 3 Prediction result of weak learning machine




图 4 弱学习机预测输出

Fig. 4 Prediction result of weak learning machine

其次,验证本方法的预测有效性,将其建模预测结果与 BH-LSSVM 单模型算法和传统基于 AdaBoost 集成算法进行对比。选取与建模样本在同一工况下,工作时期相同样本 100 组,进行集成模型整体预测,相同工作时期样本预测结果如图 5 所示。

为检验组合集成模型的泛化能力,选取不同工作时期样本 100 进行集成模型整体预测,其结果如图 6 所示。

表 1 计算了两个实验的 3 种算法的均方误差 (root mean squared error, RMSE) 和平均绝对误差 (mean absolute error, MAE)。

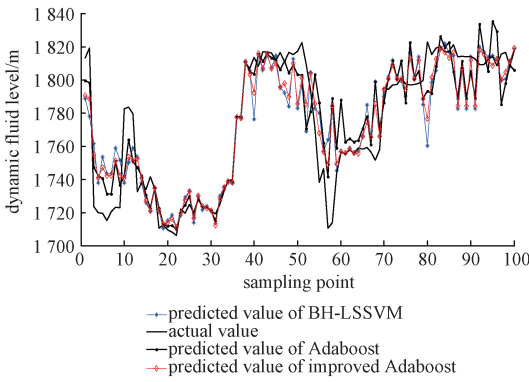


图5 动液面软测量模型预测输出

Fig. 5 Prediction result of dynamic fluid levels modeling

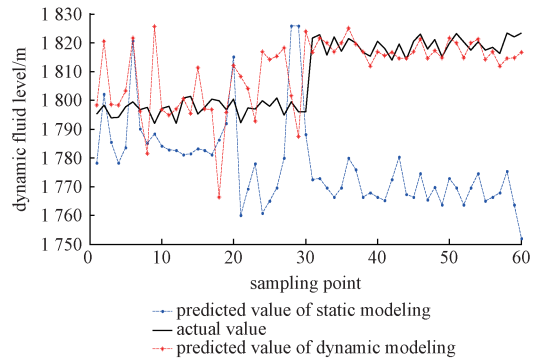


图7 动液面软测量模型预测输出

Fig. 7 Prediction output of dynamic fluid levels model




图6 动液面软测量模型预测输出

Fig. 6 Prediction output of dynamic fluid levels model

表1 不同算法预测的误差

Table 1 Predicted error of different algorithm

实验	算法	MAE	RMSE
相同时 期样本	BH - LSSVM	14.163 6	20.699 8
	传统 AdaBoost	12.833 2	18.034
	改进 AdaBoost	11.068 9	17.052 1
不同时 期样本	BH - LSSVM	31.664 4	46.596 7
	传统 AdaBoost	30.190 3	42.487
	改进 AdaBoost	23.656	31.773 2

通过图6和表1可以看出改进后的Adaboost集成算法预测值误差明显减小,精度得到提高,且具有很好的泛化能力。

随着生产的进行,油井相关参数会跟随井况或生产工艺的变化而改变,导致原有软测量模型输出会逐渐恶化,采用本文提出的利用定期巡检数据动态更新样本的方法进行测试,选取同一井组另一工况下生产数据100组进行动态测试,测试过程如算法第二环节描述过程,更新子集规模为30组。为验证本方法自适应更新性能,将其更新后预测输出结果与传统基于AdaBoost集成算法静态模型进行对比预测结果如图7所示。

表2计算了两种状态模型预测输出的RMSE和MAE。

表2 动态与静态模型预测误差

Table 2 Prediction error of dynamic and static model

实验	算法	MAE	RMSE
不同	静态模型	33.797 1	38.350 7
工况	动态更新模型	7.159 9	10.806 7

通过上述实验可以看出本文所提出方法能够自适应生产的变化,有效利用生产过程数据,提高动液面的预测精度。

### 5 结论

本文为解决动液面预测过程中存在的问题,在软测量回归建模预测的过程中引入了多用于分类问题研究的AdaBoost学习算法,并针对其不足,提出采用改进AdaBoost集成自适应学习算法,对样本权重及弱学习机权重进行计算,将样本预测误差加入样本权重的更新中,替代传统的两值区分,弱学习机权重中增加模型整体预测误差指标,使之更加适合回归模型预测的应用,利用油田生产过程中定期巡检的少量动液面数据评估原有集成模型,利用相似度原理在保留原有模型信息的基础上增加新信息,基于样本权重训练新的弱学习机,动态更新构建强学习机集成模型以适应新的油田生产工况。采用来自辽河油田生产现场实际数据进行软测量建模,仿真结果表明了该算法具有良好的泛化能力和自适应性,能够提高动液面预测精度。

### 参考文献

[1] 李翔宇,高宪文,李琨,等. 基于多源信息特征融合的抽油井动液面集成软测量建模[J]. 化工学报, 2016, 67(6):2469-2479.

- LI X Y, GAO X W, LI K, et al. Ensemble soft sensor modeling for dynamic liquid level of oil well based on multi-source information feature fusion [J]. Journal of Chemical Industry and Engineering, 2016, 67(6):2469-2479.
- [ 2 ] 李琨, 韩莹, 黄海礁. 基于 IBH-LSSVM 的混沌时间序列预测及其在抽油井动液面短期预测中的应用[J]. 信息与控制, 2016, 45(2):241-247.
- LI K, HAN Y, HUANG H J. Chaotic time series prediction based on IBH-LSSVM and its application to short-term prediction of dynamic fluid level in oil wells [J]. Information and Control, 2016, 45 ( 2 ) : 241-247.
- [ 3 ] 李翔宇, 高宪文, 侯延彬, 等. 基于在线动态高斯过程回归抽油井动液面软测量建模[J]. 化工学报, 2015, 66(6):2150-2158.
- LI X Y, GAO X W, HOU Y B, et al. Online dynamic Gaussian process regression for dynamic liquid level soft sensing of sucker -rod pumping well [J]. Journal of Chemical Industry and Engineering, 2015, 66 ( 6 ) : 2150-2158.
- [ 4 ] 刘佳, 邵诚, 朱理. 基于迁移学习工况划分的裂解炉收 PSO-LS-SV 建模[J]. 化工学报, 2016, 5 ( 5 ) : 1982-1988.
- LIU J, SHAO CH, ZHU L. Modeling of cracking furnace yields with PSO-LS-SVM based on operating condition classification by transfer learning [ J ]. Journal of Chemical Industry and Engineering, 2016, 5 ( 5 ) : 1982-1988.
- [ 5 ] 周丽春, 靳鑫, 刘毅, 等. 即时局部建模在填料塔液泛气速预测的应用[J]. 化工学报, 2016, 67 ( 3 ) : 1070-1075.
- ZHOU L CH, JIN X, LIU Y, et al. Just-in-time local modeling for flooding velocity prediction in packed towers[J]. Journal of Chemical Industry and Engineering, 2016,67(3):1070-1075.
- [ 6 ] 赵超, 戴坤成, 王贵评, 等. 基于 AWLS-SVM 的污水处理过程软测量建模[J]. 仪器仪表学报, 2015, 36(8):1792-1800.
- ZHAO CH, DAI K CH, WANG G P, et al. Soft sensor modeling for wastewater treatment process based on adaptive weighted least squares support vector machines[J]. Chinese Journal of Scientific Instrument, 2015,36(8):1792-1800.
- [ 7 ] 孙茂伟, 杨慧中. 基于改进 Bagging 算法的高斯过程集成软测量建模[J]. 化工学报, 2016, 67 ( 4 ) : 1386-1391.
- SUN M W, YANG H ZH. Gaussian process ensemble soft-sensor modeling based on improved Bagging algorithm [ J ]. Journal of Chemical Industry and Engineering, 2016, 67(4):1386-1391.
- [ 8 ] 夏陆岳, 王海宁, 朱鹏飞, 等. KPCA-bagging 集成神经网络软测量建模方法[J]. 信息与控制, 2015, 44(5):519-524.
- XIA L Y, WANG H N, ZHU P F, et al. Soft-sensor modeling method using kernel principal component analysis bagging ensemble neural network [ J ]. Information and Control, 2015, 44(5):519-524.
- [ 9 ] KANKANALA P, DAS S, PAHWA A. AdaBoost<sup>+</sup>: An ensemble learning approach for estimating weather-related outages in distribution systems [J]. IEEE Transactions on Power Systems, 2014, 29(1):359-367.
- [ 10 ] 毕雪芹, 惠婷. 基于肤色分割与 AdaBoost 算法的人脸检测[J]. 国外电子测量技术, 2015, 34(12):82-86.
- BI X Q, HUI T. Face detection based on skin color segmentation and AdaBoost algorithm [ J ]. Foreign Electronic Measurement Technology, 2015, 34 ( 12 ) : 82-86
- [ 11 ] 焦晓璇, 景博, 黄以锋, 等. 基于小波包 BP\_AdaBoost 算法的机载燃油泵故障诊断研究[J]. 仪器仪表学报, 2016, 37(9):1978-1988.
- JIAO X X, JING B, HUANG Y F, et al. Research on fault diagnosis for airborne fuel pump based on wavelet package and BP\_AdaBoost algorithm [J]. Chinese Journal of Scientific Instrument, 2016, 37(9):1978-1988.
- [ 12 ] MATHANKER S K, WECKLER P R, BOWSER T J, et al. AdaBoost classifiers for pecan defect classification [J]. Computers and Electronics in Agriculture, 2011, 77(1):60-68.
- [ 13 ] WANG J, GAO L, ZHANG H, et al. Adaboost with SVM-based classifier for the classification of brain motor imagery tasks [M]. Berlin Heidelberg: Springer, 2011: 629-634.
- [ 14 ] 刘元元, 杨功流, 李思宜. BP-AdaBoost 模型在光纤陀螺零偏温度补偿中的应用[J]. 北京航空航天大学学报, 2014, 40 ( 2 ) : 235-239.
- LIU Y Y, YANG G L, LI S Y. Application of BP-AdaBoost model in temperature compensation for fiber optic gyroscope bias [J]. Journal of Beijing University of Aeronautics and Astronautics, 2014, 40 ( 2 ) : 235-239.
- [ 15 ] 寇鹏, 高峰. 几何转换 Boosting 回归算法及其在高耗能企业负荷预测中的应用[J]. 系统工程理论与实践, 2013, 3(7):1880-1888.
- KOU P, GAO F. Boosting regression method based on geometric conversion and its application to load forecasting in energy-intensive enterprise [ J ]. Systems

- Engineering Theory & Practice, 2013, 3(7):1880-1888.
- [16] 田惠欣, 李坤, 孟博. 一种用于软测量建模的增量学习集成算法[J]. 控制与决策, 2015, 30(8):1523-1526.
- TIAN H X, LI K, MENG B. An incremental learning ensemble algorithm for soft sensor modeling[J]. Control and Decision, 2015, 30(8):1523-1526.
- [17] PATEL A J, PATEL J S. Ensemble systems and incremental learning[C]. International Conference on Intelligent Systems & Signal Processing, 2013: 365-368.
- [18] 王通, 高宪文, 蒋子健. 基于黑洞算法的LSSVM的参数优化[J]. 东北大学学报: 自然科学版, 2014, 35(2): 170-174.
- WANG T, GAO X W, JIANG Z J. Parameters optimizing of LSSVM based on black hole algorithm [J]. Journal of Northeastern University: Natural Science, 2014, 35(2): 170-174.
- [19] 刘毅, 金福江, 高增梁. 时变过程在线辨识的即时递推核学习方法研究[J]. Acta Automatica Sinica, 2013, 39(5):602-609.
- LIU Y, JIN F J, GAO Z L. Online identification of time-varying processes using just-in-time recursive kernel learning approach [J]. Acta Automatica Sinica, 2013, 39(5):602-609.
- [20] 王通, 高宪文, 刘文芳. 自适应软测量方法在动液面预测中的研究与应用[J]. 化工学报, 2014, 65(12): 4898-4904.

WANG T, GAO X W, LIU W F. Adaptive soft sensor method and application in determination of dynamic fluid level[J]. CIESC Journal, 2014, 65(12):4898-4904.

### 作者简介



**王通**(通讯作者), 1976年出生, 2004年于大连理工大学获得硕士学位, 2015年于东北大学获得博士学位, 现为沈阳工业大学讲师、硕士生导师, 主要研究是复杂工业过程监测、控制及故障诊断监测。

E-mail: tykj\_wt@126.com

**Wang Tong** (Corresponding author) was born in 1976, received M. Sc. from Dalian University of Technology in 2004, and Ph. D. from Northeastern University in 2015, respectively. Currently, he is a lecturer and M. Sc. supervisor in Shenyang University of Technology. His main research interests include complex industrial process detection, control and fault diagnosis.



**段泽文**, 1992年出生, 2016年于太原理工大学获得学士学位, 现为沈阳工业大学硕士研究生, 主要研究是复杂工业过程监测、控制及故障监测。

E-mail: duan\_zw1025@sina.com

**Duan Zewen** was born in 1992, received B. Sc. from Taiyuan University of Technology in 2016. Now, he is a M. Sc. candidate in Shenyang University of Technology. His main research interests include complex industrial process detection, control and fault diagnosis.