

基于 CFNN 的污水处理过程溶解氧浓度在线控制

权利敏^{1,2}, 杨翠丽^{1,2}, 乔俊飞^{1,2}

(1. 北京工业大学信息学部, 北京 100124; 2. 计算智能与智能系统北京市重点实验室, 北京 100124)

摘要: 污水处理过程入水干扰严重, 不确定性强, 因而对溶解氧浓度进行实时控制与精确控制比较困难。为了提高溶解氧浓度的控制精度和控制器的鲁棒性, 提出一种基于相关熵模糊神经网络 (CFNN) 的溶解氧浓度在线控制方法。首先, 建立了基于跟踪误差相关熵的性能准则, 以抑制较大的异常值。其次, 基于在线梯度下降算法调整控制器的参数, 并分析了系统的稳定性。最后, 基于基准仿真 1 号模型 (BSM1) 进行实验。结果表明, 提出的 CFNN 控制器能够实时精准地跟踪溶解氧浓度, 相比其他基于均方误差准则的神经网络控制器, 其具有更高的控制精度与稳定性。

关键词: 溶解氧; 在线控制; 相关熵; 模糊神经网络; 污水处理过程

中图分类号: TP273

文献标识码: A

doi: 10.11959/j.issn.2096-6652.202028

CFNN-based online control for dissolved oxygen concentration of wastewater treatment processes

QUAN Limin^{1,2}, YANG Cuili^{1,2}, QIAO Junfei^{1,2}

1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China

2. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing 100124, China

Abstract: Due to the frequent disturbance in flow and load, as well as the large uncertainty in the wastewater treatment processes, it is difficult to control the dissolved oxygen accurately and in real-time. To improve the accuracy and robustness of the controller, an online control method of dissolved oxygen concentration using the correntropy based fuzzy neural network (CFNN) was proposed. First, the performance index was established based on the correntropy of tracking errors to suppress large outliers in the process. Then, the parameters of controller were updated by the online gradient descent algorithm. Moreover, the stability of the control system was analyzed. Finally, the experiments were carried out based on the Benchmark Simulation Model No.1 (BSM1). The results prove that the CFNN controller performs better than the mean square error based neural network controller in accuracy and model stability.

Key words: dissolved oxygen, online control, correntropy, fuzzy neural network, wastewater treatment processes

1 引言

污水处理能够去除污水中的有机污染物以及氮、磷等污染物, 对于改善水环境至关重要^[1-2]。面

对越来越严格的出水标准, 污水处理过程 (wastewater treatment processes, WWTP) 需要维持稳定、高效的运行以改善出水水质。而在污水处理过程中, 溶解氧 (dissolved oxygen, DO) 浓度直接

收稿日期: 2020-07-01; 修回日期: 2020-08-19

通信作者: 乔俊飞, junfeiq@bjut.edu.cn

基金项目: 国家自然科学基金资助项目 (No.61533002, No.61890930, No.61973010); 国家重点研发计划基金资助项目 (No.2018YFC19008005); 水体污染控制与治理科技重大专项基金资助项目 (No.2018ZX07111005)

Foundation Items: The National Natural Science Foundation of China (No.61533002, No.61890930, No.61973010), The National Key Research and Development Program of China (No.2018YFC19008005), The Major Science and Technology Program for Water Pollution Control and Treatment of China (No.2018ZX07111005)

影响着好氧区微生物的生长与活性,是污水处理系统稳定运行的关键^[2]。因此,对 DO 浓度的实时精确控制十分必要。

近年来,污水处理过程中 DO 浓度的控制问题引起了国内外许多学者的广泛关注^[2-12]。其中,比例-积分-微分(proportional-integral-derivative, PID)控制器^[4-5]因其算法简单、易于实践而得到应用。然而,传统的 PID 控制方法难以在线调整参数,且存在控制精度低的问题。因此,一些智能控制算法(如模糊控制^[6-7]、神经网络控制^[8-11]等)被广泛应用到 DO 浓度的控制中。Belchior C A C 等人^[7]提出一种自适应模糊控制算法,提高了 DO 浓度控制算法的自适应性,但模糊规则的获取依靠专家经验,控制精度仍有待提高。Bo Y C 等人^[8]提出一种基于回声状态网络(echo state network, ESN)的自适应动态规划控制方法,并在基准仿真 1 号模型(benchmark simulation model No.1, BSM1)的干燥天气工况下进行实验,结果表明,基于 ESN 的自适应动态规划控制方法具有较高的 DO 浓度控制精度。但是,污水处理过程入水工况多变,干扰频繁,基于 ESN 的控制方法难以保证系统的稳定性。近来,模糊神经网络(fuzzy neural network, FNN)因既有处理模糊信息的能力,又具有神经网络的自学习能力,而被广泛应用在工业过程的建模与控制中^[9-14]。例如, Qiao J F 等人^[10]提出一种基于模糊神经网络的自组织模糊控制(self-organizing fuzzy control, SOFC)方法,基于模糊神经网络自动获取模糊规则,提高了 DO 浓度控制的自适应能力与控制精度。周红标^[11]构建了一种自组织模糊神经网络(self-organizing fuzzy neural network, SOFNN)控制器,大大提高了 DO 浓度控制系统的稳定性与控制精度。

尽管基于神经网络建立的 DO 浓度控制器具有较好的自适应能力与较高的控制精度,但这些方法均采用传统的均方误差(mean square error, MSE)准则设计控制器。由于污水处理过程具有干扰频繁与不确定性强的特征,实际数据中往往存在较大的异常值,基于 MSE 的建模容易受到干扰。熵作为随机变量不确定度的度量^[15],近来被用作建模的性能指标,主要有最小误差熵(minimum error entropy, MEE)准则^[16]和最大相关熵(maximum correntropy criterion, MCC)准则^[17]两种形式。然而, MEE 准则计算负担大,且对误差的平均值不敏感。因此,选择基于相关熵建立控制器的性能指标。

基于以上分析,本文提出一种基于相关熵模糊神经网络(correntropy based fuzzy neural network, CFNN)的 DO 浓度在线控制方法。首先,构建了基于 CFNN 的控制器,通过梯度下降算法在线更新控制器参数,并在理论上分析了控制系统的稳定性。其次,选取 DO 浓度跟踪误差与误差变化率作为控制器的输入。最后,基于 BSM1,选择雨天、暴雨两种工况进行实验验证。

2 控制问题描述

考虑式(1)所示的非线性时变系统:

$$\begin{cases} x_{k+1} = f(x_k, u_k) + d_k \\ y_{k+1} = g(x_{k+1}) \end{cases} \quad (1)$$

其中, $x_k \in \mathbb{R}^n$ 为状态量, $u_k \in \mathbb{R}$ 为控制量, $y_k \in \mathbb{R}$ 为系统输出, $f(\cdot)$ 与 $g(\cdot)$ 为关于系统状态量与控制量的非线性函数, d_k 为系统干扰。

污水处理系统是一个非线性动态系统,由于函数 $f(\cdot)$ 与 $g(\cdot)$ 是未知的,很难通过建立精确的数学模型对 DO 浓度进行在线控制。因此,采用 FNN 逼近理想控制率,构建基于 CFNN 的在线控制系统,其结构如图 1 所示。




图 1 基于 CFNN 的在线控制系统结构

在图 1 所示的控制系统中,控制器的输入为系统跟踪误差 e 与误差变化率 Δe 。

$$e_k = r_k - y_k \quad (2)$$

其中, e_k 为 k 时刻污水处理过程中控制系统的跟踪误差, r_k 与 y_k 分别为 k 时刻 DO 浓度的设定值与系统实际输出值。控制量 u 为污水处理系统第五单元氧传递系数 K_{La5} 的增量, J 为控制器参数学习的性能指标。

3 基于 CFNN 的在线控制器设计

3.1 基于相关熵的性能指标

相关熵作为一种局部相似度量,表示任意两个随机变量之间的广义相关性,而且基于相关熵的准则被证明在分离异常值方面比 MSE 准则更有效^[18]。对

于任意两个随机向量 $\mathbf{x}$ 与 $\mathbf{y}$ ，其相关熵 $V(\mathbf{x}, \mathbf{y})$ 可以表示为：

$$V(\mathbf{x}, \mathbf{y}) = E[\kappa(\mathbf{x}, \mathbf{y})] \quad (3)$$

其中， $E[\cdot]$ 为数学期望， $\kappa(\cdot)$ 为任意 Mercer 核函数，这里选择高斯核函数作为相关熵的核函数，如下所示：

$$\kappa(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{y}\|^2}{2\sigma_g^2}\right) \quad (4)$$

其中， $\sigma_g > 0$ 为核宽度参数。

然而，在实际的控制器参数优化中，采用梯度下降算法的目标是求解最小误差。因此，采用相关熵诱导度量（correntropy induced metric, CIM）性能指标，对 CIM 进行最小化等同于求最大相关熵^[18]。

$$\text{CIM}(\mathbf{x}, \mathbf{y}) = (\kappa(0) - V(\mathbf{x}, \mathbf{y}))^{1/2} = \left(\kappa(0) - \frac{1}{K} \sum_{i=1}^K \kappa(x_i, y_i)\right)^{1/2} \quad (5)$$

其中， x_i 与 y_i 分别为向量 $\mathbf{x}$ 与 $\mathbf{y}$ 的第 i 个元素， K 为向量维度。

3.2 FNN 结构

模糊神经网络同时具有模糊逻辑的规则映射能力与神经网络的自学习能力，能够实现规则的在线提取以及相应参数的在线优化^[12]。采用如图 2 所示的 4 层结构的 FNN 设计控制器，跟踪 DO 浓度的设定值。该 FNN 包含输入层、隶属函数层、规则层以及输出层，网络的数学描述如下。




图2 模糊神经网络的拓扑结构

$$u = \mathbf{w}^\top \mathbf{v} = \sum_{j=1}^L w_j v_j \quad (6)$$

其中， u 为 FNN 的输出， $\mathbf{v} = [v_1, v_2, \dots, v_L] \in \mathbb{R}^L$ 为规则层的输出矩阵， $\mathbf{w} = [w_1, w_2, \dots, w_L]^\top \in \mathbb{R}^L$ 为连接规则

层与输出层的权重矩阵， $j=1, 2, \dots, L$ 为规则层的模糊规则数。其中，规则层的第 j 个神经元的输出 v_j 为：

$$v_j = \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_j\|^2}{\sigma_j^2}\right) / \sum_{j=1}^L \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_j\|^2}{\sigma_j^2}\right) \quad (7)$$

其中， $\mathbf{x} = [x_1, x_2]^\top$ 为 FNN 的输入向量， $\mathbf{c}_j = [c_{1,j}, c_{2,j}]^\top$ 与 $\sigma_j = [\sigma_{1,j}, \sigma_{2,j}]^\top$ 分别为第 j 个模糊规则 R_j 对应的隶属函数层的中心向量与宽度向量。

3.3 CFNN 在线学习算法

为了实现 FNN 控制器的参数的在线学习，将式 (5) 所示的性能指标改写为以下形式：

$$\min_{\boldsymbol{\theta}} J_k = \frac{1}{\sqrt{2\pi}\sigma_g} \left(1 - \exp\left(-\frac{e_k^2}{2\sigma_g^2}\right)\right) \quad (8)$$

其中， J_k 为 k 时刻的性能指标。令 $\boldsymbol{\theta} = [\mathbf{c}^\top, \boldsymbol{\sigma}^\top, \mathbf{w}^\top]^\top$ 为 FNN 的参数矩阵，其中 $\mathbf{c} = [c_1, c_2, \dots, c_L]^\top$ 与 $\boldsymbol{\sigma} = [\sigma_1, \sigma_2, \dots, \sigma_r]^\top$ 分别为 FNN 的中心矩阵与宽度矩阵。

采用梯度下降算法在线优化 FNN 控制器的参数：

$$\boldsymbol{\theta}_{k+1} = \boldsymbol{\theta}_k - \eta_0 \frac{\partial J_k}{\partial \boldsymbol{\theta}_k} \quad (9)$$

其中， $\eta_0 \in (0, 1)$ 表示 FNN 控制器参数的学习率。

$$\frac{\partial J_k}{\partial \boldsymbol{\theta}_k} = \frac{\partial J_k}{\partial e_k} \frac{\partial e_k}{\partial \boldsymbol{\theta}_k} \quad (10)$$

其中，

$$\frac{\partial J_k}{\partial e_k} = \frac{1}{\sqrt{2\pi}\sigma_g^3} \exp\left(-\frac{e_k^2}{2\sigma_g^2}\right) e_k \quad (11)$$

令 $\eta = \frac{\eta_0}{\sqrt{2\pi}\sigma_g^3}$ ，则式 (9) 可以被改写为：

$$\boldsymbol{\theta}_{k+1} = \boldsymbol{\theta}_k - \eta \exp\left(-\frac{e_k^2}{2\sigma_g^2}\right) e_k \frac{\partial e_k}{\partial \boldsymbol{\theta}_k} \quad (12)$$

基于以上分析，CFNN 控制器设计的主要步骤如下。

步骤一 初始化 CFNN 控制器参数。随机初始化网络参数 $\boldsymbol{\theta}$ ，设置 CFNN 的规则数 L 、网络参数学习率 η_0 以及 DO 浓度设定值。

步骤二 计算控制器的输入，即当前时刻 DO 浓度的跟踪误差 e_k 与误差变化率 Δe_k 。

步骤三 估计控制率，即 CFNN 的输出 u 。基于 BSM1 对 CFNN 进行训练，根据式 (6) 与式 (7)

计算网络输出。

步骤四 计算性能指标 J_k 的值, 并根据式 (12) 更新 CFNN 的参数。

步骤五 根据输出的控制率 u 更新 WWTP 系统的 K_{La5} , 若全部仿真数据运行完毕, 结束循环; 否则, 转到步骤二。

3.4 CFNN 稳定性分析

为了分析基于 CFNN 的控制系统的稳定性, 构造如下李雅普诺夫函数:

$$V_k = J_k = \frac{1}{\sqrt{2\pi}\sigma_g} \left(1 - \exp\left(\frac{-e_k^2}{2\sigma_g^2}\right) \right) \quad (13)$$

结合式 (13) 与式 (9) ~ (12) 可得:

$$\Delta V_k = \Delta J_k = \frac{1}{\sqrt{2\pi}\sigma_g} \left(\exp\left(\frac{e_k^2}{-2\sigma_g^2}\right) - \exp\left(\frac{e_{k+1}^2}{-2\sigma_g^2}\right) \right) = \quad (14)$$

$$\frac{1}{\sqrt{2\pi}\sigma_g} \exp\left(\frac{e_k^2}{-2\sigma_g^2}\right) \left(1 - \exp\left(\frac{e_{k+1}^2 - e_k^2}{-2\sigma_g^2}\right) \right)$$

令 $h_k = e_{k+1}^2 - e_k^2$, $\Delta e_k = e_{k+1} - e_k$, 则:

$$h_k = 2e_k \Delta e_k + \Delta e_k^2 \quad (15)$$

其中,

$$\begin{aligned} \Delta e_k &\cong \left(\frac{\partial e_k}{\partial \Theta_k} \right)^\top \Delta \Theta_k = \\ &-\eta \exp\left(\frac{e_k^2}{-2\sigma_g^2}\right) e_k \left(\frac{\partial e_k}{\partial \Theta_k} \right)^\top \frac{\partial e_k}{\partial \Theta_k} = \\ &-\eta \exp\left(\frac{e_k^2}{-2\sigma_g^2}\right) e_k \left(\frac{\partial y_k}{\partial \Theta_k} \right)^\top \frac{\partial y_k}{\partial \Theta_k} \end{aligned} \quad (16)$$

将式 (16) 代入式 (15) 可得:

$$h_k = e_k^2 \left(\left(1 - \eta \exp\left(\frac{e_k^2}{-2\sigma_g^2}\right) \left(\frac{\partial y_k}{\partial \Theta_k} \right)^\top \frac{\partial y_k}{\partial \Theta_k} \right) - 1 \right) \quad (17)$$

由于 $e_k^2 \geq 0$, 当 $0 < \eta < 2 / \left(\left(\frac{\partial y_k}{\partial \Theta_k} \right)^\top \frac{\partial y_k}{\partial \Theta_k} \right)$ 时,

$h(k) \leq 0$, 结合式 (14) 可知 $\Delta V_k \leq 0$, 根据李雅普诺夫稳定性定理, CFNN 控制系统稳定。

4 仿真与分析

为了验证基于 CFNN 的 DO 浓度在线控制系统的性能, 基于国际水协会 (International Water As-

sociation, IWA) 与欧盟科技合作组织 (European Co-operation in the Field of Scientific and Technical Research, COST) 开发的 BSM1 进行了实验研究。采用平方误差积分 (integral of squared error, ISE)、绝对误差积分 (integral of absolute error, IAE)、最大偏差 (maximal deviation from set point, $\text{Dev}^{\max}$) 3 个评价指标分析控制器的精度与稳定性^[19]。

$$\text{IAE} = \int_{t_0}^{t_f} |e| dt \quad (18)$$

$$\text{ISE} = \int_{t_0}^{t_f} e^2 dt \quad (19)$$

$$\text{Dev}^{\max} = \max \{|e|\} \quad (20)$$

其中, e 为 DO 浓度设定值 (用 S_o 表示) 与控制系统实际输出的 DO 浓度之间的误差。

4.1 实验设置

(1) 实验数据

BSM1 提供了干燥、雨天、暴雨 3 种天气工况下 14 天的污水入水数据, 采样周期为 15 min。为了评估 CFNN 控制器的控制精度与抗干扰能力, 本实验选取入水波动较大的雨天与暴雨工况数据进行测试。雨天工况的数据: 基于干燥天气数据, 在第 8~11 天增加了持续降雨过程。暴雨工况的数据: 基于干燥天气数据, 在第 9 天和第 11 天增加了突发暴雨事件, 入水流量大幅增加。

(2) 参数设置

CFNN 的模糊规则数 $L=6$, 参数学习率 $\eta_0=0.001$, 核宽度 $\sigma_g=1$ 。实验中, 分别考虑 DO 浓度设定值为固定值 ($S_o=2 \text{ mg} \cdot \text{L}^{-1}$) 与阶跃变化的值 ($S_o=1.8 \sim 2.2 \text{ mg} \cdot \text{L}^{-1}$) 两种情况。

4.2 结果分析

实验首先采用恒定的 DO 浓度设定值, 即 $S_o=2 \text{ mg} \cdot \text{L}^{-1}$ 。基于 BSM1 雨天与暴雨工况数据进行仿真, 采用前 7 天的数据进行训练, 采用后 7 天的数据进行验证。为了验证基于 CFNN 的 DO 浓度在线控制方法的性能, 将实验结果与 SOFC^[10]、SOFNN^[11]、直接自适应动态神经网络控制 (direct adaptive dynamic neural network control, DADNNC)^[12]等基于 MSE 准则的控制方法进行了比较。

图 3 与图 4 分别为雨天工况下基于 CFNN 的 DO 浓度跟踪控制结果与误差, 可以看出 CFNN 控

制器在第 8~11 天连续降雨的天气下仍具有较好的稳定性,能够有效地跟踪 DO 浓度设定值。由图 4 可以看出 CFNN 控制器的控制精度较高,在第 8 天工况突变的情况下,仍能维持较高的控制精度。图 5 给出了控制量 K_{La5} 的变化趋势,其变化曲线较为光滑,表明 CFNN 控制器参数的在线调整能够维持系统的稳定运行。




图3 DO 浓度跟踪控制效果(恒定设定值)




图4 DO 浓度的跟踪误差(恒定设定值)




图5 控制量变化曲线(恒定设定值)

表 1 给出了雨天和暴雨两种工况下不同控制器的性能比较。由表 1 可以看出,与其他基于 MSE 准则的控制器相比,在两种工况下 CFNN 控制器

都具有最低的 IAE、ISE 与 Dev^{max} 指标值,且结构较为紧凑。其中,ISE 指标值比其他方法至少下降了两个数量级,体现出 CFNN 控制器具有较高的稳定性。

表1 雨天和暴雨工况下不同控制器的性能比较
(恒定设定值)

天气	控制器	规则数	IAE	ISE	Dev^{max}
雨天	CFNN	6	3.2×10^{-3}	8.76×10^{-6}	7.56×10^{-3}
	SOFC ^[10]	10	$3.1 \times 10^{-2*}$	$7.26 \times 10^{-4*}$	$3.6 \times 10^{-2*}$
	SOFNN ^[11]	12	$4.2 \times 10^{-2*}$	$1.81 \times 10^{-4*}$	$1.12 \times 10^{-2*}$
	DADNNC ^[12]	6	$3.2 \times 10^{-2*}$	$3.95 \times 10^{-4*}$	$6.06 \times 10^{-2*}$
暴雨	CFNN	6	2.1×10^{-3}	1.75×10^{-6}	3.46×10^{-3}
	SOFC ^[10]	9	$2.5 \times 10^{-2*}$	$8.63 \times 10^{-4*}$	$9.7 \times 10^{-2*}$
	SOFNN ^[11]	12	$6.0 \times 10^{-2*}$	$1.19 \times 10^{-3*}$	$8.22 \times 10^{-2*}$

备注: * 表示原文中的结果,加粗表示最优指标

为了进一步验证 CFNN 控制器的性能,雨天工况下,设置 DO 浓度设定值为阶跃变化的值($S_o = 1.8 \sim 2.2 \text{ mg} \cdot \text{L}^{-1}$)。图 6 给出了 14 天的 DO 浓度跟踪控制效果,可以看出在 DO 浓度设定值呈阶跃变化时,CFNN 控制器能够快速跟踪设定值。图 7 为 DO 浓度的跟踪控制误差,大部分误差分布在区间 $[-0.002, 0.002]$,且在 S_o 变化时,误差较小,最大误差出现在突发降雨的第 8 天。因此,在 DO 浓度设定为阶跃变化的值时,CFNN 仍具有较高的控制精度。图 8 为控制量 K_{La5} 的变化曲线,可以看出在变 DO 浓度设定值控制方案下,控制量仍维持平稳变化,亦体现了 CFNN 控制器的稳定性。




图6 DO 浓度跟踪控制效果(变设定值)




图7 DO浓度的跟踪控制误差




图8 控制量变化曲线(变设定值)

表2给出了在雨天工况下, DO浓度设定值为阶跃变化的值时, CFNN、SOFC与DADNNC的控制效果。对比各个方法的控制结果可以看出, CFNN仍具有最低的IAE、ISE与 Dev^{max} 指标值, 且IAE指标值比另外两种方法下降了一个数量级。该方法 Dev^{max} 指标值与恒定So控制方案下的 Dev^{max} 指标值偏差较小, 表明CFNN控制器在DO浓度设定值变化时仍能维持稳定。基于以上结果分析, CFNN控制器在线跟踪控制DO浓度时具有较高的控制精度, 且控制器的稳定性与抗干扰能力较强。

表2 雨天工况下, DO浓度设定值为阶跃变化时不同控制器的性能比较

控制器	规则数/个	IAE	ISE	Dev^{max}
CFNN	6	2.1×10^{-3}	2.34×10^{-4}	7.6×10^{-3}
SOFC ^[10]	14	$2.2 \times 10^{-2*}$	$2.86 \times 10^{-4*}$	$3.5 \times 10^{-2*}$
DADNNC ^[12]	5	2.8×10^{-2}	9.7×10^{-4}	5.6×10^{-2}

备注: * 表示原文中的结果, 加粗表示最优指标

5 结束语

为了实现DO浓度的在线精准控制, 提出一种基于相关熵准则的模糊神经网络控制器, 建立了基

于跟踪误差相关熵的性能准则, 采用梯度下降算法在线优化控制器参数, 并在BSM1上进行了实验验证。基于CFNN的DO浓度在线控制方法具有以下特点。

(1) 构建了基于相关熵的性能指标, 相比MSE准则, 能够更有效地抑制异常值, 更适用于入水波动较大、干扰频繁的污水处理过程。

(2) 基于CFNN的DO浓度在线控制方法, 能够自适应调整控制器参数, 实时跟踪DO浓度设定值, 具有控制精度高、稳定性好的特点。

(3) 基于BSM1在雨天与暴雨两种工况下进行实验验证。实验结果表明, CFNN控制器与其他基于MSE准则的神经网络控制器相比, 控制精度更高, 且具有更强的抗干扰能力, 控制器稳定性好。

虽然基于CFNN的在线控制方法能够有效地控制DO浓度, 但没有考虑污水处理过程控制系统的经济指标。因此, 下一步的研究工作是考虑经济指标, 实现污水处理过程的稳定与低能耗运行。

参考文献:

- [1] DOMINIC S, SHARDT Y A W, DING S X, et al. An adaptive, advanced control strategy for KPI-based optimization of industrial processes[J]. IEEE Transactions on Industrial Electronics, 2016, 63(5): 3252-3260.
- [2] RUAN J J, ZHANG C, LI Y, et al. Improving the efficiency of dissolved oxygen control using an on-line control system based on a genetic algorithm evolving FWNN software sensor[J]. Journal of Environmental Management, 2017, 187: 550-559.
- [3] LI M H, HU S F, XIA J W, et al. Dissolved oxygen model predictive control for activated sludge process model based on the fuzzy c-means cluster algorithm[J]. International Journal of Control, Automation and Systems, 2020: 1-10.
- [4] SONG X L, ZHAO Y B, SONG Z Y, et al. Dissolved oxygen control in wastewater treatment based on robust PID controller[J]. International Journal of Modelling, Identification and Control, 2012, 15(4): 297-303.
- [5] SANTÍN I, BARBU M, PEDRET C, et al. Dissolved oxygen control in biological wastewater treatments with non-ideal sensors and actuators[J]. Industrial & Engineering Chemistry Research, 2019, 58(45): 20639-20654.
- [6] ELTAG K, ASLAMX M S, ULLAH R. Dynamic stability enhancement using fuzzy PID control technology for power system[J]. International Journal of Control, Automation and Systems, 2019, 17(1): 234-242.
- [7] BELCHIOR C A C, ARAÚJO R A M, LANDECK J A C. Dissolved oxygen control of the activated sludge wastewater treatment process using stable adaptive fuzzy control[J]. Computers & Chemical Engineering, 2012, 37: 152-162.
- [8] BO Y C, ZHANG X. Online adaptive dynamic programming based on echo state networks for dissolved oxygen control[J]. Applied Soft Computing, 2018, 62: 830-839.

- [9] QIAO J F, HOU Y, ZHANG L, et al. Adaptive fuzzy neural network control of wastewater treatment process with multiobjective operation[J]. Neurocomputing, 2018, 275: 383-393.
- [10] QIAO J F, ZHANG W, HAN H G. Self-organizing fuzzy control for dissolved oxygen concentration using fuzzy neural network[J]. Journal of Intelligent & Fuzzy Systems, 2016, 30(6): 3411-3422.
- [11] 周红标. 基于自组织模糊神经网络的污水处理过程溶解氧控制[J]. 化工学报, 2017, 68(4): 1516-1524.
- ZHOU H B. Dissolved oxygen control of wastewater treatment process using self-organizing fuzzy neural network[J]. CIESC Journal, 2017, 68(4): 1516-1524.
- [12] 张伟, 乔俊飞, 李凡军. 溶解氧浓度的直接自适应动态神经网络控制方法[J]. 控制理论与应用, 2015, 32(1): 115-121.
- ZHANG W, QIAO J F, LI F J. Direct adaptive dynamic neural network control for dissolved oxygen concentration[J]. Control Theory & Applications, 2015, 32(1): 115-121.
- [13] CHEN C S. Robust self-organizing neural-fuzzy control with uncertainty observer for MIMO nonlinear systems[J]. IEEE Transactions on Fuzzy Systems, 2011, 19(4): 694-706.
- [14] HAN H G, ZHANG L, LIU H X, et al. Multiobjective design of fuzzy neural network controller for wastewater treatment process[J]. Applied Soft Computing, 2018, 67: 467-478.
- [15] BESSA R J, MIRANDA V, GAMA J. Entropy and correntropy against minimum square error in offline and online three-day ahead wind power forecasting[J]. IEEE Transactions on Power Systems, 2009, 24(4): 1657-1666.
- [16] CHEN B D, MA R J, YU S Y, et al. Granger causality analysis based on quantized minimum error entropy criterion[J]. IEEE Signal Processing Letters, 2019, 26(2): 347-351.
- [17] LIU W, POKHAREL P P, PRINCIPE J C. Correntropy: properties and applications in non-gaussian signal processing[J]. Transactions on Signal Processing, 2007, 55(11): 5286-5298.
- [18] NAYYERI M, SADOOGHI YAZDI H, MASKOOKI A, et al. Universal approximation by using the correntropy objective function[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(9): 4515-4521.
- [19] ALEX J, BETEAU J F, COPP J B, et al. The COST simulation benchmark description and simulator manual[M]. Luxembourg: Office for Publications of the European Community, 2002.

[作者简介]



权利敏(1989-),女,北京工业大学信息学部博士生,主要研究方向为污水处理过程的建模与智能控制。



杨翠丽(1986-),女,博士,北京工业大学信息学部副教授,主要研究方向为神经网络和智能优化算法。



乔俊飞(1968-),男,博士,北京工业大学信息学部教授、博士生导师,国家杰出青年科学基金获得者,教育部新世纪优秀人才,主要研究方向为智能信息处理、智能控制理论与应用。