

DOI: 10.11992/tis.201801019

网络出版地址: <http://kns.cnki.net/kcms/detail/23.1538.tp.20180428.1354.004.html>

基于自组织模糊神经网络溶解氧控制方法研究

许进超^{1,2}, 杨翠丽^{1,2}, 乔俊飞^{1,2}, 马士杰^{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: 针对污水处理过程中溶解氧浓度难以控制的问题, 提出了一种基于自组织模糊神经网络 (self-organizing fuzzy neural network, SOFNN) 的溶解氧 (dissolved oxygen, DO) 控制方法。首先, 采用激活强度和神经元重要性两个评判标准, 来判断神经元对网络的贡献及活跃程度。然后, 对不活跃的神经元进行删减, 以此来对神经网络结构进行自适应的调整, 从而满足实际控制要求, 提高控制精度。其次, 采用梯度下降算法对 SOFNN 神经网络的各个参数进行实时调整, 以保证网络的精度。最后, 将该自组织方法用在 Mackey-Glass 时间序列预测中, 结果表明所提出的自组织模糊神经网络具有较好的预测效果; 同时将所提出的 SOFNN 方法在 BSM1 仿真平台上进行实验验证。结果表明, 所提出的自组织模糊神经网络控制方法能够对溶解氧浓度进行较好地控制, 具有一定的自适应能力。

关键词: 污水处理; 溶解氧; 过程控制; 神经网络; 自组织

中图分类号: TP183 **文献标志码:** A **文章编号:** 1673-4785(2018)06-0905-08

中文引用格式: 许进超, 杨翠丽, 乔俊飞, 等. 基于自组织模糊神经网络溶解氧控制方法研究 [J]. 智能系统学报, 2018, 13(6): 905-912.

英文引用格式: XU Jinchao, YANG Cuili, QIAO Junfei, et al. Dissolved oxygen concentration control method based on self-organizing fuzzy neural network[J]. CAAI transactions on intelligent systems, 2018, 13(6): 905-912.

Dissolved oxygen concentration control method based on self-organizing fuzzy neural network

XU Jinchao^{1,2}, YANG Cuili^{1,2}, QIAO Junfei^{1,2}, MA Shijie^{1,2}

(1. Faculty of Information Technology, Beijing University of technology, Beijing 100124, China; 2. Beijing Key Laboratory of Computational Intelligence and Intelligence System, Beijing 100124, China)

Abstract: It is difficult to control the dissolved oxygen (DO) concentration in wastewater treatment processes. To solve this problem, this paper proposes a dissolved oxygen control method based on a self-organizing fuzzy neural network (SOFNN). First, two judging criteria, firing strength and neuron importance, were used to determine the contribution and activity of neurons to the network. Then the inactive neurons were deleted to adjust the structure of the neural network to adaptively meet the actual control requirements and improve control accuracy. Second, a gradient descent algorithm was used to update the SOFNN parameters to ensure accuracy of the neural network. Finally, the proposed algorithm was used for the Mackey-Glass time series prediction, and the results showed that the proposed SOFNN had better prediction performance. Furthermore, the proposed SOFNN method was used on the benchmark simulation model no.1 (BSM1). The results indicate that the proposed SOFNN controller can achieve a better control effect for the DO control and has a good adaptive ability.

Keywords: wastewater treatment; dissolved oxygen; process control; neural network; self-organization

污水处理过程是一个复杂的生化反应过程,

伴随有物理化学反应、生化反应、相变过程及物质与能量的转化和传递过程, 建模困难, 导致其过程控制更加困难^[1]。而在污水处理过程中, 溶解氧浓度 (DO) 是最重要的控制参数。溶解氧浓

收稿日期: 2018-01-11. 网络出版日期: 2018-05-03.

基金项目: 国家自然科学基金项目 (61533002, 61603012); 北京市教育委员会科研计划项目 (KM201710005025).

通信作者: 许进超. E-mail: winadream@163.com.

度不足或过量都会对微生物的生存环境带来一定的影响。溶解氧浓度较低时会导致丝状菌的大规模繁殖,最终导致污泥膨胀,使得分解效果降低。相反,溶解氧浓度过高时,会破坏微生物的絮凝效果,使得悬浮固体沉降性变差,曝气能耗增加^[2]。因此为了保证出水指标满足污水处理过程的标准,溶解氧的浓度必须控制在一定的范围内。

针对污水处理过程中溶解氧的控制,许多学者进行了大量研究。其中经典的 PID 控制由于其简单的设计而被广泛应用。Wahab 等^[3]提出了基于污水处理过程的多变量 PID 控制,实现了对溶解氧的控制,并且对 PID 控制器的参数进行优化;Vrecko^[4]等提出了一种结合 PID 及前馈控制方法来溶解氧浓度进行控制。然而, PID 控制器的控制参数选择需要大量的经验知识,选择过程较为繁琐,而且在实际应用中, PID 控制器普遍存在控制精度较低的问题。同时,传统的 PID 控制器受其自身特点的限制,使得其针对污水处理过程这样一个非线性、大时变过程,并不能取得较好的控制效果^[5-7]。

基于此,许多学者对非线性系统的智能控制方法进行了大量研究。其中神经网络以其强大的自学习、自适应及非线性逼近能力,而受到了广泛关注。刘等^[8]将自适应模糊神经网络控制器应用到活性污泥模型中 DO 溶度的控制中。结果表明,该控制器具有较强的鲁棒性,获得了较好的控制效果;Huang 等^[9]将模糊神经网络控制方法应用到生物膜污水处理过程的曝气量控制过程中,取得了较好的控制效果;付等^[10]将模糊神经网络策略应用到污水基准仿真平台 BSM1 中实现了对 DO 浓度的控制。大量研究结果表明,以神

经网络为主的智能控制方法能够有效地适用于污水处理这样的非线性大滞后过程中。然而,对于一般的神经网络而言,其结构固定,使得其难以适应复杂多变的环境。基于此,如何针对特定问题自动调整神经网络结构一直是国内外研究的热点问题^[11-12]。

针对以上污水处理过程中 DO 浓度的跟踪控制存在的问题,文中提出了一种基于自组织模糊神经网络的溶解氧浓度控制方法。该自组织模糊神经网络利用激活强度和神经元重要性来判定模糊神经网络规一化层神经元的重要程度,从而对神经元进行增加和删减,以此来自动调整模糊神经网络的结构,防止网络结构出现冗余或不足。同时为保证网络的收敛性,文中采用梯度下降算法对神经网络的中心、宽度和权值进行训练。最后将该算法应用到 Mackey-Glass 时间序列预测及污水处理过程基准仿真平台 BSM1 中,实验结果表明所提出的自组织模糊神经网络相较于其他方法,具有较好的预测和控制效果,证明了该方法的有效性。

1 BSM1 模型

BSM1 是欧盟科学技术合作组织 (COST) 和国际水协会 (IWAQ) 合作提出的基准仿真模型^[13]。其总体布局如图 1 所示。该模型为测试污水处理过程控制策略和方法提供了一个验证平台。BSM1 模型主要由两部分组成:生化反应池和二沉池。其中生化反应池包含 5 个单元,前两个单元为厌氧区,其余为好氧区。在 BSM1 中, DO 的控制主要是通过控制生化反应池第 5 分区 K_{La5} 来实现的。

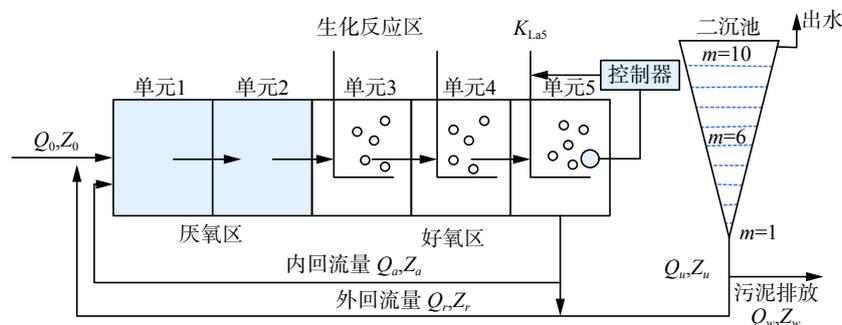


图 1 BSM1 布局示意图

Fig. 1 The overall layout of BSM1

2 SOFNN 控制器设计

2.1 控制系统结构

本论文应用自组织模糊神经网络控制好氧区

第 5 分区的 DO 浓度。图 2 为基于自组织模糊神经网络的溶解氧浓度控制器整体结构。

在控制系统中,控制器输入为 $e(k)$ 和 $e_c(k)$, 其可表示为

$$e(k) = y_d(k) - y(k)$$

$$e_c(k) = e(k) - e(k-1)$$

式中: $e(k)$ 表示溶解氧浓度的实际值与期望值的误差量; $e_c(k)$ 表示误差变化量; $y_d(k)$ 和 $y(k)$ 分别表示控制系统中溶解氧的期望值及控制系统的实际输出值。

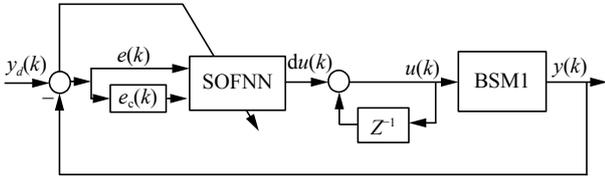


图 2 基于自组织模糊神经网络的溶解氧控制器结构框图

Fig. 2 The block diagram of the dissolved oxygen control system based on the fuzzy neural network

控制器的输出为 $du(k)$, 即控制量的增量。由于在 BSM1 溶解氧浓度控制系统中, 是通过控制生化反应池第五分区的氧传递系数 K_{La5} 来控制溶解氧浓度的, 所以这里的 $du(k)$ 即为 K_{La5} 的增量。

2.2 模糊神经网络结构

模糊神经网络是神经网络与模糊逻辑系统的结合体, 它综合了两者的优点。一般而言, 模糊神经网络主要由输入层、RBF 层、归一化层和输出层组成, 其拓扑结构如图 3 所示^[4]。其中 RBF 层第 j 个神经元的内部结构如图 4 所示。

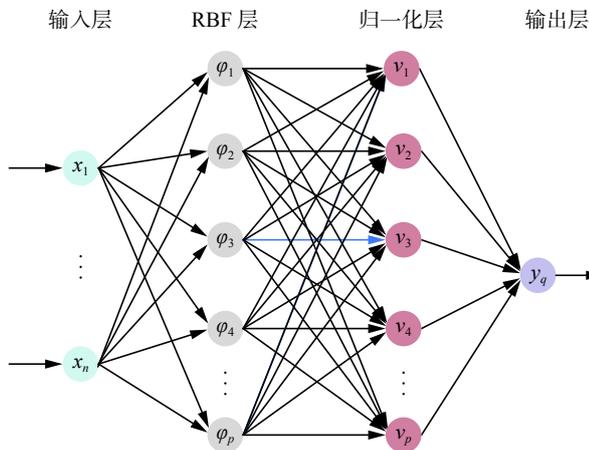


图 3 模糊神经网络拓扑结构

Fig. 3 The structure of fuzzy neural network

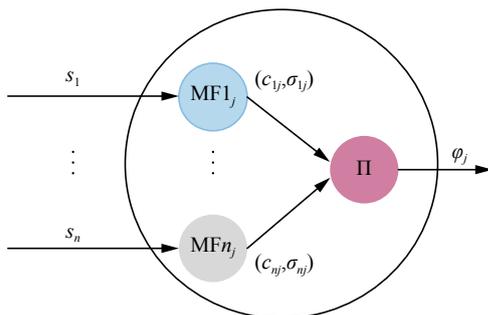


图 4 RBF 层第 j 个神经元的结构

Fig. 4 The j th neural structure of the RBF layer

第 1 层为输入层, 只起到信息传递的作用。该层共有 n 个神经元, 代表 FNN 的输入变量的个数。其输出表达式为

$$s_i = x_i$$

式中: $i=1, 2, \dots, n$; s_i 表示第 i 个神经元的输出; 且输入变量为 $\mathbf{x} = [x_1 \ x_2 \ \dots \ x_n]$ 。

第 2 层为 RBF 层, 该层的功能是对输入量进行模糊化处理, 在这里选取 RBF 神经元作为隶属函数进行模糊化, 隶属函数选用为高斯函数。该层第 j 个神经元的输入为 $\mathbf{s} = [s_1 \ s_2 \ \dots \ s_n]$ 。 \mathbf{c}_j 和 σ_j 分别表示第 j 个 RBF 神经元的中心和宽度, 具体表示为 $\mathbf{c}_j = [c_{1j} \ c_{2j} \ \dots \ c_{nj}]$ 和 $\sigma_j = [\sigma_{1j} \ \sigma_{2j} \ \dots \ \sigma_{nj}]$ 。RBF 层共有 p 个神经元, 该层第 j 个神经元的输出表达式为

$$\varphi_j = \exp\left(-\sum_{i=1}^n \frac{(u_i - c_{ij})^2}{2\sigma_{ij}^2}\right)$$

式中: $i=1, 2, \dots, n$; $j=1, 2, \dots, p$; c_{ij} 和 σ_{ij} 分别表示第 j 个神经元的第 i 个隶属函数的中心和宽度。

第 3 层为规一化层, 该层的神经元数与 RBF 层相同, 有 p 个神经元。该层第 l 个神经元输出为

$$v_l = \frac{\varphi_l}{\sum_{j=1}^p \varphi_j} = \frac{\exp\left(-\sum_{i=1}^n \frac{(u_i - c_{ij})^2}{\sigma_{ij}^2}\right)}{\sum_{j=1}^p \exp\left(-\sum_{i=1}^n \frac{(u_i - c_{ij})^2}{\sigma_{ij}^2}\right)}$$

式中: $j=1, 2, \dots, p$; $l=1, 2, \dots, p$; v_l 表示第 l 个神经元输出。

第 4 层为输出层, 该层的功能是解模糊, 这里采用重心法来对其进行进行归一化处理, 其输出表达式为

$$y_q = \sum_{l=1}^p w_{lq} v_l = \frac{\sum_{l=1}^p w_{lq} \exp\left(-\sum_{i=1}^n \frac{(u_i - c_{ij})^2}{\sigma_{ij}^2}\right)}{\sum_{j=1}^p \exp\left(-\sum_{i=1}^n \frac{(u_i - c_{ij})^2}{\sigma_{ij}^2}\right)}$$

式中: w_l 表示规一化层第 l 个神经元与输出层神经元之间的连接权值; y 表示网络输出。

2.3 模糊神经网络在线学习

模糊神经网络的在线学习主要包括结构调整和参数学习两部分。结构学习采用增长-修剪算法, 参数学习采用梯度下降算法。

2.3.1 结构增长算法

利用激活强度^[15]作为结构增长的判断准则。激活强度定义公式如式 (1) 所示。激活强度大小表明该神经元对网络的贡献。激活强度越大, 表明该神经元对网络的贡献越大; 反之, 则说明贡献较小。当输入数据对 RBF 层中所有神经元的

激活强度的最大值仍小于设定的增长阈值时,表明当前的规则无法对新数据进行有效覆盖,需要增加神经元以满足当前控制环境的要求。

$$AI_j = \exp\left(-\sum_{i=1}^n \frac{(u_i - c_{ij})^2}{2\sigma_{ij}^2}\right) \quad (1)$$

最大激活强度为

$$I_g = \arg \max_{1 \leq j \leq p(t)} AI_j \quad (2)$$

式中: $j=1,2,\dots,p$; $p(t)$ 表示当前的归一化层神经元数。

若 $I_g < I_{\text{gth}}$, 则满足增长条件,需增加一个神经元,即 $p(t+1) = p(t) + 1$; 同时新增神经元参数设置为

$$c_{\text{new}} = \frac{1}{2}(c_g + x(t)) \quad (3)$$

$$\sigma_{\text{new}} = \sigma_g \quad (4)$$

$$w_{\text{new}} = \frac{y_d - y}{\exp\left(-\sum_{i=1}^k \frac{(x(t) - c_{\text{inew}})^2}{2\sigma_{\text{inew}}^2}\right)} \quad (5)$$

式中: c_{new} 、 σ_{new} 和 w_{new} 分别表示新增神经元的参数; g 表示距离当前样本欧式距离最小的神经元; c_g 、 σ_g 为神经元 g 的中心和宽度; y_d 和 y 分别为期望输出和网络输出。

2.3.2 结构修剪算法

在实际的生物细胞中,神经元并不是总处于一个活跃状态,一直不活跃的神经元终究会走向衰亡。同时为避免网络结构过度增长,避免网络结构出现冗余的现象,本文采用了一种基于神经元重要性的网络在线修剪算法^[16]。该算法的思想为:初始条件下每个神经元的重要性为 1,并设置不活跃阈值 ρ 。每次计算每个神经元的激活强度,若激活强度小于设定的不活跃阈值 ρ 时,说明该神经元对输出的贡献较小,可以忽略并将该神经元进行一次重要性衰减,其计算公式由式(6)表达。当 t 时刻满足删减条件(7)时,则删除该神经元。

$$I_k(t+1) = \begin{cases} I_k(t) \exp(-\tau), & AI_k < \rho \\ I_k(t), & AI_k \geq \rho \end{cases} \quad (6)$$

$$I_k \leq I_{\text{cth}} \quad (7)$$

式中: I_k 表示第 k 个神经元的重要性,初始条件下为 1; $\rho \in (0,1)$ 是预先设定的不活跃阈值; τ 表示衰减常数; $I_{\text{cth}} \in (0,1)$ 为预先设定的删减阈值。这里 $\rho = 0.01$, $I_{\text{cth}} = 0.01$ 。

为保证神经网络输出稳定,减少删除神经元后对网络的影响,这里参考文献[14]对神经网络参数进行补偿,具体参数设置如下:

$$c'_h = c_h \quad (8)$$

$$\sigma'_h = \sigma_h \quad (9)$$

$$w'_h = \frac{w_h \exp\left(-\sum_{i=1}^k \frac{(x(t) - c_{ih})^2}{2\sigma_{iq}^2}\right) + w_s \exp\left(-\sum_{i=1}^k \frac{(x(t) - c_{is})^2}{2\sigma_{is}^2}\right)}{\exp\left(-\sum_{i=1}^k \frac{(x(t) - c_{ih})^2}{2\sigma_{ih}^2}\right)} \quad (10)$$

$$c'_s = 0 \quad (11)$$

$$\sigma'_s = 0 \quad (12)$$

$$w'_s = 0 \quad (13)$$

式中: s 表示被修剪的神经元; h 表示距离神经元 s 欧式距离较小的神经元; c_h 和 c'_h 、 σ_h 与 σ'_h 、 w_h 和 w'_h 分别是神经元 h 调整前后的参数; c'_s 、 σ'_s 和 w'_s 分别是被修剪神经元调整后的参数; $x(t)$ 表示当前输入样本。

2.3.3 神经网络参数学习

在模糊神经网络参数训练中,采用梯度下降算法,通过该算法对网络的中心值、宽度值和权值进行更新。

在参数训练过程中,首先定义一个目标函数:

$$J(k) = \frac{1}{2}(y_d(k) - y(k))^2 = \frac{1}{2}e^2(k) \quad (14)$$

式中: $y_d(k)$ 和 $y(k)$ 分别表示系统期望输出和实际的神经网络输出。参数学习的目的是使得期望目标函数 $J(k)$ 达到最小。

在梯度下降算法中,各个参数更新公式如式(15)~(20)所示:

$$c_{ij}(k+1) = c_{ij}(k) - \eta \frac{\partial J(k)}{\partial c_{ij}(k)} \quad (15)$$

$$\sigma_{ij}(k+1) = \sigma_{ij}(k) - \eta \frac{\partial J(k)}{\partial \sigma_{ij}(k)} \quad (16)$$

$$w_l(k+1) = w_l(k) - \eta \frac{\partial J(k)}{\partial w_l(k)} \quad (17)$$

式中:

$$\frac{\partial J(k)}{\partial c_{ij}(k)} = -\frac{e(k)w_l(k)v_l(k)(u_i(k) - c_{ij}(k))}{\sigma_{ij}^2(k)} \quad (18)$$

$$\frac{\partial J(k)}{\partial \sigma_{ij}(k)} = -\frac{e(k)w_l(k)v_l(k)(u_i(k) - c_{ij}(k))^2}{\sigma_{ij}^3(k)} \quad (19)$$

$$\frac{\partial J(k)}{\partial w_l(k)} = -e(k)v_l(k) \quad (20)$$

式中: η 表示参数学习率。

基于以上分析,SOFNN 算法具体流程如下:

1) 初始条件下模糊神经网络归一化层神经元数为 3,并对模糊神经网络的中心、宽度和权值参数进行随机初始化;设置增长阈值 I_{gth} 、神经元不活跃阈值 ρ 及修剪阈值 I_{cth} ;

2) 根据式(2)计算最大激活强度,并判断该神经元是否满足增长条件,若满足,则需要增长,并

利用式 (3) ~ (5) 对新增神经元的中心、宽度和权值进行初始值化设定; 否则转向步骤 3);

3) 根据修剪条件对网络隐含层神经元进行分析, 若满足式 (6), 则对相应的模糊规则重要性进行一次衰减。当满足删减条件式 (7) 时, 则对该模糊规则进行删除。并且神经元参数调整如式 (8) ~ (13);

4) 利用式 (14) ~ (20) 对神经网络的参数进行修改;

5) 直到所有样本都学习完毕或满足停止条件, 否则, 转向步骤 5)(结构调整已完成) 或步骤 2)(结构还需调整) 进行重复训练。

3 仿真实验

为了验证所提出的自组织模糊神经网络方法的可行性和有效性, 文中通过 Mackey-Glass 时间序列和污水处理过程溶解氧浓度跟踪控制进行仿真实验。

3.1 Mackey-Glass 时间序列预测

Mackey-Glass 时间序列可由式 (15) 描述:

$$x(t+1) = (1-a)x(t) + \frac{bx(t-\tau)}{1+x^{10}(t-\tau)} \quad (21)$$

式中: $a=0.1, b=0.2, \tau=17, x(0)=1.2$

根据式 (21) 产生 1 000 个样本, 其中前 500 个样本用于训练, 剩余 500 个样本用于测试。

性能评价指标分别采用最终规一化层神经元数、均方根误差 RMSE 和平均百分比误差 APE, 其中 RMSE 和 APE 计算公式如式 (22)~(23) 所示:

$$RMSE = \sqrt{\frac{1}{P} \sum_{p=1}^P (y_d(t) - y(t))^2} \quad (22)$$

$$APE = \frac{1}{P} \sum_{p=1}^P \frac{|y_d(t) - y(t)|}{|y_d(t)|} \times 100\% \quad (23)$$

图 5 给出了训练过程归一化层神经元数的变化情况, 可以看出最终神经元数稳定在 7 个左右。网络预测结果及预测误差分别如图 6 和图 7 所示, 从图 6 中可以看出, 所提出的 SOFNN 网络输出与期望输出曲线基本吻合, 表明该方法能够对非线性时间序列进行较好地逼近。从图 7 可以看出网络的测试误差值保持在 [-0.05,0.05] 较小的范围内, 表现出良好的泛化性能。

表 1 给出了不同算法的性能比较。从表 1 中可以看出, SOFNN 算法的最终神经元数为 7, 各项指标都优于其他算法。结果表明该方法能够使网络的结构得到最大化的精简, 网络的泛化能力得到提高。

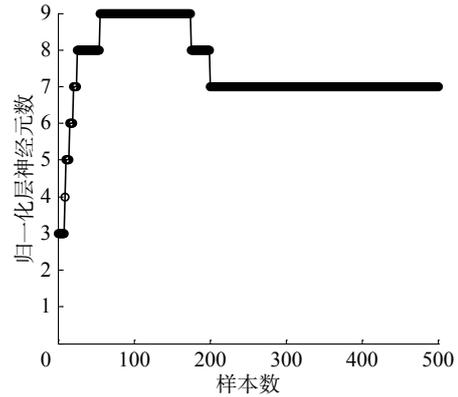


图 5 规一化层神经元变化曲线
Fig. 5 The neural number variation of normalized layer

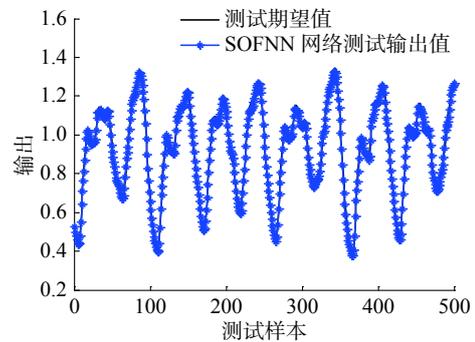


图 6 预测结果
Fig. 6 The prediction error

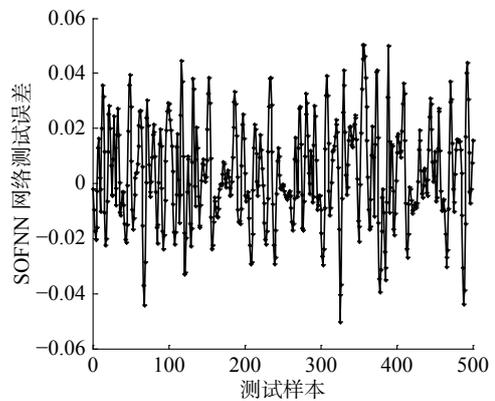


图 7 预测误差
Fig. 7 Prediction errors

表 1 不同算法性能比较

算法	规一化层神经元数	RMSE	APE
SOFNN	7	0.009 9	0.007 1
GDFNN ^[17]	11	0.011 8	0.008 4
SOFMLS ^[18]	7	0.047 1	0.033 5
FAOS-PFNN ^[19]	11	0.012 7	0.009 0
SOFNNGA ^[20]	7	0.013 2	0.009 4

3.2 污水处理过程溶解氧浓度控制

3.2.1 溶解氧浓度为恒定值

首先,设计对溶解氧浓度的恒定设定值 (2 mg/l) 的跟踪控制试验。在阴雨天气工况下,对生化反应池第五分区溶解氧浓度进行控制。并将该方法与其他 3 种控制策略进行比较。

图 8 给出了该方法对溶解氧浓度的控制效果。图 9 给出了在控制过程中规一化层神经元数的变化情况。从图 8 可以看出,所提出的 SOFNN 控制器能够对 DO 设定值进行较好的跟踪,具有较好的控制精度。从图 9 可以看出,通过激活强度和神经元重要性的在线结构调整机制,使得控制器的网络结构最终稳定在 8 个左右,表明在控制过程中通过在线增长和修剪算法,能够获得一个较为精简的网络结构。

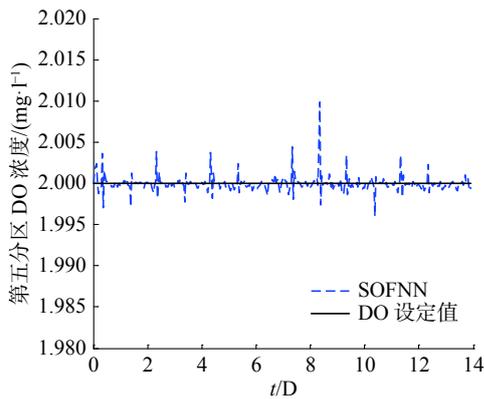


图 8 恒定值溶解氧的控制效果
Fig. 8 The control effect of constant DO set-point

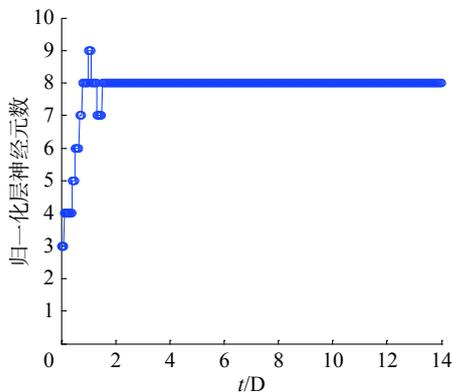


图 9 规一化层神经元数变化
Fig. 9 The neural number variation of normalized layer

表 2 给出了不同控制器的性能比较。通过与其他 3 种控制器的性能指标比较,可以看出基于 SOFNN 的 DO 控制系统相较于 PID、FNN 及 BP 控制算法,具有更好的控制效果。

表 2 不同控制器性能比较

Table 2 Performance comparison of different controllers

控制器	*隐含层神经元数	IAE	ISE	MaxDev
SOFNN	8	0.117	2.27×10^{-4}	9.91×10^{-3}
FNN	10	0.591	2.84×10^{-3}	1.73×10^{-2}
BP	12	0.706	3.24×10^{-3}	1.45×10^{-2}
PID	—	4.515	1.54×10^{-1}	9.97×10^{-2}

(*这里将SOFNN、FNN的归一化层统称为隐含层)

3.2.2 溶解氧浓度为变定值

为了更好地验证 SOFNN 控制器的稳定性和鲁棒性,文中将溶解氧浓度的设定值 1.8 mg/l ~ 2.2 mg/l 范围内阶跃变化,并考察 SOFNN 控制器在阴雨天气条件下的溶解氧浓度跟踪控制性能。图 10 给出了 SOFNN 控制效果图,图 11 给出了规一化层神经元数变化曲线。

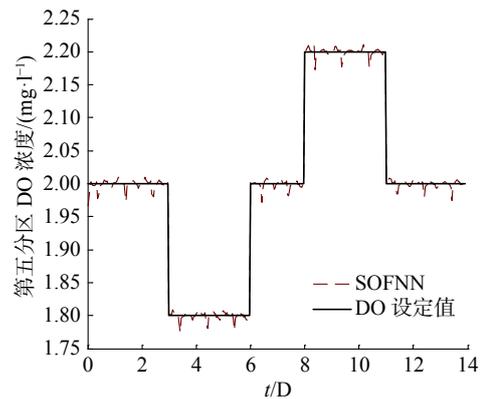


图 10 变设定值溶解氧的控制效果
Fig. 10 The control effect of step change DO set-point

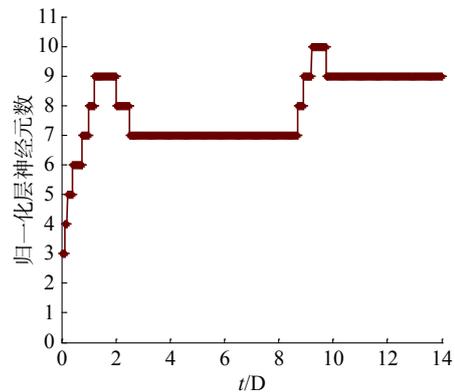


图 11 规一化层神经元数变化
Fig. 11 The neural number variation of normalized layer

从图 10 可以看出,当 DO 期望设定值发生变化后,控制器能够及时地根据当期那状况对 DO 进行良好跟踪控制,使其稳定在期望值附近。并且从图 11 可以看出,当环境发生变化时,所提出的 SOFNN 控制器能够根据当前环境情况变化自

组织的调整控制器结构。通过性能指标比较可以看出, 所提出的 SOFNN 控制器具有较小的 IAE、ISE 和 MaxDev, 表明该 SOFNN 控制器性能优于其他 3 种控制器, 具有较好的控制效果、稳定性及控制精度。并且, 通过比较隐含层神经元数可以看出, 该 SOFNN 控制方法具有较少的神经元数, 网络结构更加紧凑, 如表 3。

表 3 不同控制器性能比较

Table 3 Performance comparison of different controllers

控制器	*隐含层神经元数	IAE	ISE	MaxDev
SOFNN	9	0.296	2.49×10^{-3}	1.26×10^{-2}
FNN	10	0.734	4.26×10^{-3}	1.61×10^{-2}
BP	12	0.761	3.26×10^{-3}	1.52×10^{-2}
PID	—	4.501	1.53×10^{-1}	9.95×10^{-2}

(*这里将SOFNN、FNN的归一化层统称为隐含层)

4 结束语

针对污水处理过程中溶解氧浓度难以控制的问题, 提出了一种基于自组织模糊神经网络(SOFNN)的控制方法。该自组织方法考虑到实际生物神经网络中的特性及神经元对网络输出的贡献程度, 采用了一种基于神经元重要性的删减方法和基于神经元激活强度的增加方法。在删减阶段, 采用基于重要性衰减的方法, 这种策略虽然未能及时将“冗余”神经元进行删除, 但是能够保证神经网络的稳定性, 降低误删重要神经元的可行性。并通过梯度下降算法对网络的参数进行调整。然后通过两个实验来证明该方法的有效性。最后将该算法应用到 Mackey-Glass 时间序列预测及污水处理过程基准仿真平台 BSM1 中, 实验结果表明所提出的自组织模糊神经网络相较于其他方法, 具有较好的预测和控制效果, 证明了该方法的有效性。

参考文献:

- [1] SANTÍN I, PEDRET C, VILANOVA R, et al. Advanced decision control system for effluent violations removal in wastewater treatment plants[J]. Control engineering practice, 2016, 49: 60–75.
- [2] ÅMAND L, OLSSON G, CARLSSON B. Aeration control—a review[J]. Water science and technology, 2013, 67(11): 2374–2398.
- [3] WAHAB N A, KATEBI R, BALDERUD J. Multivariable PID control design for activated sludge process with nitrification and denitrification[J]. Biochemical engineering journal, 2009, 45(3): 239–248.
- [4] VRECKO D, HVALA N, KOCIJAN J. Wastewater treatment benchmark: what can be achieved with simple control?[J]. Water science and technology, 2002, 45(4/5): 127–134.
- [5] AYESA E, DE LA SOTA A, GRAU P, et al. Supervisory control strategies for the new WWTP of Galindo-Bilbao: the long run from the conceptual design to the full-scale experimental validation[J]. Water science and technology, 2006, 53(4/5): 193–201.
- [6] 潘海鹏, 徐玉颖. 基于 BP 网络的流浆箱双变量 PID 解耦控制 [J]. 化工学报, 2010, 61(8): 2154–2158.
PAN Haipeng, XU Yuying. Double variable PID decoupling control of headbox based on BP neural network[J]. CI-ESC journal, 2010, 61(8): 2154–2158.
- [7] KOTZAPETROS A D, PARASKEVAS P A, STASINAKIS A S. Design of a modern automatic control system for the activated sludge process in wastewater treatment[J]. Chinese journal of chemical engineering, 2015, 23(8): 1340–1349.
- [8] 刘超彬, 乔俊飞, 张芳芳. 污水处理过程中溶解氧的模糊神经网络控制 [J]. 山东大学学报: 工学版, 2005, 35(3): 83–87.
LIU Chaobin, QIAO Junfei, ZHANG Fangfang. Fuzzy neural network controls of dissolved oxygen in the wastewater treatment processes[J]. Journal of Shandong university: engineering science, 2005, 35(3): 83–87.
- [9] HUANG Mingzhi, WAN Jinquan, MA Yongwen, et al. Control rules of aeration in a submerged biofilm wastewater treatment process using fuzzy neural networks[J]. Expert systems with applications, 2009, 36(7): 10428–10437.
- [10] FU Wentao, QIAO Junfei, HAN Gaitang, et al. Dissolved oxygen control system based on the T-S fuzzy neural network[C]//Proceedings of 2015 International Joint Conference on Neural Networks. Killarney, Ireland, 2015: 1–7.
- [11] 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 Wei, QIAO Junfei, LI Fanjun. Direct adaptive dynamic neural network control for dissolved oxygen concentration[J]. Control theory and applications, 2015, 32(1): 115–121.
- [12] HABBI H, BOUDOUAOUY Y, KARABOGA D, et al. Self-generated fuzzy systems design using artificial bee colony optimization[J]. Information sciences, 2015, 295: 145–159.

- [13] JEPPSSON U, PONS M N. The COST benchmark simulation model—current state and future perspective[J]. Control engineering practice, 2004, 12(3): 299–304.
- [14] HAN Honggui, QIAO Junfei. A self-organizing fuzzy neural network based on a growing-and-pruning algorithm[J]. IEEE transactions on fuzzy systems, 2010, 18(6): 1129–1143.
- [15] FIGUEROA-GARCÍA J C, OCHOA-REY C M, AVELLANEDA-GONZÁLEZ J A. Rule generation of fuzzy logic systems using a self-organized fuzzy neural network[J]. Neurocomputing, 2015, 151: 955–962.
- [16] HSU Chunfei. Self-organizing adaptive fuzzy neural control for a class of nonlinear systems[J]. IEEE transactions on neural networks, 2007, 18(4): 1232–1241.
- [17] WU Shiqian, ER M J, CAO Yang. A fast approach for automatic generation of fuzzy rules by generalized dynamic fuzzy neural networks[J]. IEEE transactions on fuzzy systems, 2001, 9(4): 578–594.
- [18] DE JESÚS RUBIO J. SOFMLS: online self-organizing fuzzy modified least-squares network[J]. IEEE transactions on fuzzy systems, 2009, 17(6): 1296–1309.
- [19] WANG Ning, ER M J, MENG Xianyao. A fast and accurate online self-organizing scheme for parsimonious fuzzy neural networks[J]. Neurocomputing, 2009, 72(16/17/18): 3818–3829.
- [20] LENG Gang, MCGINNITY T M, PRASAD G. Design for self-organizing fuzzy neural networks based on genetic algorithms[J]. IEEE transactions on fuzzy systems, 2006, 14(6): 755–766.

作者简介:



许进超,女,1992年生,硕士研究生,主要研究方向为污水处理过程智能控制。



杨翠丽,女,1986年生,讲师,博士研究生,主要研究方向为进化算法、智能信息处理。发表学术论文 10 余篇,其中 SCI 检索 7 篇, EI 检索 12 篇。



乔俊飞,男,1968年生,教授,博士生导师,主要研究方向为智能信息处理、智能优化控制。近年发表学术论文近 70 篇,被 SCI 检索 15 篇。获教育部科技进步奖一等奖和北京市科学技术奖三等奖各 1 项,获得授权国家发明专利 12 项。