

基于鲁棒极限学习机的污泥膨胀智能检测方法

焦广利,张璐,钟麦英

(山东科技大学 电气与自动化工程学院,山东 青岛 266590)

摘要:污水处理运行数据中常含有离群点,严重影响污泥膨胀检测效果。针对该问题提出一种基于鲁棒极限学习机的智能检测方法。首先,考虑到极限学习机的输出权值由最小二乘估计获得,易受离群点的影响导致模型鲁棒性较差,通过引入M-估计技术构建基于鲁棒极限学习机(RELM)的离群点检测模型,实现离群点的检测和修正。其次,建立基于鲁棒极限学习机的污泥膨胀检测模型,根据污泥膨胀检测模型误差及阈值逻辑完成污泥膨胀的检测。最后,利用污水处理厂采集的运行数据对提出的智能检测方法进行验证。实验结果表明,本研究方法不仅可以实现离群点的有效修正,而且可以完成污泥膨胀的准确检测。

关键词:污泥膨胀;鲁棒极限学习机;检测模型;智能检测

中图分类号:TN929.5

文献标志码:A

Intelligent detection method of sludge bulking based on robust extreme learning machine

JIAO Guangli, ZHANG Lu, ZHONG Maiying

(College of Electrical Engineering and Automation, Shandong University of Science and Technology, Qingdao, Shandong 266590, China)

Abstract: Outliers often exist in the operating data of wastewater treatment process, which seriously affects the sludge bulking detection effect. To solve this problem, this paper proposes an intelligent detection method based on robust extreme learning machine(RELM). Firstly, considering that the output weights of the extreme learning machine obtained by least square estimation were easily affected by outliers and would lead to the poor robustness of detection models, an outlier detection model based on the extreme learning machine was established by using M-estimation technology to detect and correct the outliers. Secondly, a sludge bulking detection model based on the robust extreme learning machine was proposed to detect the sludge bulking according to the errors of the sludge bulking detection model and the threshold logic. Finally, the operating data from a wastewater treatment process were utilized to verify the effectiveness of the proposed intelligent detection method. The results show that the proposed method can not only correct the outliers efficiently, but it can also detect the sludge bulking accurately.

Key words: sludge bulking; RELM; detection model; intelligent detection

污水处理过程主要采用活性污泥法处理技术,利用活性污泥中微生物的吸附和降解能力,去除污水中的污染物,改善出水水质^[1]。然而,由于进水流量、进水水质等被动接受、二沉池端泥水分离异常等原因导致污水处理过程中污泥膨胀现象频发^[2],不仅影响出水水质,严重时会导致污水处理系统瘫痪^[3]。如何实时检测污泥膨胀,保证污水处理过程的安全稳定运行,是污水处理厂面临的挑战性问题。

近年来,国内外学者围绕污泥膨胀检测方法展开了研究,其方法主要分为模型驱动和数据驱动^[4]。模型

收稿日期:2021-06-28

基金项目:国家自然科学基金项目(62103246);中国博士后科学基金项目(2021M691966)

作者简介:焦广利(1993—),男,山东菏泽人,硕士研究生,主要从事机器学习故障诊断研究。

钟麦英(1965—),女,山东博兴人,教授,博士生导师,主要从事故障诊断与容错控制研究,本文通信作者。

E-mail:myzhong@sdust.edu.cn

驱动的方法主要通过建立活性污泥模型分析污泥的沉降性能,获取污泥膨胀信息^[5]。例如,Dominika等^[6]通过分析活性污泥过程模型,获取污泥膨胀和底物浓度关系,实现了污泥膨胀的有效检测。Vazquez等^[7]通过分析微生物的生长特点及活性污泥的形态,建立污水处理相关过程变量与活性污泥颗粒大小的表征模型,实现对污泥膨胀状态的判断。由于污水处理过程中污泥膨胀引发因素众多,发生机理复杂,模型驱动的检测方法难以直接适用。随着传感器技术及数据采集技术等的发展,数据驱动的检测方法得到快速发展^[8-11]。数据驱动的方法主要通过分析污水处理过程水质参量和污泥膨胀的关系,建立污泥膨胀检测模型,实现污泥膨胀检测。现有的数据驱动的污泥膨胀检测方法主要有基于神经网络的检测方法、基于多元统计分析的检测方法等。例如,Han等^[12]利用递归核主元分析方法构建污泥膨胀检测模型,并利用卷积网络实现污泥膨胀的辨识。Brault等^[13]提出一种基于神经网络的污泥膨胀检测方法获取污泥膨胀动态特性,并根据专家经验判断是否发生污泥膨胀。Nashia等^[14]基于图像处理技术获取不同类型丝状菌的丰度信息,利用人工神经网络建立丝状菌丰度与污泥容积指数的特征模型,通过专家经验实现污泥膨胀检测。Han等^[15]提出一种基于多元局部二次多项式回归的污泥膨胀检测方法,通过建立污泥容积指数与相关过程变量之间的关系,实现污泥膨胀的智能检测。Cheng等^[16]提出一种基于改进典型相关分析的污泥膨胀检测方法,通过引入增广的拉格朗日算法恢复低秩数据矩阵中重要信息,降低了噪声数据对污泥膨胀检测的影响,提高了污泥膨胀检测精度。Wu等^[17]提出一种基于改进多核相关向量机的污泥膨胀检测方法,通过引入多核学习提高相关向量机模型性能,实现了污泥膨胀的高效检测。虽然上述方法能够实现污泥膨胀的检测,但由于检测仪表精度下降或人为操作失误等原因,获取的运行数据中常含有离群点,这些离群点在建立污泥膨胀检测模型之前通过数据预处理剔除,造成部分信息丢失,导致污泥膨胀特征模型精度下降,使污泥膨胀检测的准确性受到影响。另外,上述污泥膨胀检测方法大多依靠人工经验判断,由于不同污水处理厂之间的差异性,基于人工经验的异常工况检测方法在应用时受到了一定的限制。

针对上述问题,提出一种基于鲁棒极限学习机(robust extreme learning machine, RELM)的污泥膨胀智能检测方法:以模型结构简单、训练速度快的极限学习机作为基础,构建离群点检测模型和污泥膨胀检测模型,利用M-估计实现建模误差加权,降低离群点对模型精度造成的不良影响,保证检测模型的鲁棒性。通过与其他检测精度较高模型的实验比较,验证所提方法具有更强的鲁棒性。此外,根据离群点检测模型的估计误差及阈值逻辑,实现离群点的在线检测及修正,提高在线数据的准确性,实现污泥膨胀的智能检测。

1 污泥膨胀智能检测方法

1.1 污水处理过程描述

活性污泥法污水处理过程主要包括生化反应池和二沉池处理两部分(见图1)。首先,污水进入生化反应池,对各种有机物进行分解并将其转化为稳定的无机物。随后污水进入二沉池,进行泥水分离,上清液直接排放,部分活性污泥回流至生化反应池。污水处理过程的高效稳定运行离不开正常的泥水分离,一旦泥水




图1 污水处理过程示意图

Fig. 1 Schematic diagram of wastewater treatment process

分离出现异常,将会发生污泥膨胀。

污泥容积指数(sludge volume index, SVI)作为反映污泥沉降性能的一个重要指标,可用于评价污泥膨胀的严重程度。在设计污泥膨胀检测方法之前,需获取影响 SVI 的关键过程变量:混合液悬浮固体浓度(mixed liquor suspended solids, MLSS)、化学需氧量(chemical oxygen demand, COD)、溶解氧(dissolved oxygen, DO)、总氮(total nitrogen, TN)、生化需氧量(biochemical oxygen demand, BOD)和温度(temperature, T)^[18]。

1.2 离群点检测模型构建

为有效去除运行数据中的离群点,构建一种基于鲁棒极限学习机的检测模型,模型结构如图 2 所示。离群点检测模型输出可表示为:

$$SVI(t) = \sum_{j=1}^L \beta_j g(\langle \mathbf{a}_j, \mathbf{x}(t) \rangle + b_j), \quad (1)$$

式中: $SVI(t)$ 为 t 时刻的模型输出值; $\mathbf{x}(t)$ 为 t 时刻的模型输入变量, $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_6(t)]^T = [MLSS(t), COD(t), DO(t), TN(t), BOD(t), T(t)]^T \in \mathbf{R}^6$; $\mathbf{a}_j \in \mathbf{R}^6$ 为输入权值,用于连接输入层和隐含层, $j = 1, 2, \dots, L$; L 为隐含层节点数; b_j 为第 j 个隐节点的偏置, \mathbf{a}_j 和 b_j 在 $[-1, 1]$ 范围内随机产生^[19]; $\langle \mathbf{a}_j, \mathbf{x}(t) \rangle$ 表示向量 \mathbf{a}_j 和 $\mathbf{x}(t)$ 的内积^[20]; $g(\cdot)$ 是非线性激活函数,本研究选择 sigmoid 函数; $\boldsymbol{\beta}$ 表示输出层和隐含层之间的权值, $\boldsymbol{\beta} = [\beta_1, \beta_2, \dots, \beta_L]^T$,可利用最小二乘法求解得到。对于 M 组输入输出样本, $\boldsymbol{\beta}$ 的计算式为^[21]:

$$\boldsymbol{\beta} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \cdot \mathbf{SVI}. \quad (2)$$

式中: \mathbf{SVI} 为检测模型输出矩阵; \mathbf{H} 为隐含层的输出矩阵,且

$$\mathbf{H} = \begin{bmatrix} g(\langle \mathbf{a}_1, \mathbf{x}(1) \rangle + b_1) & \cdots & g(\langle \mathbf{a}_L, \mathbf{x}(1) \rangle + b_L) \\ \vdots & \ddots & \vdots \\ g(\langle \mathbf{a}_1, \mathbf{x}(M) \rangle + b_1) & \cdots & g(\langle \mathbf{a}_L, \mathbf{x}(M) \rangle + b_L) \end{bmatrix}_{M \times L}. \quad (3)$$

由于基于极限学习机离群点检测模型的输出权值由最小二乘法得到,易受离群点的影响导致模型精度下降。为了实现鲁棒建模,利用 M-估计技术减少离群点对模型性能的影响。M-估计技术的基本思想是采用迭代加权最小二乘回归的方法,根据样本误差大小确定样本权值,通过加权的方式降低离群点的影响,实现鲁棒建模的目的^[22]。引入 M-估计技术后的目标函数改写为:

$$Q(t) = \sum_{t=1}^M \rho(r(t)) = \sum_{t=1}^M \rho(SVI(t) - \mathbf{H}(t)\boldsymbol{\beta}), \quad (4)$$

式中: ρ 表示 M-估计的影响函数, $r(t)$ 为预测误差。

引入 M-估计技术后,输出权重 $\boldsymbol{\beta}$ 的求解过程可表示为:

$$\hat{\boldsymbol{\beta}} = \arg \min_{\boldsymbol{\beta} \in \mathbf{R}^L} \sum_{t=1}^M \rho\left(\frac{SVI(t) - \mathbf{H}(t)\boldsymbol{\beta}}{\hat{\sigma}}\right) = \arg \min_{\boldsymbol{\beta} \in \mathbf{R}^L} \sum_{t=1}^M \rho\left(\frac{r(t)}{\hat{\sigma}}\right). \quad (5)$$

式中 $\hat{\sigma}$ 为误差稳健尺度估计,其取值为^[23]:

$$\hat{\sigma} = d_{MAD} / 0.6745, \quad d_{MAD} = \text{med}(|r(t) - \text{med}(r(t))|), \quad (6)$$

其中 med 表示中值绝对偏差,是统计离散程度的一种度量。

令 $\partial(\sum_{t=1}^M \rho(\frac{r(t)}{\hat{\sigma}})) / \partial \boldsymbol{\beta} = 0$, 可得:

$$\sum_{t=1}^M \rho'\left(\frac{r(t)}{\hat{\sigma}}\right) \mathbf{H}^T(t) = 0. \quad (7)$$




图 2 离群点检测模型结构图

Fig. 2 Structure diagram of outliers detection model

根据 $r(t)$ 定义加权因子函数:

$$\omega(r(t)) = \rho'(r(t))/r(t). \tag{8}$$

将式(8)代入式(7)得:

$$\sum_{t=1}^M \omega\left(\frac{r(t)}{\hat{\sigma}}\right) \times (SVI(t) - \mathbf{H}(t)\boldsymbol{\beta})\mathbf{H}^T(t) = 0. \tag{9}$$

根据式(9)可得:

$$\mathbf{H}^T \mathbf{W} \mathbf{H} \boldsymbol{\beta} = \mathbf{H}^T \mathbf{W} \cdot \mathbf{SVI}. \tag{10}$$

故 $\boldsymbol{\beta}$ 的迭代求解过程可表示为:

$$\hat{\boldsymbol{\beta}}^{(k+1)} = (\mathbf{H}^T \mathbf{W}^{(k)} \mathbf{H})^{-1} \mathbf{H}^T \mathbf{W}^{(k)} \cdot \mathbf{SVI}. \tag{11}$$

式中: k 为迭代次数; $\mathbf{W}^{(k)}$ 是以 $w(t) = 1, 2, \dots, M$ 为对角元的加权矩阵; $w(t)$ 为加权因子。考虑到建模误差可能不服从高斯分布, 利用柯西分布来确定加权因子函数

$$w(r(t), r_c, a_c) = a_c / \pi(a_c^2 + (r(t) - r_c)^2), r(t) \in \mathbf{R}. \tag{12}$$

式中: r_c 用于确定柯西分布加权因子函数的位置,

$$r_c = \text{median}(r(t)); \tag{13}$$

a_c 用于确定柯西分布加权因子函数的宽度,

$$a_c = 1 \sqrt{\frac{\sum_{t=1}^M \|r(t) - \sum_{t=1}^M r(t)/M\|^2}{M}}. \tag{14}$$

利用正常数据和污泥膨胀数据对离群点检测模型进行离线训练和测试, 模型估计误差表示为:

$$J_o(t) = |SVI_r(t) - SVI(t)|. \tag{15}$$

式中: $J_o(t)$ 为离群点检测模型估计误差, $SVI_r(t)$ 为实际测量值, $SVI(t)$ 为离群点检测模型输出值。将模型测试的最大误差设置为离群点检测阈值:

$$J_{o,th} = \max(J_o(t)). \tag{16}$$

在线阶段, 一旦离群点检测模型误差超出检测阈值 $J_{o,th}$, 则将其识别为离群点, 并利用离群点检测模型的估计值取代离群点, 实现在线修正。离群点检测模型算法步骤如算法 1 所示。

算法 1 离群点检测模型算法

- 1) 通过式(2)计算初始 $\hat{\boldsymbol{\beta}}^{(0)}$, 即 $\hat{\boldsymbol{\beta}}^{(0)} = (\mathbf{H}^T \mathbf{H})^{-1} \mathbf{H}^T \cdot \mathbf{SVI}$ 。
- 2) 计算误差向量 $\mathbf{r}^{(0)}$, 即 $\mathbf{r}^{(0)} = \mathbf{H}\hat{\boldsymbol{\beta}}^{(0)} - \mathbf{SVI}$, 通过式(8)计算 $\hat{\sigma} = d_{MAD}/0.6745$, 对误差进行标准化处理, 即 $r^{(0)}/\hat{\sigma}^{(0)}$ 。
- 3) 把标准化后的误差代入加权因子函数(12)求解每个建模误差的加权值, 并把加权因子写成矩阵的形式 $\mathbf{W}^{(0)}$ 。
- 4) 通过式(11)迭代计算 $\hat{\boldsymbol{\beta}}^{(1)}, \dots, \hat{\boldsymbol{\beta}}^{(k)}, \hat{\boldsymbol{\beta}}^{(k+1)}$, 其终止条件为: $|\hat{\boldsymbol{\beta}}^{(k+1)} - \hat{\boldsymbol{\beta}}^{(k)}| / \hat{\boldsymbol{\beta}}^{(k)} < \delta$ 。其中, δ 为一个较小的正数, k 表示迭代次数。
- 5) 最终 $\boldsymbol{\beta}$ 取值为: $\hat{\boldsymbol{\beta}} = \hat{\boldsymbol{\beta}}^{(k+1)}$ 。

1.3 污泥膨胀智能检测模型

为了实现污泥膨胀的检测, 需构建污泥膨胀检测模型。本研究采用鲁棒极限学习机构建污泥膨胀检测模型, 模型的输出可表示为:

$$SVI_d(t) = \sum_{i=1}^I \eta_i f_i(\langle \boldsymbol{\Phi}_i, \mathbf{v}(t) \rangle + \zeta_i), i = 1, 2, \dots, I. \tag{17}$$

其中: $SVI_d(t)$ 为污泥膨胀模型输出值, $\mathbf{v}(t)$ 为模型输入变量, $\mathbf{v}(t) = [v_1(t), v_2(t), \dots, v_6(t)]^T = [MLSS(t), COD(t), DO(t), TN(t), BOD(t), T(t)]^T \in \mathbf{R}^6$, $\boldsymbol{\Phi}_i \in \mathbf{R}^M$ 为输入权值, ζ_i 为第 i 个隐含层节点的偏置, $f(\cdot)$ 是非线性激活函数, η_i 为输出权值, 其更新方式分别如式(2)~(14)所示。

利用正常数据对污泥膨胀检测模型进行离线训练和测试, 模型估计误差为:

$$J_d(t) = |SVI_r(t) - SVI_d(t)|. \tag{18}$$

其中: $J_d(t)$ 为污泥膨胀检测模型估计误差, $SVI_d(t)$ 为污泥膨胀检测模型输出值。

在模型训练过程中,仅利用无污泥膨胀数据,污泥膨胀检测模型误差相对较小,而污泥膨胀模型在线检测阶段,由于出现污泥膨胀数据,导致模型误差波动较大。因此,为了有效检测污泥膨胀,将模型离线测试时的最大误差设置为污泥膨胀检测阈值,即

$$J_{d,th} = \max(J_d(t))。 \tag{19}$$

当污泥膨胀检测模型估计误差大于阈值时,则认为发生了污泥膨胀,即:

$$\begin{cases} J_d(t) \leq J_{d,th}, \text{无污泥膨胀;} \\ J_d(t) > J_{d,th}, \text{污泥膨胀。} \end{cases} \tag{20}$$

1.4 污泥膨胀智能检测算法

基于鲁棒极限学习机的污泥膨胀检测分为离线建模和在线检测两部分,如图 3 所示。

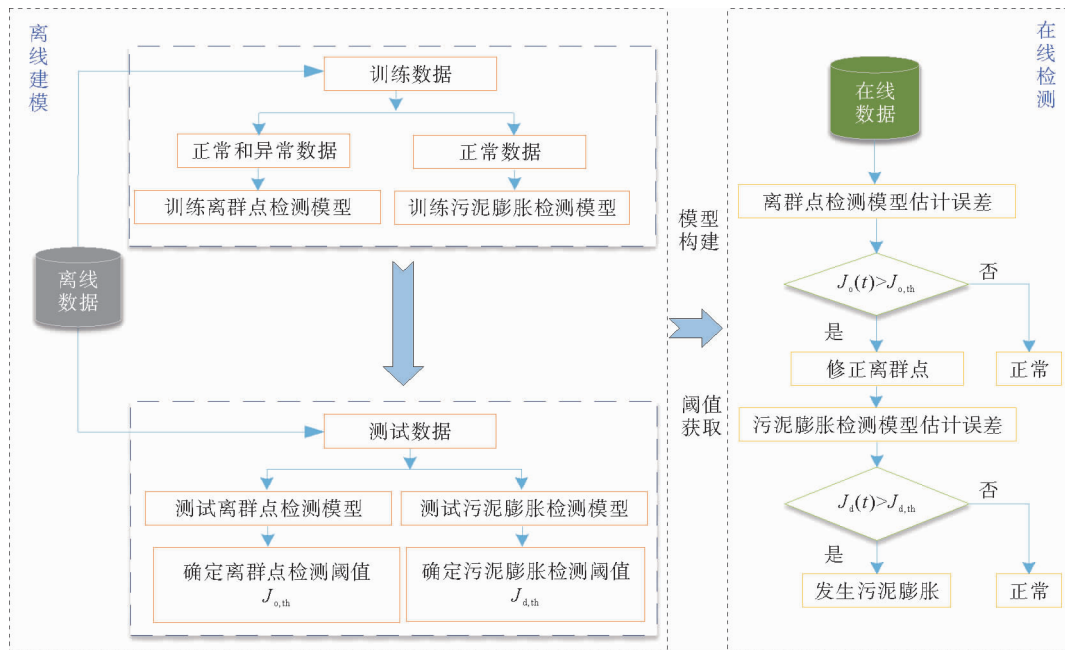


图 3 污泥膨胀检测算法架构图

Fig. 3 Schematic diagram of sludge bulking detection algorithm

离线阶段,利用训练数据分别建立离群点检测模型和污泥膨胀检测模型;利用测试数据获取离群点检测模型估计误差,确定离群点检测阈值;利用测试数据获取污泥膨胀检测模型估计误差,获取污泥膨胀检测阈值。在线阶段,根据获取的离群点检测模型估计误差,通过阈值逻辑对离群点数据进行检测及修正;在获取污泥膨胀检测模型估计误差的基础上,利用阈值逻辑判断是否发生污泥膨胀,具体步骤如算法 2 所示。

算法 2 污泥膨胀智能检测算法

离线阶段:

- 1) 获取 SVI 及其相关过程变量($MLSS$ 、 COD 、 DO 、 TN 、 BOD 、 T)离线数据;
- 2) 通过算法 1 构建 SVI 离群点检测模型及污泥膨胀检测模型;
- 3) 分别通过式(16)和式(19)确定 SVI 离群点检测阈值 $J_{o,th}$ 和污泥膨胀检测阈值 $J_{d,th}$ 。

在线阶段:

- 1) 获取 SVI 及其相关过程变量($MLSS$ 、 COD 、 DO 、 TN 、 BOD 、 T)在线数据;
- 2) 获取 SVI 离群点检测模型的估计误差,通过式(16)判断 SVI 离群点,由 SVI 离群点检测模型的估计值替换 SVI 离群点;
- 3) 获取污泥膨胀检测模型的估计误差,由式(20)判断是否发生污泥膨胀。

2 实验结果及分析

为了验证所提方法的有效性,利用从污水处理厂采集的 2018 年运行数据对所提方法进行验证,验证分为三部分:检测模型的训练和测试效果分析、离群点检测和修正效果及分析和污泥膨胀检测效果及分析。

实验共包含 786 组数据,选择 100 组同时含有污泥膨胀数据和正常数据作为在线数据,剩余 686 组数据作为离线数据。

离线阶段,对于离群点检测模型,利用 686 组混合数据(包含正常数据和污泥膨胀数据)训练和测试离群点检测模型,其中 636 组用于训练,并在训练数据中随机抽取 5% 的数据加入离群点,剩余 50 组数据用于测试;对于污泥膨胀检测模型,利用 550 组不含污泥膨胀的数据对模型进行训练和测试,其中选择 500 组数据用于训练,并在训练数据中随机抽取 5% 的数据加入离群点,剩余 50 组数据用于测试。需要注意的是,离线测试数据中不含离群点。

在线阶段,随机抽取 5% 的在线数据加入离群点,设定在线数据从第 70 个样本点开始出现污泥膨胀数据。离群点添加方式为:

$$SVI_o(t) = SVI_r(t) + sign \times [rand(0, 1)(\max(SVI_r(t)) - \min(SVI_r(t)))]. \quad (21)$$

式中:rand(0, 1)表示(0, 1)范围内的随机数;SVI_r(t)、max(SVI_r(t))、min(SVI_r(t))分别表示输出变量 SVI 的实际值、最大值、最小值;sign 取+1 时表示正偏离群点,取-1 时表示负偏离群点。为了确保添加离群点的合理性,加入正偏离群点和负偏离群点的比例为 2:1。

离群点检测模型结构为 6-50-1,即输入变量为 6,隐层神经元数为 50,输出变量为 SVI;污泥膨胀检测模型结构为 6-20-1,即输入变量为 6,隐层神经元数为 20,输出变量为 SVI_d。

利用均方根误差(RMSE)和模型精度(MA)评价智能检测模型的性能:

$$RMSE = \sqrt{\frac{1}{2T} \sum_{t=1}^T (SVI_r(t) - SVI(t))^2}, \quad (22)$$

$$MA = \frac{1}{T} \sum_{t=1}^T \left(1 - \frac{|SVI_r(t) - SVI(t)|}{SVI_r(t)} \right) \times 100\%. \quad (23)$$

式中 T 表示在线样本个数。

2.1 检测模型的测试效果

图 4 为鲁棒极限学习机(RELM)训练过程中加权因子随着离群点检测模型误差(归一化)的变化图。由图 4 可见,当离群点检测模型误差较大时,加权因子会变小,以此来保证模型输出更接近于实际值。

图 5 和图 6 分别为离群点检测模型的测试效果图和测试估计误差效果图,误差均在[-15, 15]范围内,均方根误差在 2.6 左右。

图 7 和图 8 分别为污泥膨胀检测模型的测试效果以及估计误差测试效果,误差在[-10, 10]范围内,均方根误差在 2.4 左右。测试结果表明,所设计的基于鲁棒极限学习机的检测模型能够准确地描述污泥膨胀动态特性。

为了进一步验证基于鲁棒极限学习机(RELM)的检测模型优势,将该方法同其他 SVI 检测模型方法进行对比,包括基于极限学习机的检测模型(extreme learning machine, ELM)、基于模糊神经网络的检测模型(fuzzy neural network, FNN)^[24]、基于多元局部多项式二次多项式回归模型(multivariate local quadratic polynomial regression, MLQPR)^[15]。利用 500 组正常数据作为训练数据,并随机抽取 10% 的数据加入离群点,利用 50 组不含离群点的正常数据作为测试数据。图 9 为不同模型的测试估计误差效果图,从图中可以看出,基于鲁棒极限学习机(RELM)的污泥膨胀检测模型性能更优。

鉴于训练数据中添加离群点的随机性以及检测模型本身的随机性,为了使对比结果更加合理,对该实验运行 10 次,并对运行结果取平均,不同检测模型的性能对比结果见表 1。从表 1 中可以看出,基于鲁棒极限学习机的检测模型能够获得较小的测试平均 RMSE 及较高的测试平均 MA。




图 4 加权因子分配图

Fig. 4 Distribution figure of weighting factors




图 5 离群点检测模型测试效果图

Fig. 5 Test rendering of outliers detection model




图 6 离群点检测模型测试误差效果图

Fig. 6 Test error rendering of outliers detection model




图 7 污泥膨胀检测模型测试效果图

Fig. 7 Test renderings of sludge bulking detection model




图 8 污泥膨胀检测模型测试误差效果图

Fig. 8 Test error renderings of sludge bulking detection model

2.2 离群点检测和修正效果

图 10 为离群点在线检测效果图和数据修正效果图。从图中可以看出,修正后的红色曲线和无离群点的黑色曲线几乎重合,说明本方法能够实现离群点数据的检测及修正,减少了离群点对污泥膨胀检测的影响,提高了检测效果。

2.3 污泥膨胀检测效果

利用 100 组在线数据(设定从第 70 个数据点开始出现污泥膨胀数据)进行检测。图 11 为污泥膨胀检测模型在线预测 SVI 的效果图,图 12 为污泥膨胀检测模型的检测效果。从图中可以看出,无污泥膨胀时,污泥膨胀检测模型估计误差均处于阈值以下。从第 70 个数据点开始,污泥膨胀模型估计误差超出阈值,则认为发生了污泥膨胀。实验结果表明,所设计的污泥膨胀检测方法能够实现污泥膨胀的检测,验证了所提出的污泥膨胀智能检测方法的有效性。

表 1 不同模型性能对比

Tab. 1 Performance comparison of different models

| 污泥膨胀检测模型 | 测试误差绝对值 | | 测试 RMSE | 测试 MA/% |
|----------|---------|-------|---------|---------|
| | 最大值 | 最小值 | | |
| RELM | 6.563 | 0.127 | 4.297 | 95.5 |
| ELM | 20.735 | 0.294 | 5.364 | 92.3 |
| MLQPR | 68.375 | 2.107 | 10.322 | 72.5 |
| FNN | 18.639 | 0.147 | 7.590 | 83.6 |




图 9 模型估计误差对比效果图

Fig. 9 Model estimation error comparison renderings

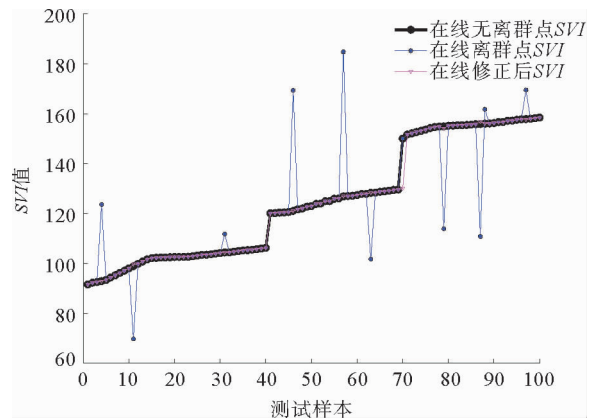


图 10 离群点检测及数据修正效果图

Fig. 10 Outliers detection and data correction renderings




图 11 污泥膨胀检测模型在线预测效果图

Fig. 11 On-line prediction rendering of sludge bulking model




图 12 污泥膨胀检测模型检测效果图

Fig. 12 Detection rendering of sludge bulking detection model

3 结论

本研究提出一种基于鲁棒极限学习机的污泥膨胀智能检测方法,通过引入 M-估计技术构建基于鲁棒极限学习机的离群点检测模型和污泥膨胀检测模型,利用离群点检测模型的估计误差对离群点进行检测和修正,根据污泥膨胀检测模型的估计误差及阈值逻辑实现了污泥膨胀的精准检测。实验结果表明,本方法不仅实现了污泥膨胀的鲁棒建模而且对离群点进行了修正,实现了污泥膨胀的精确检测。

本方法只适用于单一工况下的检测,而污水处理过程同时存在多种异常工况,如何基于迁移学习等方法设计适用于多工况的智能检测方法是下一步需要解决的问题。

参考文献:

- [1] HESS J, BERNARD O. Design and study of a risk management criterion for an unstable anaerobic wastewater treatment process[J]. *Journal of Process Control*, 2008, 18(1): 71-79.
- [2] WAQAS S, BILAD M R, MAN Z, et al. Recent progress in integrated fixed-film activated sludge process for wastewater treatment: A review[J/OL]. *Journal of Environmental Management*, 2020, 268. DOI: 10.1016/j.jenvman.2020.110718.
- [3] 张璐, 钟麦英. 基于自适应模糊神经网络的污泥膨胀智能检测方法[J]. *山东科技大学学报(自然科学版)*, 2022, 41(1): 98-106.
ZHANG Lu, ZHONG Maiying. Intelligent detection method for sludge bulking based on adaptive fuzzy neural network[J]. *Journal of Shandong University of Science and Technology(Natural Science)*, 2022, 41(1): 98-106.
- [4] DEEPNARIAN N, NASR M, AMOCH I D, et al. Impact of sludge bulking on receiving environment using quantitative microbial risk assessment(QMRA)-based management for full-scale wastewater treatment plants[J/OL]. *Journal of Environmental Management*, 2020, 267. DOI: 10.1016/j.jenvman.2020.110660.
- [5] 韩红桂, 伍小龙, 张璐, 等. 城市污水处理过程异常工况识别和抑制研究[J]. *自动化学报*, 2018, 44(11): 1971-1984.
HAN Honggui, WU Xiaolong, ZHANG Lu, et al. Identification and suppression of abnormal conditions in municipal wastewater treatment process[J]. *Acta Automatica Sinica*, 2018, 44(11): 1971-1984.
- [6] DOMINIKA S, AGNIEZSKA T, PRZEMYSŁAW K. Long-term performance and microbial characteristics of the anamox-enriched granular sludge cultivated in a bench-scale sequencing batch reactor[J]. *Biochemical Engineering Journal*, 2017, 120(1): 125-135.
- [7] VAZQUEZ I, RODRIGUEZ J, MARANON E, et al. Study of the aerobic biodegradation of coke wastewater in a two and three-step activated sludge process[J]. *Journal of Hazardous Materials*, 2006, 137(3): 1681-1688.
- [8] LIU Y Q, PAN Y P, HUANG D P, et al. Fault prognosis of filamentous sludge bulking using an enhanced multi-output gaussian processes regression[J]. *Control Engineering Practice*, 2017, 62: 46-54.
- [9] 岳宇飞, 罗建旭. 一种改进的 SOM 神经网络在污水处理故障诊断中的应用[J]. *华东理工大学学报(自然科学版)*, 2017, 43(3): 389-396.
YUE Yufei, LUO Jianxu. An application of improved SOM neural network in fault diagnosis of wastewater treatment[J]. *Journal of East China University of Science and Technology(Natural Science Edition)*, 2017, 43(3): 389-396.
- [10] BANSAL N K, FENG X, ZHANG W J, et al. Modeling temporal pattern and event detection using hidden Markov model with application to a sludge bulking data[J]. *Procedia Computer Science*, 2012, 12: 218-223.
- [11] SAMUELSSON O, BJORK A, ZAMBRANO J. Gaussian process regression for monitoring and fault detection of wastewater treatment processes[J]. *Water Science and Technology*, 2017, 75(12): 2952-2963.
- [12] HAN H G, DONG L X, QIAO J F. Data-knowledge-driven diagnosis method for sludge bulking of wastewater treatment process[J]. *Journal of Process Control*, 2021, 98: 106-115.
- [13] BRAULT J M, LABIB R, PERRIER M, et al. Prediction of activated sludge filamentous bulking using ATP data and neural networks[J]. *The Canadian Journal of Chemical Engineering*, 2011, 89(4): 901-913.
- [14] NASHIA D, MAHMOUD N, SHEENA K, et al. Artificial intelligence and multivariate statistics for comprehensive assess

- ment of filamentous bacteria in wastewater treatment plants experiencing sludge bulking[J/OL]. *Environmental Technology & Innovation*, 2020, 19. DOI:10.1016/j.eti.2020.100853.
- [15] SCHULER A J, JASSBY D. Filament content threshold for activated sludge bulking: Artifact or reality?[J]. *Water Research*, 2007, 41(19): 4349-4356.
- [16] CHENG H C, WU J, Huang D P, et al. Robust adaptive boosted canonical correlation analysis for quality-relevant process monitoring of wastewater treatment[J]. *ISA Transactions*, 2021, 117: 210-220.
- [17] WU J, CHENG H C, LIU Y Q, et al. Learning soft sensors using time difference-based multi-kernel relevance vector machine with applications for quality-relevant monitoring in wastewater treatment[J]. *Environmental Science and Pollution Research*, 2020, 27(23): 28986-28999.
- [18] HAN H G, LIU Z, GUO Y N, et al. An intelligent detection method for bulking sludge of wastewater treatment process[J]. *Journal of Process Control*, 2018, 68: 118-128.
- [19] TAO H, SHARAFATI A, MOHAMMED A, et al. Global solar radiation estimation and climatic variability analysis using extreme learning machine based predictive model[J]. *IEEE Access*, 2020, 8(2): 12026-12042.
- [20] 李温鹏, 周平. 高炉铁水质量鲁棒正则化随机神经网络建模[J]. *自动化学报*, 2020, 46(4): 721-733.
LI Wenpeng, ZHOU Ping. Robust regularized RVFLNs modeling of molten iron quality in blast furnace ironmaking[J]. *Acta Automatica Sinica*, 2020, 46(4): 721-733
- [21] 刘进进, 周平, 温亮. 高炉铁水质量均方根误差概率加权集成学习建模[J]. *控制理论与应用*, 2020, 37(5): 987-998.
LIU Jinjin, ZHOU Ping, WEN Liang. Root mean square error probability weighted integrated learning based modeling for molten iron quality in blast furnace ironmaking[J]. *Control Theory & Applications*, 2020, 37(5): 987-998.
- [22] WANG K N, PEI H M, CAO J D, et al. Robust regularized extreme learning machine for regression with non-convex loss function via DC program[J]. *Journal of the Franklin Institute*, 2020, 357(11): 7069-7091.
- [23] ZHOU P, LV Y B, WANG H, et al. Data-driven robust RVFLNS modeling of a blast furnace iron-making process using Cauchy distribution weighted M-estimation[J]. *IEEE Transactions on Industrial Electronics*, 2017, 64(9): 7141-7151.
- [24] HAN H G, WU X L, QIAO J F. Nonlinear systems modeling based on self-organizing fuzzy-neural-network with adaptive computation algorithm[J]. *IEEE Transactions on Cybernetics*, 2013, 44(4): 554-564.

(责任编辑:傅 游)