

# 基于自组织递归小波神经网络的污水处理过程多变量控制

苏尹<sup>1,2</sup> 杨翠丽<sup>1</sup> 乔俊飞<sup>1</sup>

**摘要** 污水处理过程 (Wastewater treatment process, WWTP) 是一个包含多个生化反应的复杂过程, 具有非线性和动态特性。因此, 实现污水处理过程的精准控制是一项挑战。为解决这个问题, 提出一种基于自组织递归小波神经网络 (Self-organized recurrent wavelet neural network, SRWNN) 的污水处理过程多变量控制。首先, 针对污水处理过程的动态特性, 根据小波基的激活强度设计一种自组织机制来动态调整递归小波神经网络控制器的结构, 提高控制的性能。然后, 采用结合自适应学习率的在线学习算法, 实现控制器的参数学习。此外, 通过李雅普诺夫稳定性定理证明此控制器的稳定性。最后, 采用基准仿真平台进行仿真验证, 实验结果表明, 此控制方法可以有效提高污水处理过程的控制绝对误差积分 (Integral of absolute error, IAE) 和积分平方误差 (Integral of squared error, ISE) 的精度。

**关键词** 神经网络控制, 污水处理过程, 自组织机制, 多变量控制

**引用格式** 苏尹, 杨翠丽, 乔俊飞. 基于自组织递归小波神经网络的污水处理过程多变量控制. 自动化学报, 2024, 50(6): 1199–1209

**DOI** 10.16383/j.aas.c220679

## Multivariate Control of Wastewater Treatment Process Based on Self-organized Recurrent Wavelet Neural Network

SU Yin<sup>1,2</sup> YANG Cui-Li<sup>1</sup> QIAO Jun-Fei<sup>1</sup>

**Abstract** The wastewater treatment process (WWTP) is a complex process containing multiple biochemical reactions with nonlinear and dynamic characteristics. Therefore, it is a challenge to achieve accurate control of the wastewater treatment process. To solve this problem, a multi-variable control of wastewater treatment process based on the self-organized recurrent wavelet neural network (SRWNN) is proposed. Firstly, to deal with the dynamicity of wastewater treatment process, according to the firing strength of the wavelet base, the self-organizing mechanism is designed to dynamically adjust the structure of the recurrent wavelet neural network controller to improve the control performance. Then, an online learning algorithm combined with adaptive learning rate is used to learn the parameters of controller. In addition, the stability of the controller is proved by the Lyapunov stability theorem. Finally, the benchmark simulation platform is used to conduct simulation. The experimental results show that this control method can effectively improve the integral of absolute error (IAE) and integral of squared error (ISE) of the wastewater treatment process.

**Key words** Neural network control, wastewater treatment process (WWTP), self-organized mechanism, multi-variable control

**Citation** Su Yin, Yang Cui-Li, Qiao Jun-Fei. Multivariate control of wastewater treatment process based on self-organized recurrent wavelet neural network. *Acta Automatica Sinica*, 2024, 50(6): 1199–1209

随着人口的增长和经济的发展, 全国水污染问

收稿日期 2022-08-29 录用日期 2023-05-18

Manuscript received August 29, 2022; accepted May 18, 2023  
国家自然科学基金 (61890930-5, 62021003, 61973010), 国家重点  
研发计划 (2021ZD0112302) 资助

Supported by National Natural Science Foundation of China (61890930-5, 62021003, 61973010) and National Key Research and Development Program of China (2021ZD0112302)

本文责任编辑 刘艳军

Recommended by Associate Editor LIU Yan-Jun

1. 北京工业大学信息学部计算智能与智能系统北京重点实验室  
北京 100124 2. 嘉兴大学信息科学与工程学院 嘉兴 314001

1. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Faculty of Information Technology, Beijing University of Technology, Beijing 100124 2. College of Information Science and Engineering, Jiaxing University, Jiaxing 314001

题日益严重, 水环境持续恶化<sup>[1]</sup>。污水处理过程 (Wastewater treatment process, WWTP) 能够去除污水中的污染物和难降解的有机物, 已经成为缓解水资源、解决水污染问题的重要方法<sup>[2-3]</sup>。污水处理过程包含复杂的生化反应, 难以建立精确的机理模型, 各个参数的动力学反应是非线性的, 同时是一个动态时变的过程。因此, 如何实现污水处理过程的精准控制是一项挑战。

近年来, 一些传统的控制方法如前馈控制<sup>[4]</sup> 和 PID 控制<sup>[5-7]</sup> 广泛应用于污水处理的控制。这些方法的结构简单、应用广泛, 但是针对复杂的污水处

理过程控制精度有限。为解决污水处理过程的非线性，提高控制精度，学者们提出一些智能控制方法。例如，Hoang 等<sup>[8]</sup>提出一种对冲代数方法对污水处理过程中溶解氧 (Dissolved oxygen, DO) 进行控制，实验结果表明该方法能够有效地跟踪控制 DO 浓度。许进超等<sup>[9]</sup>提出一种基于自组织模糊神经网络的 DO 控制方法，结果表明该方法的控制精度优于传统的控制方法。但是，实际的污水处理过程包含多个控制回路和控制变量，是一个典型的多变量控制过程<sup>[10-12]</sup>。以上方法仅考虑 DO 浓度的控制，因此，不能保证污水处理过程的高效稳定运行。

为保证污水处理过程的稳定运行，多变量控制方法引起人们的广泛关注。例如，乔俊飞等<sup>[13]</sup>提出一种基于知识的方法对污水处理过程进行优化控制。Vega 等<sup>[14]</sup>提出一种多目标模型预测控制方法对 DO 浓度和硝态氮 (Nitrate nitrogen, NO) 浓度进行控制。Han 等<sup>[15]</sup>提出一种基于模糊神经网络的多变量控制方法，实验结果证明能够有效地提高污水处理过程的控制精度。在这些方法中，神经网络控制由于其对非线性系统强大的自学习能力已经成为多变量控制的研究热点<sup>[16-18]</sup>。其中，递归小波神经网络结合递归神经网络的动态特性和小波分析的能力，具有较好的控制效果<sup>[19-20]</sup>。然而，控制器的结构是固定的，难以适应污水处理过程不同的操作条件。

神经网络控制器的结构会影响控制的性能，当网络结构过大时，虽然控制的性能更佳，但是耗时长；当网络结构过小时，虽然控制速度更快，但是控制的精度可能不足。因此，为自动调整神经网络控制器的结构，张伟等<sup>[21]</sup>提出一种基于规则无用率的结构修剪算法对模糊神经网络的结构进行调整。El-Sousy 等<sup>[22]</sup>提出一种结构增长的自组织递归模糊小波神经网络进行跟踪控制。Han 等<sup>[23]</sup>提出一种神经网络增长和删减机制调整控制器的结构。实验结果证明这些方法都能够有效地调整控制器的结构，提高控制精度。其中，增长和删减机制对神经元的衡量更加全面，因此在本文中选取其作为神经网络控制器的调整机制。

基于以上分析，针对污水处理过程的非线性和动态特性，为提高控制精度，本文提出一种基于自组织递归小波神经网络 (Self-organized recurrent wavelet neural network, SRWNN) 的污水处理过程控制方法。首先，设计基于神经元激活响度的小波节点自组织机制，基于该机制 SRWNN 能够在控制过程中自动调整网络的结构以适应不同的操作工况，提高网络的控制性能。此外，在参数学习过程中

设计自适应学习率，提高网络的学习速度。并且证明了控制器的稳定性，保证其在实际污水处理过程中的应用。最后，基于活性污泥污水处理基准仿真 1 号模型 (Benchmark simulation model No. 1, BSM1) 验证了方法的有效性。

## 1 污水处理过程

活性污泥法是污水处理过程最常用的方法，其流程如图 1 所示。活性污泥法包含生化反应池和二沉池两个部分。在生化反应池中，红色部分是缺氧区，主要完成反硝化反应过程；蓝色部分是好氧区，主要进行硝化反应过程。生物反硝化反应进行后，一部分污水通过内循环再次反硝化；另一部分在二沉池中沉淀。

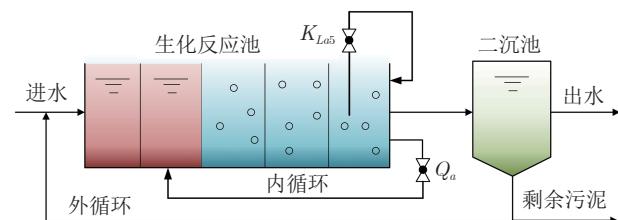


图 1 活性污泥法  
Fig. 1 Activated sludge method

在整个活性污泥法中，硝化反应和反硝化反应是核心过程。其中，溶解氧 (DO) 浓度在硝化反应中起着重要的作用；硝态氮 (NO) 浓度对反硝化反应的速度有很大的影响。此外，DO 浓度过高或者过低都会对反硝化反应产生抑制作用，从而影响 NO 浓度。因此，如何实现 DO 和 NO 的多变量精准控制，设计高性能的控制器对提高污水处理过程的效率非常重要。

根据活性污泥法的流程，DO 和 NO 的动力学方程为

$$\frac{dS_{NO,k}}{dt} = \frac{1}{V_k} ((Q_a + Q_r + Q_0)(Z_{k-1} - Z_k) + r_k V_k) \quad (1)$$

$$\begin{aligned} \frac{dS_{O,k}}{dt} = & \frac{1}{V_k} (Q_k S_{O,k-1} + r_k V_k + K_{Lak} V_k S_{O,sat} - \\ & K_{Lak} V_k S_{O,k} - Q_k S_{O,k}) \end{aligned} \quad (2)$$

其中， $Q_k$  和  $V_k$  是第  $k$  个反应池的流量和体积， $r_k$  是反应速率， $Q_a$  是第 2 个反应池的内部回流量， $Q_r$  和  $Q_0$  分别是污泥回流量和进水流量， $S_{O,k}$  是第  $k$  个反应池的 DO 浓度， $S_{O,sat}$  是 DO 的饱和值， $K_{Lak}$  是第  $k$  个反应池的氧气传递系数， $Z_k$  是第  $k$  个反应池的组分浓度， $S_{NO,K}$  是第  $k$  个反应池的 NO 浓度。

根据式(1)和生化反应的机理, DO 浓度取决于氧气传递系数, NO 浓度取决于内部回流量。因此, 选取  $K_{La5}$  和  $Q_a$  分别作为控制第 5 分区 DO 浓度和第 2 分区 NO 浓度的操作变量。

## 2 自组织递归小波神经网络控制器

在本节中, 针对污水处理过程的非线性和动态性, 为提高控制的精度, 提出一种自组织递归小波神经网络(SRWNN)对 DO 和 NO 浓度进行控制, 如图 2 所示。首先, 针对污水处理过程的非线性, 控制器采用一个多输入多输出的递归小波神经网络来提高控制的精度。然后, 设计基于激活强度的小波节点自组织机制以适应污水处理过程不同的工况。此外, 提出结合自适应学习率的参数学习算法。最后, 给出 SRWNN 控制器的稳定性证明。



图 2 控制框图

Fig. 2 Control block diagram

SRWNN 控制器的结构如图 3 所示, 其结构包括输入层、母小波层、小波层和输出层。其中 SRWNN 控制器的输入节点  $n$  和输出节点都是固定的, 分别为 4 和 2。假设 SRWNN 有  $q$  个小波节点, 在  $t$  时刻, SRWNN 的输入为

$$\mathbf{x}(t) = [e_{DO}(t), \Delta e_{DO}(t), e_{NO}(t), \Delta e_{NO}(t)] \quad (3)$$

其中,  $e_{DO}(t) = S_{DO, set}(t) - S_{DO}(t)$  和  $e_{NO}(t) =$

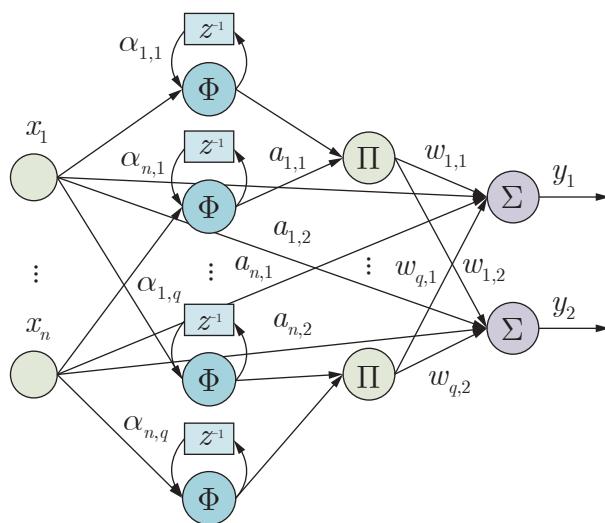


图 3 SRWNN 结构图

Fig. 3 The structure of SRWNN

$S_{NO, set}(t) - S_{NO}(t)$  分别是 DO 和 NO 浓度的误差,  $S_{DO, set}(t)$  和  $S_{DO}(t)$  是 DO 浓度的设定值和实际值,  $S_{NO, set}(t)$  和  $S_{NO}(t)$  分别是 NO 浓度的设定值和实际值,  $\Delta e_{DO}(t)$  和  $\Delta e_{NO}(t)$  是误差的变化量。

控制器的输出  $\mathbf{y}(t) = [y_1(t), y_2(t)] = [\Delta K_{La5}(t), \Delta Q_a(t)]$ , 且

$$y_k(t) = \sum_{j=1}^q w_{j,k}(t) u_j^{(3)}(t) + \sum_{i=1}^n a_{i,k}(t) x_i(t) \quad (4)$$

其中,  $a_{i,k}(t)$  是第  $i$  个输入对第  $k$  个输出的输出权值,  $w_{j,k}(t)$  是第  $j$  个小波节点对第  $k$  个输出的输出权值,  $u_j^{(3)}(t)$  是第  $j$  个小波节点的输出, 计算方式为

$$u_j^{(3)}(t) = \prod_{i=1}^n u_{i,j}(t) = \prod_{i=1}^n \phi\left(\frac{h_{i,j}(t) - b_{i,j}(t)}{c_{i,j}(t)}\right) \quad (5)$$

$$\phi(x) = -x \exp\left(-\frac{1}{2}x^2\right) \quad (6)$$

$$h_{i,j}(t) = x_i(t) + \alpha_{i,j}(t) u_{i,j}(t-1) \quad (7)$$

其中,  $u_{i,j}(t)$  是母小波层的输出,  $b_{i,j}(t)$  和  $c_{i,j}(t)$  分别是小波函数的平移和扩张系数,  $\phi(x)$  是选取的小波函数,  $\alpha_{i,j}(t)$  是反馈权值。

注 1. 污水处理过程是一个典型的非线性过程。递归小波神经网络能够以任意精度逼近非线性系统; 与此同时, 网络结合小波分析的能力, 有效地提高了神经网络的学习能力。因此, 针对污水处理过程的非线性, 本文选取递归小波神经网络作为控制器。

### 2.1 结构自组织机制

在实际的污水处理过程中包含多种工况, 例如晴天、雨天和暴雨等不同的天气条件工况。在不同的工况下, 进水流量和污染物的浓度都有所不同。固定结构的神经网络控制器无法适应不同的工况, 控制精度有限。此外, 神经网络的结构通常使用试凑法来选取, 虽然能够选取合适的网络结构但是耗时长。因此, 针对污水处理过程的动态特性, 提出一种基于激活强度的自组织机制来自动调整控制器的小波节点。

小波基的激活强度表达了输入属于相应小波基的强度。激活强度高的小波基表示其空间位置比激活强度低的小波基更接近输入。激活强度  $D_j(t)$  的可解释性强, 且计算简单, 因此被选取来调整 SRWNN 控制器小波神经元的数量, 具体为

$$D_j(t) = |u_j^{(3)}(t)| \quad (8)$$

其中,  $u_j^{(3)}(t)$  是第  $j$  个小波节点的输出. 则 SRWNN 自组织机制的具体过程如下.

1) 增长阶段. 当 SRWNN 控制器满足以下条件时, 增加一个新的小波节点.

$$D_j(t) > D_{\max} \quad (9)$$

其中,  $D_{\max}$  是人为设定的增长阈值. 新增的小波节点的初始参数设定为

$$\begin{cases} w_{q+1,k}(t) = (d_k(t) - y_k(t)) \left( u_{q+1}^{(3)}(t) \right)^{-1} \\ b_{i,q+1}(t) = r_1, c_{i,q+1}(t) = r_2 \\ \alpha_{i,q+1}(t) = r_3 \end{cases} \quad (10)$$

其中,  $d_k(t)$  是第  $k$  个输出节点对应的期望输出,  $u_{q+1}^{(3)}(t)$  是新增的第  $q+1$  个小波节点的输出,  $r_1, r_2, r_3$  是从  $[-1, 1]$  范围内随机选取的常数.

2) 修剪阶段. 小波节点的修剪阶段是为了删除多余的节点. 当满足以下条件时, 第  $l$  个节点将会被删除.

$$D_l(t) < D_{\min} \quad (11)$$

其中,  $D_{\min}$  是修剪阈值. 当第  $l$  个节点被删除时, 与其具有最短欧几里得 (Euclidean) 距离的第  $l'$  个节点的参数更新为

$$\begin{cases} w'_{l',k}(t) = w_{l',k}(t) + w_{l,k}(t)u_l(t)(u_{l'}(t))^{-1} \\ b'_{i,l'}(t) = b_{i,l'}(t), c'_{i,l'}(t) = c_{i,l'}(t) \\ \alpha'_{i,l'}(t) = \alpha_{i,l'}(t) \end{cases} \quad (12)$$

其中,  $w'_{l',k}(t), b'_{i,l'}(t), c'_{i,l'}(t), \alpha'_{i,l'}(t)$  是第  $l'$  个节点修剪后的参数,  $w_{l',k}(t), b_{i,l'}(t), c_{i,l'}(t), \alpha_{i,l'}(t)$  是第  $l'$  个节点修剪前的参数,  $w_{l,k}(t)$  是第  $l$  个节点修剪前的输出权值,  $u_l(t)$  和  $u_{l'}(t)$  分别是第  $l$  个节点和第  $l'$  个节点修剪前的输出.

**注 2.** 小波节点的增加和删除是同时进行的. 与固定结构的递归小波神经网络不同, SRWNN 的自组织机制能够根据不同的输入自动调节网络的结构, 从而提高控制的性能.

## 2.2 参数学习机制

为了对控制器的参数进行更新, 提出一种结合了自适应学习率的在线学习算法. SRWNN 的代价函数定义如下:

$$J(t) = \frac{1}{2}(e_{\text{DO}}^2(t) + e_{\text{NO}}^2(t)) \quad (13)$$

其中,  $e_{\text{DO}}^2(t)$  和  $e_{\text{NO}}^2(t)$  分别是 DO 和 NO 的跟踪误差. 根据梯度下降法, SRWNN 参数的更新式如下:

$$w_{j,k}(t+1) = w_{j,k}(t) - \lambda_w \frac{\partial J(t)}{\partial w_{j,k}(t)} \quad (14)$$

$$a_{i,k}(t+1) = a_{i,k}(t) - \lambda_a \frac{\partial J(t)}{\partial a_{i,k}(t)} \quad (15)$$

$$b_{i,j}(t+1) = b_{i,j}(t) - \lambda_b \frac{\partial J(t)}{\partial b_{i,j}(t)} \quad (16)$$

$$c_{i,j}(t+1) = c_{i,j}(t) - \lambda_c \frac{\partial J(t)}{\partial c_{i,j}(t)} \quad (17)$$

$$\alpha_{j,k}(t+1) = \alpha_{j,k}(t) - \lambda_\alpha \frac{\partial J(t)}{\partial \alpha_{j,k}(t)} \quad (18)$$

其中,  $\lambda_\Omega = \{\lambda_w, \lambda_a, \lambda_b, \lambda_c, \lambda_\alpha\}$  是自适应学习率.  $\Omega(t) = \{w(t), a(t), b(t), c(t), \alpha(t)\}$ , 自适应学习率定义如下

$$\lambda_\Omega = \frac{2}{\min_k \left( \frac{\partial e_k(t)}{\partial \Omega(t)} \right)^2} \quad (19)$$

式 (14) ~ (18) 中,  $J(t)$  对参数的偏导可以进一步计算如下

$$\frac{\partial J(t)}{\partial w_{j,k}(t)} = -e_k(t)u_j^{(3)}(t) \quad (20)$$

$$\frac{\partial J(t)}{\partial a_{i,k}(t)} = -e_k(t)u_i^{(2)}(t) \quad (21)$$

$$\frac{\partial J(t)}{\partial b_{i,j}(t)} = -\sum_{k=1}^2 e_k(t)w_{j,k}(t) \frac{u_j^{(3)}(t)}{u_{i,j}^{(2)}(t)} \phi' \left( -\frac{1}{c_{i,j}(t)} \right) \quad (22)$$

$$\begin{aligned} \frac{\partial J(t)}{\partial c_{i,j}(t)} = & -\sum_{k=1}^2 e_k(t)w_{j,k}(t) \frac{u_j^{(3)}(t)}{u_{i,j}^{(2)}(t)} \times \\ & \phi' \left( -\frac{h_{i,j}(t) - b_{i,j}(t)}{(c_{i,j}(t))^2} \right) \end{aligned} \quad (23)$$

$$\begin{aligned} \frac{\partial J(t)}{\partial \alpha_{i,j}(t)} = & -\sum_{k=1}^2 e_k(t)w_{j,k}(t) \frac{u_j^{(3)}(t)}{u_{i,j}^{(2)}(t)} \times \\ & \phi' \left( \frac{1}{c_{i,j}(t)} \right) u_{i,j}^{(2)}(t-1) \end{aligned} \quad (24)$$

其中,  $\phi'$  是  $t$  时刻  $\phi(x)$  对  $x$  的导数,  $e_1(t) = e_{\text{DO}}(t)$ ,  $e_2(t) = e_{\text{NO}}(t)$ .

## 2.3 基于 SRWNN 的多变量控制

根据以上的分析, 基于 SRWNN 的污水处理过程控制的流程图如图 4 所示, 主要步骤如下:

**步骤 1.** 参数初始化. SRWNN 的参数在范围  $(-1, 1)$  随机初始化, 设置增长阈值  $D_{\max}$  和修剪阈值  $D_{\min}$ .

**步骤 2.** 控制器参数学习. 根据式 (14) ~ (19) 更新控制器的参数.

**步骤 3.** 控制器结构学习. 如果小波节点的激

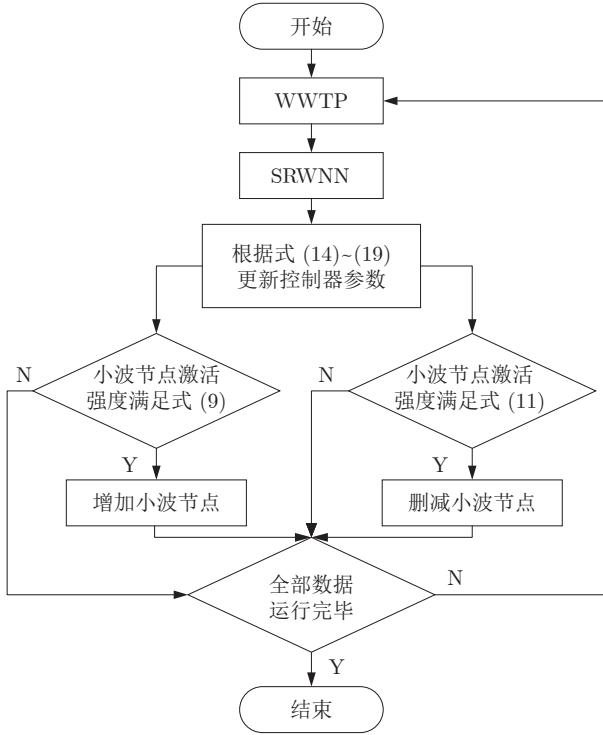


图 4 控制流程图

Fig. 4 The flow chart of control

活强度满足条件 (9), 则增加一个小波神经元, 新增的神经元参数根据式 (10) 初始化; 如果满足条件 (11), 则删减一个小波节点, 并根据式 (12) 调节参数。

**步骤 4.** 若全部数据运行完毕, 则结束循环; 否则, 转到步骤 2.

#### 2.4 计算复杂度

本部分分析了 SRWNN 的计算复杂度。首先对固定结构的计算复杂度进行分析, 由以上的介绍可知, SRWNN 的输入和输出节点是固定的, 分别为 4 和 2, 假设 SRWNN 的小波节点个数是固定的, 为  $q$ , 则 SRWNN 可调节参数的个数为  $N_s = 3 \times 4q + 2q + 2 \times 4$ , 即  $N_s = 14q + 8$ . 则 SRWNN 的计算复杂度为  $O(N_s^2)$ . 当控制器的小波节点发生变化时, 假设小波节点的个数由  $q$  变为  $q_1$ , 则此时  $N_s = 14q_1 + 8$ , 计算复杂度为  $O(N_s^2 + 1)$ .

#### 2.5 稳定性分析

为了验证 SRWNN 在实际应用中的可行性, 应用李雅普诺夫稳定性定理分析了 SRWNN 的稳定性。首先分析了固定结构的 SRWNN 的稳定性, 然后证明了小波节点变化时 SRWNN 的稳定性。具体分析过程如下。

**定理 1.** 假设 SRWNN 的隐藏节点为  $q$ , 当自适应学习率满足式 (19) 时, 固定结构的 SRWNN 控制器的稳定性能够保证。

**证明.** 构造控制器的李雅普诺夫函数如下:

$$V(t) = \frac{1}{2} (e_1^2(t) + e_2^2(t)) \quad (25)$$

其中,  $e_1(t)$  和  $e_2(t)$  分别是 DO 和 NO 浓度的跟踪误差. 则  $V(t)$  的变化值为

$$\begin{aligned} \Delta V(t) &= \frac{1}{2} \sum_{k=1}^2 (e_k^2(t+1) - e_k^2(t)) = \\ &\Delta V_1(t) + \Delta V_2(t) \end{aligned} \quad (26)$$

根据文献 [24], 控制误差的变化量如下:

$$\Delta e_k(t) = e_k(t+1) - e_k(t) \approx \left[ \frac{\partial e_k(t)}{\partial \Omega(t)} \right] \Delta \Omega(t) \quad (27)$$

根据式 (14) ~ (18), 可得

$$\Delta e_k(t) = -\lambda_\Omega e_k(t) \left[ \frac{\partial e_k(t)}{\partial \Omega_k(t)} \right]^2 \quad (28)$$

则有

$$\begin{aligned} \Delta V_k(t) &= \frac{1}{2} (2e_k(t)\Delta e_k(t) + \Delta e_k^2(t)) = \\ &\frac{1}{2} \left( -2\lambda_\Omega e_k^2(t) \left[ \frac{\partial e_k(t)}{\partial \Omega_k(t)} \right]^2 + \lambda_\Omega^2 e_k^2(t) \left[ \frac{\partial e_k(t)}{\partial \Omega_k(t)} \right]^4 \right) = \\ &- \frac{1}{2} e_k^2(t) \lambda_\Omega \left[ \frac{\partial e_k(t)}{\partial \Omega_k(t)} \right]^2 \left( 2 - \lambda_\Omega \left[ \frac{\partial e_k(t)}{\partial \Omega_k(t)} \right]^2 \right) \end{aligned} \quad (29)$$

可以看出, 当  $\lambda_\Omega \leq 2 / (\frac{\partial e_k(t)}{\partial \Omega(t)})^2$  时,  $V(t) > 0$ , 当学习率满足式 (19) 时,  $0 < V(t+1) < V(t)$ . 则当 SRWNN 结构固定时, 控制器是稳定的.  $\square$

**定理 2.** 在  $t$  时刻, 假设 SRWNN 控制器的小波节点个数发生变化, 当学习率满足式 (19) 时, SRWNN 控制器的稳定性能够保证.

**证明.** 在  $t$  时刻, 假设第  $l$  个小波节点被删除时, 小波节点的个数为  $q-1$ . 根据式 (12), SRWNN 的近似误差如下:

$$\begin{aligned} e'_k(t) &= d_k(t) - \sum_{j=1}^{q-1} w_{j,k}(t) u_j^{(3)}(t) - \sum_{i=1}^n a_{i,k}(t) x_i(t) = \\ &d_k(t) - \sum_{j=1, j \neq l'}^{q-1} w_{j,k}(t) u_j^{(3)}(t) - \\ &w_{l',k}(t) u_{l'}^{(3)}(t) - \sum_{i=1}^n a_{i,k}(t) x_i(t) = \end{aligned}$$

$$\begin{aligned}
d_k(t) - \sum_{j=1, j \neq l'}^{q-1} w_{j,k}(t) u_j^{(3)}(t) - w_{l',k}(t) u_{l'}^{(3)}(t) - \\
\sum_{j=1, j \neq l'}^{q-1} w_{l,k}(t) u_l^{(3)}(t) (u_{l'}^{(3)}(t))^{-1} u_{l'}^{(3)}(t) - \\
\sum_{i=1}^n a_{i,k}(t) x_i(t) = d_k(t) - \sum_{j=1}^q w_{j,k}(t) u_j^{(3)}(t) - \\
\sum_{i=1}^n a_{i,k}(t) x_i(t) = e_k(t)
\end{aligned} \tag{30}$$

此外, 假设 SRWNN 增加一个新的小波节点, 此时小波节点的个数为  $q+1$ . 根据式 (10), 控制误差计算如下:

$$\begin{aligned}
e'_k(t) = d_k(t) - \sum_{j=1}^{q+1} w_{j,k}(t) u_j^{(3)}(t) + \sum_{i=1}^n a_{i,k}(t) x_i(t) = \\
d_k(t) - \sum_{j=1}^q w_{j,k}(t) u_j^{(3)}(t) + \sum_{i=1}^n a_{i,k}(t) x_i(t) - \\
w_{q+1,k}(t) u_{q+1}^{(3)}(t) = \\
d_k(t) - (d_k(t) - y_k(t)) (u_{q+1}^{(3)}(t))^{-1} (u_{q+1}^{(3)}(t)) - \\
y_k(t) = 0
\end{aligned} \tag{31}$$

根据定理 1, 当学习率满足式 (19) 时, 本定理得证.  $\square$

**注 3.** 在定理 1 中, 固定结构的 SRWNN 的稳定性可以保证. 除此之外, 当小波节点的个数变化时, 控制器的稳定性分析如定理 2 所示. 根据定理 1 和定理 2 可知, 结合自组织机制的 SRWNN 控制器是稳定的, 确保了控制器在实际中的成功应用.

### 3 实验与分析

为验证 SRWNN 对污水处理过程的控制性能, 在 BSM1 平台上进行实验. 在实验过程中, 为更全面地验证控制性能, DO 浓度和 NO 浓度的设定值分别设定为常数值和变化值. SRWNN 的初始小波节点设置为 5. 此外, SRWNN 的阈值是通过试凑法选取的, 选取结果为  $D_{\max} = 0.5$ ,  $D_{\min} = 0.01$ .

采用绝对误差积分 (Integral of absolute error, IAE)、积分平方误差 (Integral of squared error, ISE) 和最大绝对误差 (Maximal derivation from set point, DEV\_MAX) 来评估控制性能. 其表达式如下:

$$IAE = \frac{1}{N} \sum_{t=1}^{t_{\max}} |d(t) - y(t)| \tag{32}$$

$$ISE = \frac{1}{N} \sum_{t=1}^{t_{\max}} (d(t) - y(t))^2 \tag{33}$$

$$DEV\_MAX = \max \{|d(t) - y(t)|\} \tag{34}$$

其中,  $N$  是样本个数,  $d(t)$  和  $y(t)$  分别是期望输出和实际输出. 越小的 IAE, ISE 和 DEV\_MAX 代表控制性能越好.

基于 BSM1 仿真平台, 选取了晴天和阴雨两种工况下 14 天的数据进行实验测试. 采样周期为 15 min. 与此同时, 采用后 7 天的实验结果来计算控制方法的 IAE, ISE 和 DEV\_MAX.

#### 3.1 小波函数的选取

在本节中, 首先分析了小波函数的选取对控制性能的影响. 本文以 Morlet 小波函数、Mexihat 小波函数和 Gaussian 小波函数为例, 三种函数的公式分别如式 (35) ~ (37) 所示

$$\phi_1(x) = \cos(1.75x) \exp\left(-\frac{1}{2}x^2\right) \tag{35}$$

$$\phi_2(x) = (1-x^2) \exp\left(-\frac{1}{2}x^2\right) \tag{36}$$

$$\phi_3(x) = -x \exp\left(-\frac{1}{2}x^2\right) \tag{37}$$

在晴天工况下, 三种小波函数的递归小波神经网络对 DO 浓度的控制效果如图 5 所示. 从图 5 中可以看出三种小波函数的控制性能有所区别, 且与其他两种方法相比, 本文选取的 Gaussian 小波函数的效果最好.

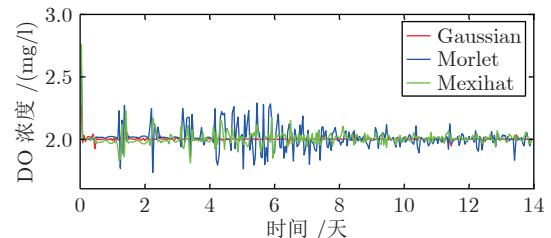


图 5 不同小波函数时 DO 控制结果

Fig.5 Control results of DO under different wavelet functions

在实际应用中, 选取小波函数主要从小波的对称性、正则性和支撑长度三个方面来考虑. 对称性主要应用在图像处理中, 可以避免相移, 简化计算; 正则性主要用来刻画函数的光滑程度, 一般正则性越长的小波函数光滑性越好; 支撑长度则一般与正则化相关, 支撑长度越长, 正则性越高.

#### 3.2 恒定设定值

在本节中, 首先采用恒定的 DO 浓度和 NO 浓

度设定值, 分别为  $S_{DO, set} = 2 \text{ mg/l}$  和  $S_{NO, set} = 1 \text{ mg/l}$ .

图 6 给出了晴天和阴雨两种工况下 SRWNN 小波节点的变化情况, 可以看出节点能够随着时间自动增加和删减, 并最终分别收敛到 3 和 4, 与定理 2 一致. 在晴天和阴雨两种不同的工况下, 小波节点的自组织机制都能够有效地调整控制器的结构, 使控制器适应不同的工况.

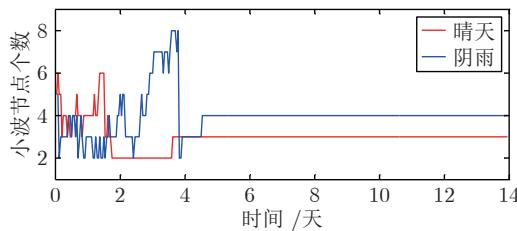


图 6 SRWNN 小波节点变化图

Fig.6 Change of SRWNN wavelet node

DO 浓度和 NO 浓度的控制结果如图 7~10 所示. 可以看出, 随着 SRWNN 结构的调整, 控制器的控制精度不断提高.

图 7 和图 8 分别给出了晴天工况下 DO 浓度和 NO 浓度的控制结果. 图 9 和图 10 分别给出了阴雨工况下 DO 浓度和 NO 浓度的控制结果. 在晴天工况下, 可以看出 SRWNN 的控制性能优于固定结构的 RWNN, 进一步验证了 SRWNN 小波节点自组织机制的有效性. 与此同时, SRWNN 的控制误差范围明显小于 RWNN, 证明了与 RWNN 相

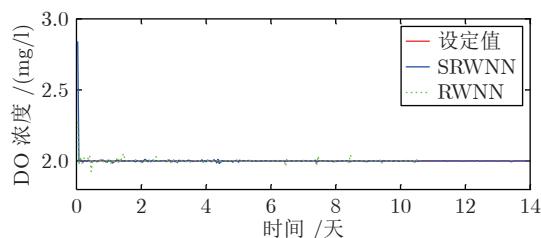


图 7 晴天工况下 DO 控制结果

Fig.7 Control results of DO under sunny condition

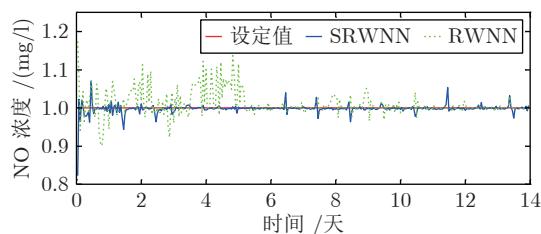


图 8 晴天工况下 NO 控制结果

Fig.8 Control results of NO under sunny condition

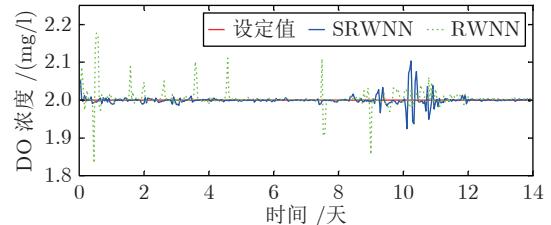


图 9 阴雨工况下 DO 控制结果

Fig.9 Control results of DO under cloudy and rain conditions

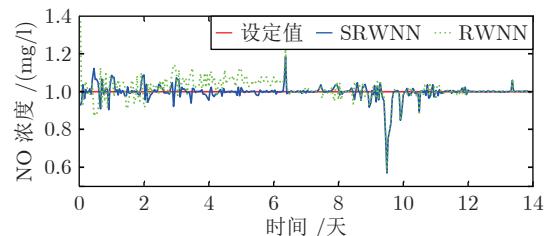


图 10 阴雨工况下 NO 控制结果

Fig.10 Control results of NO under cloudy and rain conditions

比, 在晴天工况下 SRWNN 具有更好的控制性能.

在阴雨工况下, SRWNN 的最大绝对控制误差出现在第 9 天到第 10 天左右, 与降雨引起入水的较大扰动有关. 图 11 和图 12 分别为 DO 和 NO 操作变量的变化图, 可以看出, 通过调整  $K_{La5}$  和  $Q_a$  的值能够进一步调节 DO 和 NO 浓度来跟踪设定值.

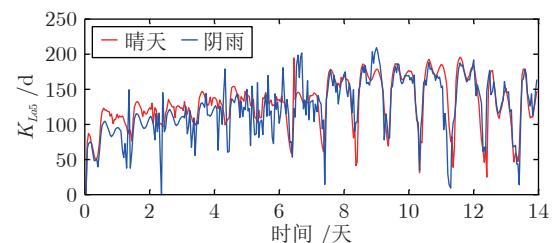


图 11  $K_{La5}$  变化曲线

Fig.11 The change curves of  $K_{La5}$

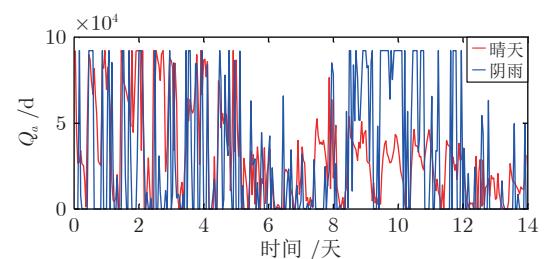


图 12  $Q_a$  变化曲线

Fig.12 The change curves of  $Q_a$

表 1 不同控制方法在恒定设定值时的性能比较  
Table 1 Performance comparison of different control methods at constant set-point

工况	控制器	No.	DO			NO		
			IAE	ISE	DEV_MAX	IAE	ISE	DEV_MAX
晴天	SRWNN	3	$5.66 \times 10^{-4}$	$1.63 \times 10^{-6}$	0.0087	0.0036	$7.61 \times 10^{-5}$	0.0114
	RWNN	5	0.0017	$3.26 \times 10^{-5}$	0.0526	0.0020	$3.06 \times 10^{-5}$	0.0540
	NNOMC	10	0.0390*	$5.31 \times 10^{-4}$ *	0.0725*	0.0490*	$7.18 \times 10^{-4}$ *	0.1630*
	RARFNNC	4	0.0073*	$1.61 \times 10^{-4}$ *	0.0104*	0.0126*	$2.83 \times 10^{-4}$ *	0.1050*
	DRFNNC	6	0.0079*	$1.82 \times 10^{-4}$ *	0.0154*	0.0085*	$3.25 \times 10^{-4}$ *	0.0176*
阴雨	SRWNN	4	0.0041	$1.75 \times 10^{-4}$	0.1042	0.0101	$9.80 \times 10^{-4}$	0.1291
	RWNN	5	0.0051	$2.21 \times 10^{-4}$	0.1434	0.0117	$1.40 \times 10^{-3}$	0.2244
	PID	—	0.0016	$1.90 \times 10^{-3}$	0.2038	0.0317	$8.23 \times 10^{-3}$	0.3233

注: “\*”表示原文中的结果, “—”表示无相应数据。

为了进一步验证 SRWNN 的控制性能, 在晴天工况下, 分别与固定结构的 RWNN, NNOMC<sup>[25]</sup>, RARFNNC<sup>[26]</sup> 和 DRFNNC<sup>[27]</sup> 方法进行比较。在阴雨工况下, 分别与 RWNN 和传统的 PID 方法进行比较。比较结果如表 1 所示, 包括 DO 浓度和 NO 浓度的 IAE, ISE 和 DEV\_MAX 的平均值, 其中 No. 表示神经网络控制器隐藏节点或者小波节点的个数。可以看出以上方法在设定值恒定不变时都有较高的精度。但是, 与其他控制方法相比, SRWNN 控制器具有最小的 IAE, ISE 和 DEV\_MAX, 控制精度更高。此外, 与固定结构的 RWNN 相比, SRWNN 在具有较少的小波节点的同时也能够获取较高的控制精度。由以上分析可知, 针对污水处理过程的非线性和动态特性, SRWNN 小波节点的自组织机制能够有效地提高控制的性能。

### 3.3 变化设定值

在本节中, 采用阶跃变化的设定值, DO 浓度和 NO 浓度的设定值分别如下

$$S_{DO, set} = \begin{cases} 1.8 \text{ mg/l}, & 8 \leq t < 9 \\ 2.2 \text{ mg/l}, & 9 \leq t < 10 \\ 2 \text{ mg/l}, & \text{其他} \end{cases} \quad (38)$$

$$S_{NO, set} = \begin{cases} 0.9 \text{ mg/l}, & 11 \leq t < 12 \\ 1.1 \text{ mg/l}, & 12 \leq t < 13 \\ 1 \text{ mg/l}, & \text{其他} \end{cases} \quad (39)$$

其中,  $t \in [0, 14]$ 。

在不同工况下, SRWNN 控制器小波节点的变化如图 13 所示。可以看出, 当 DO 和 NO 浓度的设定值变化的时候, 控制器小波节点的个数也能够跟随设定值的变化而自动增加和删减。在晴天和阴雨两种工况下, 小波节点的最终个数都为 3。这证明了

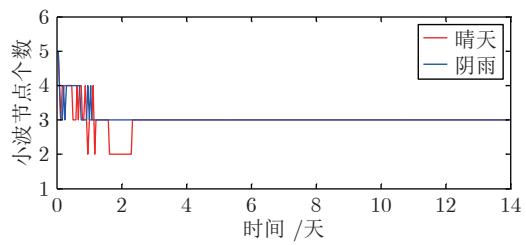


图 13 SRWNN 小波节点变化图  
Fig.13 Change of SRWNN wavelet node

在设定值变化时自组织机制也是能够收敛的, 与稳定性证明的定理 2 一致。

图 14 和图 15 分别给出了晴天工况下 DO 浓度和 NO 浓度的跟踪结果。从图中可以看出当设定值发生阶跃变化时, SRWNN 控制器仍然能够平稳地跟踪设定值。与固定结构的 RWNN 相比, SRWNN 的误差范围更小。

阴雨工况下的跟踪结果如图 16 和图 17 所示。受到降雨的入水扰动的影响, 阴雨工况下控制结果的波动较大。但是随着 SRWNN 控制器参数和结构的调整, DO 和 NO 浓度能够逐渐跟踪上其设定值。与固定结构的 RWNN 相比, SRWNN 可以自动调整控制器的结构以取得较高的控制精度。操作变量

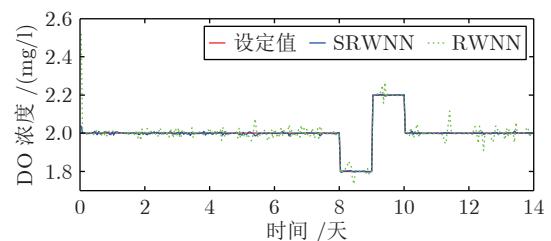


图 14 晴天工况下 DO 控制结果  
Fig.14 Control results of DO under sunny condition

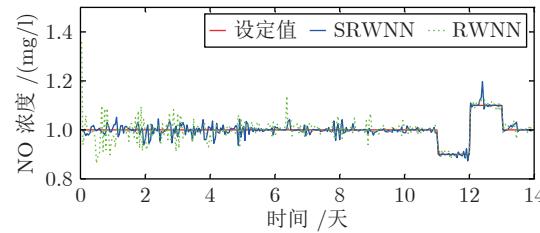


图 15 晴天工况下 NO 控制结果

Fig.15 Control results of NO under sunny condition

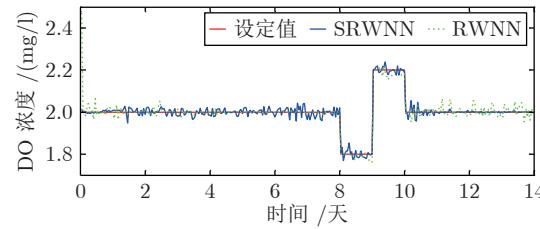


图 16 阴雨工况下 DO 控制结果

Fig.16 Control results of DO under cloudy and rain conditions

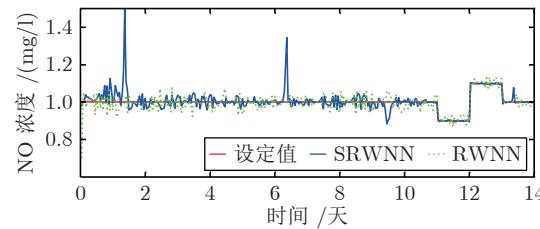
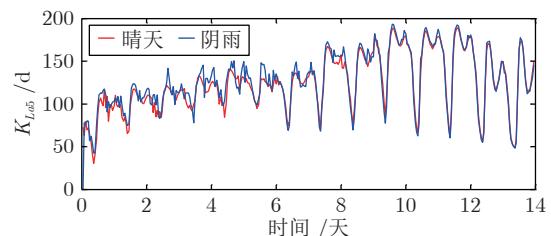
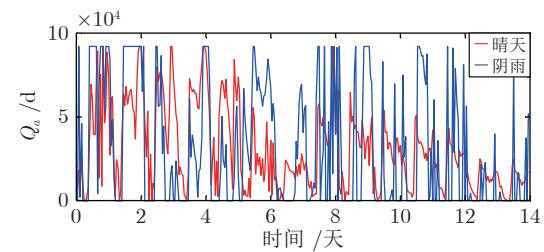


图 17 阴雨工况下 NO 控制结果

Fig.17 Control results of NO under cloudy and rain conditions

的变化曲线如图 18 和图 19 所示, 从图中可以看出在设定值变化的情况下, 控制器也能对操作变量进行有效的调整.

为了验证 SRWNN 控制器在设定值变化时的性能, 在晴天工况下, 将 SRWNN 与固定结构的

图 18  $K_{La5}$  变化曲线Fig.18 The change curves of  $K_{La5}$ 图 19  $Q_a$  变化曲线Fig.19 The change curves of  $Q_a$ 

RWNN 和 PID 控制方法进行比较; 在阴雨时, 与 RWNN 和 RFNNC<sup>[28]</sup> 进行比较. 表 2 归纳了比较的结果. 从表中可以看出, 与固定结构的 RWNN 相比, SRWNN 控制器能够根据不同的工况自动调整网络的结构, 获得更好的控制效果. 与此同时, 与其他控制方法相比, SRWNN 控制具有最小的 IAE, ISE 和 DEV\_MAX. 实验结果证明在设定值固定和变化的情况下, SRWNN 都能够对污水处理过程进行精准的控制.

#### 4 结束语

污水处理过程是一个典型的具有非线性的动态过程, 难以实现精准控制. 针对这个问题, 本文提出了一种基于 SRWNN 的多变量控制方法. 首先, 基于小波节点的激活强度设计了控制器的自组织机

表 2 不同控制方法在变化设定值时的性能比较

Table 2 Performance comparison of different control methods at changed set-point

工况	控制器	No.	DO			NO		
			IAE	ISE	DEV_MAX	IAE	ISE	DEV_MAX
晴天	SRWNN	3	0.0067	$3.68 \times 10^{-6}$	0.0156	0.0061	$1.64 \times 10^{-4}$	0.0067
	RWNN	5	0.0087	$2.62 \times 10^{-4}$	0.1156	0.0126	$2.30 \times 10^{-3}$	0.1116
	PID	—	0.0127	$2.38 \times 10^{-3}$	0.1038	0.0271	$4.90 \times 10^{-3}$	0.2184
阴雨	SRWNN	3	0.0047	$1.10 \times 10^{-4}$	0.0538	0.0065	$3.18 \times 10^{-4}$	0.1527
	RWNN	5	0.0069	$1.92 \times 10^{-4}$	0.0644	0.0088	$4.58 \times 10^{-4}$	0.1781
	RFNNC	—	0.0240*	$2.40 \times 10^{-3}$ *	0.0863	0.0260*	$1.00 \times 10^{-3}$ *	0.1881*

注: “\*”表示原文中的结果, “—”表示无相应数据.

制, 根据该机制, SRWNN 能够自动调整网络的结构以适应不同的工况。然后, 提出了一种结合自适应学习率的在线学习算法对控制器的参数进行调整。此外, 基于李雅普诺夫稳定性定理分析了控制方法的稳定性。实验结果证明 SRWNN 能够有效地控制污水处理过程。

在未来的工作中, 考虑动态调整 DO 和 NO 浓度的设定值, 平衡污水处理过程的水质和能耗。

## References

- 1 Tang W Z, Pei Y S, Zheng H, Zhao Y, Shu L M, Zhang H. Twenty years of China's water pollution control: Experiences and challenges. *Chemosphere*, 2022, **295**: Article No. 133875
- 2 Yang Cui-Li, Wu Zhan-Hong, Han Hong-Gui, Qiao Jun-Fei. Perspectives on optimal setting methods for municipal wastewater treatment processes. *Acta Automatica Sinica*, 2020, **46**(10): 2092–2108  
(杨翠丽, 武战红, 韩红桂, 乔俊飞. 城市污水处理过程优化设定方法研究进展. 自动化学报, 2020, **46**(10): 2092–2108)
- 3 Lizarralde I, Fernández-Arévalo T, Brouckaert C, Vanrolleghem P, Ikumi D S, Ekama G A, et al. A new general methodology for incorporating physico-chemical transformations into multi-phase wastewater treatment process models. *Water Research*, 2015, **74**: 239–256
- 4 Pang Nan-Quan. Optimization aeration control of reaction tank based on feed forward control model. *Industrial Control Computer*, 2015, **28**(1): 58–60  
(潘南全. 基于前馈控制模型的生化反应池曝气控制优化. 工控制计算机, 2015, **28**(1): 58–60)
- 5 Du S L, Yan Q S, Qiao J F. Event-triggered PID control for wastewater treatment plants. *Journal of Water Process Engineering*, 2022, **47**: Article No. 102765
- 6 Zeng Chun-Xia, Dong Zong-Zhe, He Tao. Application of fuzzy algebra PID control in dissolved oxygen control system of wastewater treatment. *Control and Instruments in Chemical Industry*, 2021, **48**(6): 528–534  
(曾春霞, 董宗哲, 何涛. 模糊代数 PID 控制在污水处理溶解氧控制系统的应用. 化工自动化及仪表, 2021, **48**(6): 528–534)
- 7 Liu Suo-Qing, Liu Shao-Hong, Li Jun-Hong, Peng Wei-Juan. Wastewater treatment PH value control based on fuzzy self-tuning PID cascade control. *Techniques of Automation and Applications*, 2019, **38**(2): 22–27  
(刘锁清, 刘少虹, 李军红, 彭伟娟. 基于模糊自整定 PID 串级控制的废水处理 PH 值控制. 自动化技术与应用, 2019, **38**(2): 22–27)
- 8 Hoang B L, Tien D N, Luo F, Nguyen P H. Dissolved oxygen control of the activated sludge wastewater treatment process using Hedge Algebraic control. In: Proceedings of the 7th International Conference on Biomedical Engineering and Informatics. Dalian, China: IEEE, 2014. 827–832
- 9 Xu Jin-Chao, Yang Cui-Li, Qiao Jun-Fei, Ma Shi-Jie. Dissolved oxygen concentration control method based on self-organizing fuzzy neural network. *CAAI Transactions on Intelligent Systems*, 2018, **13**(6): 905–912  
(许进超, 杨翠丽, 乔俊飞, 马士杰. 基于自组织模糊神经网络溶解氧控制方法研究. 智能系统学报, 2018, **13**(6): 905–912)
- 10 Wang D, Ha M M, Qiao J F. Data-driven iterative adaptive critic control toward an urban wastewater treatment plant. *IEEE Transactions on Industrial Electronics*, 2021, **68**(8): 7362–7369
- 11 Nawaz A, Arora A S, Yun C M, Lee J J, Lee M. Development of smart AnAmmOx system and its agile operation and decision support for pilot-scale WWTP. *Soft Computing Techniques in Solid Waste and Wastewater Management*. Amsterdam: Elsevier, 2021. 7423–7454
- 12 Han Hong-Gui, Zhang Lu, Lu Wei, Qiao Jun-Fei. Research on dynamic multiobjective intelligent optimal control for municipal wastewater treatment process. *Acta Automatica Sinica*, 2021, **47**(3): 620–629  
(韩红桂, 张璐, 卢薇, 乔俊飞. 城市污水处理过程动态多目标智能优化控制研究. 自动化学报, 2021, **47**(3): 620–629)
- 13 Qiao Jun-Fei, Han Gai-Tang, Zhou Hong-Biao. Knowledge-based intelligent optimal control for wastewater biochemical treatment process. *Acta Automatica Sinica*, 2017, **43**(6): 1038–1046  
(乔俊飞, 韩改堂, 周红标. 基于知识的污水生化处理过程智能优化方法. 自动化学报, 2017, **43**(6): 1038–1046)
- 14 Vega P, Revollar S, Francisco M, Martín J M. Integration of set point optimization techniques into nonlinear MPC for improving the operation of WWTPs. *Computers and Chemical Engineering*, 2014, **68**: 78–95
- 15 Han H G, Liu H X, Li J M, Qiao J F. Cooperative fuzzy-neural control for wastewater treatment process. *IEEE Transactions on Industrial Informatics*, 2021, **17**(9): 5971–5981
- 16 El-Sousy F F M, Abuhasel K A. Adaptive nonlinear disturbance observer using a double-loop self-organizing recurrent wavelet neural network for a two-axis motion control system. *IEEE Transactions on Industry Applications*, 2018, **54**(1): 764–786
- 17 Wang Tong, Qiu Jian-Bin, Gao Hui-Jun. Event-triggered adaptive neural network control for a class of stochastic nonlinear systems. *Acta Automatica Sinica*, 2019, **45**(1): 226–233  
(王桐, 邱剑彬, 高会军. 随机非线性系统基于事件触发机制的自适应神经网络控制. 自动化学报, 2019, **45**(1): 226–233)
- 18 Liu Y J, Li J, Tong S C, Chen C L P. Neural network control-based adaptive learning design for nonlinear systems with full-state constraints. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, **27**(7): 1562–1571
- 19 Lee C H, Chang H H. Output recurrent wavelet neural network-based adaptive backstepping controller for a class of MIMO nonlinear non-affine uncertain systems. *Neural Computing and Applications*, 2014, **24**(5): 1035–1045
- 20 Lin C H. A novel hybrid recurrent wavelet neural network control of permanent magnet synchronous motor drive for electric scooter. *Turkish Journal of Electrical Engineering and Computer Sciences*, 2014, **22**(4): 1056–1075
- 21 Zhang Wei, Qiao Jun-Fei, Li Fan-Jun. Direct adaptive dynamic neural network control for dissolved oxygen concentration. *Control Theory & Applications*, 2015, **32**(1): 115–121  
(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. 控制理论与应用, 2015, **32**(1): 115–121)
- 22 El-Sousy F F M, Abuhasel K A. Self-organizing recurrent fuzzy wavelet neural network-based mixed  $H_2/H_\infty$  adaptive tracking control for uncertain two-axis motion control system. In: Proceedings of the IEEE Industry Applications Society Annual Meeting. Addison, USA: IEEE, 2015. 1–14
- 23 Han H G, Zhang L, Hou Y, Qiao J F. Nonlinear model predictive control based on a self-organizing recurrent neural network. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, **27**(2): 402–415
- 24 Ku C C, Lee K Y. Diagonal recurrent neural networks for dynamic systems control. *IEEE Transactions on Neural Networks*, 1995, **6**(1): 144–156
- 25 Han Guang, Qiao Jun-Fei, Bo Ying-Chun. Feedforward neural network modeling and control for dissolved oxygen concentration. *Control Theory & Applications*, 2013, **30**(5): 585–591  
(韩广, 乔俊飞, 薄迎春. 溶解氧浓度的前馈神经网络建模控制方法. 控制理论与应用, 2013, **30**(5): 585–591)
- 26 Qiao J F, Han G T, Han H G, Chai W. Wastewater treatment control method based on a rule adaptive recurrent fuzzy neural network. *International Journal of Intelligent Computing and Cybernetics*, 2017, **10**(2): 94–110
- 27 Qiao J F, Han G T, Han H G, Yang C L, Chai W. Decoupling control for wastewater treatment process based on recurrent fuzzy neural network. *Asian Journal of Control*, 2019, **21**(3): 1270–1280
- 28 Han Gai-Tang, Qiao Jun-Fei, Han Hong-Gui. Wastewater treatment control method based on adaptive recurrent fuzzy neural network. *Control Theory and Applications*, 2016, **33**(9): 1252–

1258

(韩改堂, 乔俊飞, 韩红桂. 基于自适应递归模糊神经网络的污水处理控制. 控制理论与应用, 2016, 33(9): 1252–1258)



**苏 尹** 嘉兴大学信息科学与工程学院讲师. 2023年获得北京工业大学控制科学与工程专业博士学位. 主要研究方向为基于神经网络的城市污水处理过程预测及过程控制.

E-mail: suy@zjxu.edu.cn

**(SU Yin)** Lecturer at the College of Information Science and Engineering, Jiaxing University. She received her Ph.D. degree in control science and engineering from Beijing University of Technology in 2023. Her research interest covers neural network-based urban wastewater treatment process prediction and process control.)



**杨翠丽** 北京工业大学信息学部副教授. 2008年获得中国石油大学(东营)工学学士学位, 2010年获得天津大学理学硕士学位, 2014年获得香港城市大学博士学位. 主要研究方向为计算智能, 污水处理过程的建模与控制. E-mail: clyang5@bjut.edu

**(YANG Cui-Li)** Associate professor at the Faculty of

Information Technology, Beijing University of Technology. She received her bachelor degree from China University of Petroleum (Dongying) in 2008, master degree from Tianjin University in 2010, and Ph.D. degree from City University of Hong Kong, Hong Kong, China, in 2014. Her research interest covers computational intelligence, and modeling and control for wastewater treatment process.)



**乔俊飞** 北京工业大学信息学部教授. 分别于1992年和1995年获得辽宁工业大学控制工程学士和硕士学位, 1998年获得东北大学博士学位. 主要研究方向为神经网络, 智能系统, 自适应系统和过程控制. 本文通信作者. E-mail: adqiao@bjut.edu.cn

**(QIAO Jun-Fei)** Professor at the Faculty of Information Technology, Beijing University of Technology. He received his bachelor and master degrees in control engineering from Liaoning Technical University in 1992 and 1995, respectively, and his Ph.D. degree from Northeastern University in 1998. His research interest covers neural networks, intelligent systems, self-adaptive systems, and process control. Corresponding author of this paper.)