

溶解氧浓度的直接自适应动态神经网络控制方法

张伟^{1,2}, 乔俊飞^{1†}, 李凡军¹

(1. 北京工业大学 电子信息与控制工程学院 智能系统研究所, 北京 100124;

2. 河南理工大学 电气工程与自动化学院, 河南 焦作 454000)

摘要: 针对污水处理过程溶解氧浓度的控制问题, 提出一种直接自适应动态神经网络控制方法(direct adaptive dynamic neural network control, DADNNC)。构建的控制系统主要包括神经网络控制器和补偿控制器。神经网络控制器由自组织模糊神经网络实现系统状态与控制量之间的映射; 提出一种基于规则无用率的结构修剪算法, 并给出结构调整后网络收敛的理论证明。同时, 为保证系统稳定, 设计补偿控制器减小网络逼近误差, 参数调整由Lyapunov理论给出。国际基准仿真平台上的实验表明, 与固定结构神经网络控制器、PID和模型预测控制等已有控制方法相比, DADNNC方法具有更高的控制精度和更强的适应能力。

关键词: 动态神经网络控制器; 溶解氧; 规则无用率; 污水处理过程

中图分类号: TP273 文献标识码: A

Direct adaptive dynamic neural network control for dissolved oxygen concentration

ZHANG Wei^{1,2}, QIAO Jun-fei^{1†}, LI Fan-jun¹

(1. Intelligence System Institute, College of Electronic Information and Control,
Beijing University of Technology, Beijing 100124, China;

2. School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo Henan 454000, China)

Abstract: A direct adaptive dynamic neural network control (DADNNC) method is proposed to control the dissolved oxygen concentration in the wastewater treatment process. The established control system mainly includes a neural controller and a compensate controller. The neural controller fulfills the mapping between the system states and control variable using the fuzzy neural network, which can adjust the structure and parameters simultaneously. A novel pruning algorithm is presented based on the useless rate of the rules, and the convergence while adding and pruning neurons is guaranteed theoretically. Further, the compensation controller is designed for decreasing the approximating error introduced by the neural network, and the parameter update law is deduced by the Lyapunov theorem. Finally, the simulation results, based on the international benchmark simulation platform, show that the proposed method can achieve better control accuracy and superior adaptive ability compared with neural network controller with fixed structure, PID controller and model predictive control method.

Key words: dynamic neural network controller; dissolved oxygen; useless rate; wastewater treatment process

1 引言(Introduction)

溶解氧(dissolved oxygen, DO)浓度是污水生化处理过程中最重要的控制参数, 好氧区氧气不足和过量都会对微生物的生存环境带来不利影响。氧气不足时, 一方面导致好氧池中丝状菌大量繁殖, 最终产生污泥膨胀; 另一方面由于好氧菌的生长速率降低, 引起出水水质下降。而氧气过量则会引起悬浮固体沉降性变差, 同时导致能耗过高^[1-2]。从维持微生物良好生存环境, 改善过程性能和降低能耗角度考虑, 需要对溶解

氧进行有效控制。

DO浓度控制的难点在于污水处理过程精确的数学模型较难建立, 系统运行环境存在不确定性和严重干扰。污水生化处理涉及机理复杂的生化反应, 具有明显的非线性和时变特性, 实际运行工况多, 因此难以建立精确的数学模型。同时, 进水流量、污染物组份和浓度剧烈波动, 使污水处理过程处于非稳定状态, 干扰严重。微生物活动、温度和PH值等影响因素增加了系统不确定性。因此, 常规控制方法^[3-4]很难取得令

收稿日期: 2014-04-14; 录用日期: 2014-06-28。

[†]通信作者。E-mail: junfeiq@bjut.edu.cn。

国家自然科学基金项目(61034008, 61225016), 北京市自然科学基金项目(4122006), 教育部博士点新教师基金项目(20121103120020)资助。

Supported by National Natural Science Foundation of China (61034008, 61225016), Beijing Municipal Natural Science Foundation (4122006), Ph.D. Program Foundation from Ministry of Chinese Education (20121103120020).

人满意的控制效果。

模型预测控制(model predictive control, MPC)具有在线滚动优化和预测的优点,在污水处理系统中获得广泛应用^[5-6]. Holenda等人^[5]基于污水处理3阶简化模型在稳态工况下实现DO的跟踪控制。但控制精度受限于所建立的系统模型。而且,污水处理系统是一个复杂的非线性时变系统,基于稳态模型很难在整个控制中取得好的效果。将智能技术应用于污水处理过程控制,已经引起了很多学者的关注^[6-9]。其中,最为流行的技术是神经网络和模糊技术。Traoré等人^[7]研究了曝气过程的溶解氧模糊控制,将实际DO浓度与设定值的误差、误差变化以及累计误差作为模糊控制器的输入,空气流量及其变化作为控制器的输出。结果表明,与常规的开关控制相比,节省耗能约40%。溶解氧模糊控制方法避开了污水生化模型的建立问题,但是,推理规则需要大量的专家知识,且控制系统缺乏自学习能力,控制精度不高。Han等人^[8]应用神经网络技术在线建立污水系统的非线性动力学模型,在此基础上应用MPC和序列二次规划算法,实现DO的跟踪控制,取得较好的效果,但控制精度仍需提高。韩等人^[6]提出利用两个结构固定的前馈BP网络分别实现建模和控制任务的神经网络建模控制方法(feedforward neural network modeling and control, FN-NMC),开展溶解氧的控制研究。但是,应用神经网络建立系统模型,本质上属于系统辨识范畴,要求事先确定模型阶次和合理选择输入变量。薄等人^[9]基于回声状态网络(echo state network, ESN),在动态规划算法框架下实现溶解氧的跟踪控制,不需要建立系统数学模型,采用评价、提升的循环搜索方式逼近最优控制策略,是一种数据驱动的控制方法,为污水系统的控制问题提供了一种新的解决思路。但是,存在计算量大和稳定性较难保证的问题。

针对污水处理系统难以建立非线性动态模型和不确定干扰严重的难点问题,提出一种直接自适应动态神经网络控制方法。所提方法不需要建立精确的污水处理过程动力学模型,而是采用神经网络逼近一个理想控制率。构建的控制系统包含自组织神经网络控制器和用于补偿网络逼近误差的补偿控制器。神经网络控制器结构设计中,提出一种基于规则无用率的修剪算法,并考虑了隐结点调整后的参数补偿问题,从理论上保证了结构调整后的网络收敛。最后,基于国际基准仿真模型进行了实验研究。

2 问题描述(Problem description)

考虑一般的n阶SISO非线性微分方程描述^[10]:

$$\begin{cases} x^{(n)} = f(\mathbf{x}, t) + g(\mathbf{x}, t)u(t) + d, \\ y = x(t), \end{cases} \quad (1)$$

其中: $f(\mathbf{x}, t)$ 和 $g(\mathbf{x}, t)$ 是未知连续函数, $u(t) \in \mathbb{R}$, $y(t)$

$\in \mathbb{R}$ 分别为系统的控制量和系统输出, d 为系统干扰, $\mathbf{x} = (x_1, x_2, \dots, x_n)^T = (x, \dot{x}, \dots, x^{(n-1)})^T \in \mathbb{R}^n$.

定义系统误差 e 和滤波误差 s :

$$e(t) = y_d(t) - y(t), \quad (2)$$

$$s = e^{(n-1)} + k_1 e^{(n-2)} + \dots + k_n \int_0^t e(\tau) d(\tau). \quad (3)$$

若系统的动态特性已知,可得理想控制率^[11]

$$u^* = \frac{1}{g(\mathbf{x}, t)} [-f(\mathbf{x}, t) + y_d^{(n)} + \mathbf{k}^T e - d], \quad (4)$$

其中: $\mathbf{k} = [k_1, k_2, \dots, k_n]^T$, y_d 为系统期望输出,将式(4)代入式(1),同时考虑式(2)-(3),可得 $e^{(n)} + k_1 e^{(n-1)} + \dots + k_n e = 0$,则当 \mathbf{k} 取为Hurwitz多项式系数时,可以保证系统误差收敛到零^[11],即 $\lim_{t \rightarrow \infty} e(t) = 0$ 。故当系统模型已知时,采用控制率 u^* 可以保证系统获得稳定的跟踪控制。然而,污水处理系统的非线性动态模型难以建立,即 $f(\mathbf{x})$ 和 $g(\mathbf{x})$ 未知,因此理想控制率 u^* 无法实现。

3 DADNNC控制器设计(Controller design)

3.1 控制系统结构(Structure of the control system)

图1为溶解氧浓度的直接自适应动态神经网络控制(direct adaptive dynamic neural network control, DADNNC)的整体结构。

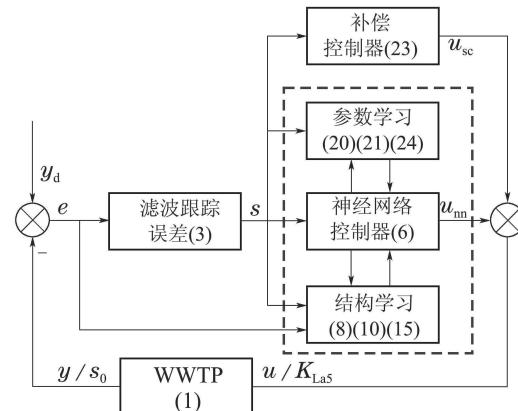


图1 控制系统框图

Fig. 1 Scheme of the control system

控制目标是通过求得合适的控制量 u (氧气转换系数 K_{La5}),使得输出 y (溶解氧浓度 S_o)能够跟踪给定的输出设定值 y_d 。构建的控制系统包括神经网络控制器和补偿控制器两部分。神经网络控制器利用TS模糊神经网络(TS-fuzzy neural network, TS-FNN)逼近理想控制率 u^* 。神经网络控制器在线学习包括结构学习和参数学习,结构学习采用增长-修剪算法确定隐结点个数(模糊规则数),参数学习由梯度下降算法给出。补偿控制器 u_{sc} 用来补偿网络逼近误差。

3.2 TS模糊神经网络(TS-FNN)

TS-FNN融合了模糊逻辑和神经网络的优点,具有优越的非线性函数逼近和在线学习能力,增加了

网络透明性, 同时易于人类经验知识的融入和规则提取。应用于溶解氧控制的TS-FNN采用图2所示的4层前馈网络结构^[12]。网络输入为滤波误差 s , 输出为控制量 u_{nn} , 并希望 u_{nn} 尽可能逼近理想控制率 u^* 。

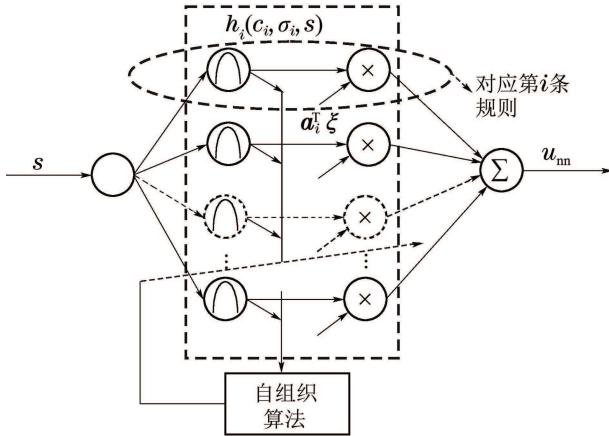


图2 TS-FNN的网络结构

Fig. 2 Network structure of the TS-FNN

第1层为输入层, 只起信息传递作用。

第2层为隶属度函数层(隐含层)。选用高斯函数作为隶属度函数, 则第*i*个隐结点输出表示为

$$h_i(c_i, \sigma_i, s) = \exp\left(-\frac{(s - c_i)^2}{\sigma_i^2}\right), \quad i = 1, 2, \dots, n, \quad (5)$$

其中 c_i , σ_i 分别为对应隶属度函数的中心和宽度。

第3层为乘积层。该层中每个神经元均有两部分输入: 对应第1隐层神经元的输出和相应规则后件线性组合, 输出为两者乘积, 即第*i*个神经元输出为

$$h_i(c_i, \sigma_i, s) \cdot (\alpha_i^T \xi) = h_i(c_i, \sigma_i, s) \cdot \left(\begin{bmatrix} \alpha_{i0} \\ \alpha_{i1} \end{bmatrix}^T \cdot \begin{bmatrix} 1 \\ s \end{bmatrix}\right).$$

其中: $\xi = [1 \ s]^T$, $\alpha_i = [\alpha_{i0} \ \alpha_{i1}]^T$ 为第*i*条规则的后件参数。乘积层与隶属度层中神经元个数相同(对应模糊规则数), 当进行增加或删除结点操作时, 两层中的神经元变化一致。

第4层为输出求和层, 可表示为

$$u_{nn} = \sum_{i=1}^n \alpha_i^T \xi h_i(c_i, \sigma_i, s), \quad (6)$$

其中*n*为现存隐含层神经元个数(模糊规则数)。

3.3 TS-FNN在线学习(TS-FNN learning algorithm)

污水生化处理是复杂、动态的控制过程, 具有非线性、时变和干扰严重等特征, 结构固定的神经网络控制效果受到很大的挑战^[13]。动态结构优化神经网络能够根据信息处理的需要, 实时调整网络拓扑结构, 进而提高神经网络性能。因此, 神经网络控制器的在线学习任务包括网络结构学习(隐层结点数确定, 即模糊规则数)和参数学习(隶属度函数中心和宽度, 以及规则后件参数)。结构学习采用增长-修剪算法, 参数学习采用梯度下降算法。

3.3.1 结构增长算法(Structure growing algorithm)

利用隐含层神经元激活强度^[12]和系统输出误差作为结构增长判断准则。当隶属度函数层神经元输出较小时, 意味着当前输入对该隐层结点的激活强度不够。因此, 当输入数据对隶属度层中所有神经元激活强度的最大值仍小于某个阈值时, 需要增加隐结点, 增加准则可由式(7)–(8)描述:

$$h_{\max} = \max_{1 \leq i \leq n} (h_i(c_i, \sigma_i, s)), \quad (7)$$

$$h_{\max} \leq G_{\text{th}}. \quad (8)$$

同时, 在污水过程控制中, 当系统输出误差较大时, 说明网络的逼近能力不足, 应考虑增加隐结点。为避免异常数据带来影响, 利用滑动窗内的平均误差(9)作为判断准则, 当满足式(10)时, 增加隐层结点。

$$\text{error} = \frac{\sum_{i=t-M+1}^t \text{error}_i}{M}, \quad (9)$$

$$|\text{error}| \geq E_{\text{th}}, \quad (10)$$

其中: $\text{error}_i = y(i) - y_d(i)$, M 为滑动窗内数据个数, $G_{\text{th}} \in (0, 1)$ 和 E_{th} 为选定的合适阈值。

假设*t*时刻, 增长条件满足, 则增加一个隐结点(规则), 初始参数设置为

$$c_{n+1} = s, \sigma_{n+1} = \sigma, \alpha_{n+1} = \mathbf{0}, \quad (11)$$

隐含层结点个数(规则数)加1, 即 $n(t+1) = n(t) + 1$ 。

3.3.2 结构修剪算法(Structure pruning algorithm)

为避免隐含层结点个数过度增长, 同时, 适应污水过程多工况条件下容易出现结构冗余的现象, 设计网络在线修剪算法。提出一种基于规则无用率的删减算法。设计思想为, 从某条规则(假设第*j*条)开始使用起, 记录规则在网络应用中起重要作用和不重要作用的次数, 并计算现存每条规则的无用率, 分别由式(12)–(14)表达, 当*t*时刻满足条件(15)时, 删除该条规则(隐结点)。

$$R_j(t+1) = \begin{cases} R_j(t) + 1, & h(j) < \beta, \\ R_j(t), & h(j) \geq \beta, \end{cases} \quad (12)$$

$$M_j(t+1) = \begin{cases} M_j(t) + 1, & h(j) > \beta, \\ M_j(t), & h(j) \leq \beta, \end{cases} \quad (13)$$

$$\text{Rate_useless}_j = \frac{R_j}{R_j + M_j}, \quad (14)$$

$$\text{Rate_useless}_j \geq R_{\text{th}}, \quad (15)$$

其中: $\beta \in (0, 1)$ 为区分隐结点是否起重要作用的设定值, $R_{\text{th}} \in (0, 1)$ 为删除阈值, 其设置应考虑采样周期快慢。可见, 所提结构删减算法, 计算量小, 适合在线控制。为保证网络输出稳定, 减少删除结点(规则)对网络的影响, 对网络参数进行补偿。假设*t*时刻第*j*个隐结点满足删除条件, 找出与第*j*个神经元欧氏距离

最近的隐层神经元, 记为 $j-j$, 并进行如下参数调整

$$c'_{j-j} = c_{j-j}, \sigma'_{j-j} = \sigma_{j-j}, \boldsymbol{\alpha}'_{j-j} = \boldsymbol{\alpha}_{j-j} + \frac{\boldsymbol{\alpha}_j h_j}{h_{j-j}}, \quad (16)$$

其中: $c_{j-j}, \sigma_{j-j}, \boldsymbol{\alpha}_{j-j}$ 是结构调整前神经元 $j-j$ 的参数, $c'_{j-j}, \sigma'_{j-j}, \boldsymbol{\alpha}'_{j-j}$ 是结构调整后神经元 $j-j$ 的参数.

附录给出了增减隐结点前后, 网络收敛性不变的理论证明.

3.3.3 参数学习(Parameter learning)

为使系统获得更快的收敛速度, 设置神经网络控制器参数学习性能函数^[12]

$$J = \dot{s}\dot{s}. \quad (17)$$

由图1所示, 系统控制量包括神经网络控制器输出和补偿控制器输出两部分, 即

$$u = u_{\text{nn}} + u_{\text{sc}}. \quad (18)$$

将式(18)代入式(1), 并考虑式(3), 系统的误差方程可表示为

$$\dot{s} = g(\mathbf{x})(u^* - u_{\text{nn}} - u_{\text{sc}}). \quad (19)$$

采用梯度下降算法^[2, 12], 可推得

$$\begin{cases} \Delta c_i = -\eta_c \frac{\partial J}{\partial c_i} = \eta_c s \boldsymbol{\alpha}_i^T \boldsymbol{\xi} \frac{(s - c_i)}{\sigma_i^2} h_i, \\ \Delta \sigma_i = -\eta_\sigma \frac{\partial J}{\partial \sigma_i} = \eta_\sigma s \boldsymbol{\alpha}_i^T \boldsymbol{\xi} \frac{(s - c_i)^2}{\sigma_i^3} h_i, \\ \Delta \boldsymbol{\alpha}_i = -\eta_\alpha \frac{\partial J}{\partial \boldsymbol{\alpha}_i} = \eta_\alpha s \boldsymbol{\xi} h_i. \end{cases} \quad (20)$$

令 $\boldsymbol{\theta} = [\mathbf{c}^T \ \boldsymbol{\sigma}^T \ \boldsymbol{\alpha}^T]$, 则参数的更新公式为

$$\boldsymbol{\theta}(t+1) = \boldsymbol{\theta}(t) + \Delta \boldsymbol{\theta}(t), \quad (21)$$

其中:

$$\mathbf{c} = [c_1 \ c_2 \ \cdots \ c_n]^T, \ \boldsymbol{\sigma} = [\sigma_1 \ \sigma_2 \ \cdots \ \sigma_n]^T,$$

$$\boldsymbol{\alpha} = [\boldsymbol{\alpha}_1 \ \boldsymbol{\alpha}_2 \ \cdots \ \boldsymbol{\alpha}_n]^T,$$

$\eta_c \in (0, 1), \eta_\sigma \in (0, 1), \eta_\alpha \in (0, 1)$ 分别为中心、宽度和后件参数的学习率.

3.4 稳定性分析及补偿控制器设计(Stability analysis and compensation controller design)

神经网络控制系统设计的主要任务是神经网络控制器的在线学习以及保证控制系统稳定. 由于污水处理在线控制中, 神经网络不可能零误差地逼近理想控制率, 存在逼近误差

$$\varepsilon = u^* - u_{\text{nn}}. \quad (22)$$

为保证系统稳定, 设计补偿控制器来补偿逼近误差 ε . 由于实际逼近误差不易获取, 利用逼近误差估计值, 设计如下补偿控制器:

$$u_{\text{sc}} = \hat{\varepsilon} + ks, \quad (23)$$

其中: $\hat{\varepsilon}$ 为逼近误差估计值, k 为数值较小的正常数. 逼近误差变化率取

$$\dot{\hat{\varepsilon}} = \eta_\varepsilon s. \quad (24)$$

定理1 当采用式(18)的控制率, 神经网络控制器和补偿控制器分别采用式(6)(23), 逼近误差变化率采用式(24), 神经网络参数由梯度下降算法(20)调整, 可以保证DADNNC系统Lyapunov稳定.

证 将式(23)–(24)代入式(19), 得

$$\dot{s} = g(\mathbf{x})(\varepsilon - \hat{\varepsilon} - ks) = g(\mathbf{x})(\tilde{\varepsilon} - ks), \quad (25)$$

其中 $\tilde{\varepsilon} = \varepsilon - \hat{\varepsilon}$.

选取候选李雅普诺夫函数

$$V(t) = \frac{1}{2}s^2 + \frac{1}{2\eta_\varepsilon}\tilde{\varepsilon}^2, \quad (26)$$

其中 $\eta_\varepsilon \in (0, 1)$ 为 $\dot{\hat{\varepsilon}}$ 的学习率. 对式(26)两边取微分

$$\begin{aligned} \dot{V} &= \dot{s}\dot{s} + \frac{1}{\eta_\varepsilon}\tilde{\varepsilon}\dot{\tilde{\varepsilon}} = sg(\mathbf{x})(\tilde{\varepsilon} - ks) + \frac{1}{\eta_\varepsilon}\tilde{\varepsilon}\dot{\tilde{\varepsilon}} = \\ &\tilde{\varepsilon}(s + \frac{1}{\eta_\varepsilon}\dot{\tilde{\varepsilon}}) - ks^2 = \tilde{\varepsilon}(s - \frac{1}{\eta_\varepsilon}\dot{\hat{\varepsilon}}) - ks^2. \end{aligned} \quad (27)$$

将式(24)代入式(27)

$$\dot{V} = -ks^2 \leqslant 0. \quad (28)$$

由式(28)可知 $\dot{V}(t)$ 负半定, 即 $V(t) \leqslant V(0)$, 意味着 $s(t)$ 和 $\tilde{\varepsilon}$ 是有界的. 令 $W(t) \equiv ks^2 \leqslant -\dot{V}(t)$, 并且两边积分, 可得

$$\int_0^t W(t)dt \leqslant V(0) - V(t), \quad (29)$$

$V(0)$ 有界, $V(t)$ 有界且非增长函数, 则有

$$\lim_{t \rightarrow \infty} \int_0^t W(t)dt < \infty. \quad (30)$$

又由于 $\dot{W}(t)$ 有界, 则由Barbalat引理^[14]得, $\lim_{t \rightarrow \infty} W(t) = 0$, 表明 $t \rightarrow \infty$ 时, 有 $s(t) \rightarrow 0$, 因此, 可以保证DADNNC系统稳定. 证毕.

4 仿真实验(Simulations)

4.1 BSM1(Benchmark simulation model No.1)

BSM1^[15]是国际水协会(international water association, IWA)提出的一个用于测试污水处理过程控制策略的标准模型(如图3所示). 根据实际污水处理系统的运行数据, BSM1分别给出了晴、阴雨和暴雨3种天气情况下, 连续2周的入水干扰数据文件, 采样周期15 min. 本文选取阴雨和暴雨工况下数据进行仿真. 阴雨天气除了包括前7天的晴好天气数据外, 第8天至11天出现一个长时间的持续降雨过程; 暴雨天气下的数据则除了前7天晴好天气数据外, 在第9天和第11天增加了反映由于暴雨出现而产生入水流量大幅度增加现象. 同时, 两种工况下都反映了周中(周一至周五)和周末的水量变化差异. 污水处理过程入水流量幅值变化很大, 最大和最小数值相差约6倍.

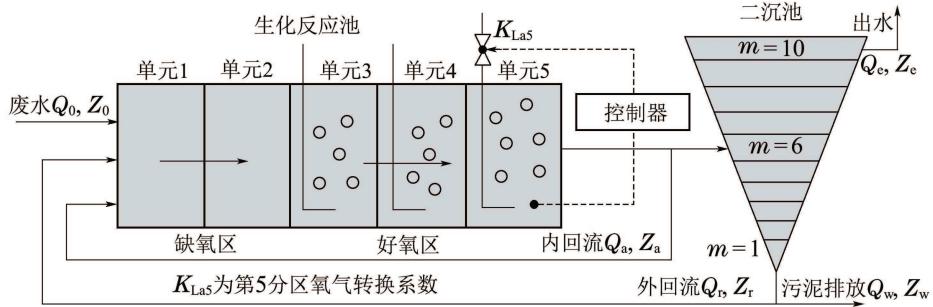


图3 BSM1布局示意图

Fig. 3 Layout of the BSM1

4.2 溶解氧浓度控制及结果分析(DO concentration control and result analysis)

首先, 设计溶解氧跟踪恒定值(2 mg/l)实验。应用所提DADNNC方法在阴雨天气工况下, 对生化池第5分区溶解氧浓度进行控制, 并与PID^[4], MPC^[5]和FMNNC^[8]方法进行比较, 各控制方法基于相同的仿真环境。本文方法中参数设置如下: $\eta_c = 0.01$, $\eta_\sigma = 0.01$, $\eta_\alpha = 0.1$, $\eta_\varepsilon = 1.0$, $k = 1$, $G_{th} = 0.6382$, $\beta = 0.3218$, $E_{th} = 0.1$, $R_{th} = 0.85$, $\sigma = 0.2$, $M = 20$ 。由图4可以直观看出DADNNC方法的控制精度明显高于PID方法。

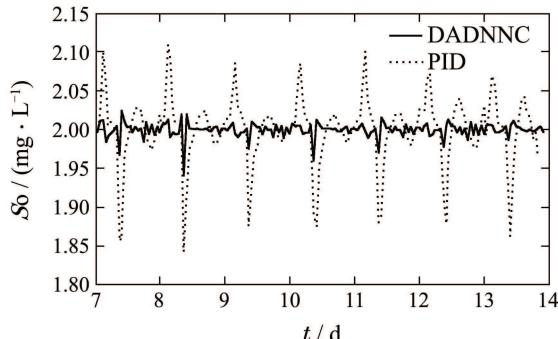


图4 溶解氧控制效果

Fig. 4 Do concentration control

表1给出了动态自适应神经网络控制方法与其他控制方法的性能参数对比。

表1 不同控制器下性能指标对比

Table 1 Comparisons of the performance indexs

| | IAE | ISE | DEV ^{max} |
|----------------------|---------|-------------------------|--------------------|
| DADNNC | 0.032 | 3.95×10^{-4} | 0.0606 |
| FNNMC ^[7] | 0.0035* | 4.37×10^{-4} * | 0.0912* |
| PID ^[4] | 0.218* | 3.11×10^{-3} * | 0.1623 |
| MPC ^[5] | 0.089* | 2.60×10^{-3} * | 0.1254 |

注: *表示原文中已有结果。IAE为绝对积分误差, ISE为平方积分误差,

DEV^{max}为最大误差偏差, 采用BSM1中定义的性能指标^[15]计算。

通过性能指标对比, 溶解氧浓度在DADNNC方法下的IAE, ISE和DEV^{max}性能明显优于PID和MPC

方法, 其中, ISE指标减小了一个数量级; 与FNNMC相比, ISE与DEV^{max}指标减小, IAE指标有所增大。但需要说明的是, FNNMC方法需要事先确定网络结构, 而本文隐层神经元个数可以根据外界环境变化动态调整, 并保持较为精简的网络结构。图5给出了所提方法隐结点的变化曲线。局部图展示了运行最初隐结点的变化情况。

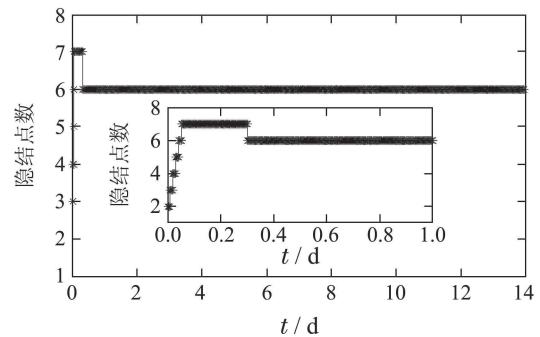


图5 隐结点变化

Fig. 5 Number variation of the hidden nodes

应用常规神经网络(这里指固定结构神经网络)控制时, 隐层神经元(模糊规则)个数过少, 系统控制精度较低, 而当网络结构选取过大时, 则易出现冗余现象。经仿真验证, 采用所提方法确定的6个隐层神经元的网络结构, 是保证相同精度前提下可以获得的较精简网络规模。此外, 常规神经网络隐层神经元个数的确定需要通过试凑或经验的方法得到, 即使能够得到较好的控制效果, 确定神经元数的工作也是费时的, 而且由于网络结构固定可能导致系统自适应能力较差。

为进一步检验所提方法的自适应能力, 设定溶解氧浓度在1.8 mg/l~2.3 mg/l范围内阶跃变化, 考察DADNNC方法在暴雨工况下跟踪溶解氧浓度的控制性能, 并进行不同初始隐结点下的DADNNC方案、固定隐结点(常规)方案与PID控制比较。记初始网络结构为1-2-1和1-9-1的DADNNC方案分别为方案A和方案B, 方案C为固定结构(1-9-1)TS-FNN自适应控制方案。3种情况下的控制效果由图6给出。由图6可以看出, 方案A和方案B两种情况下, 系统的控制效果明显优于方案C, 说明结构动态调整的神经网络控制器

自适应能力优于固定结构控制器。由于第9天入水流量和污水物浓度发生大幅度变化,出现了较大误差,但神经网络控制器通过学习,较为快速地实现了高精度跟踪控制。

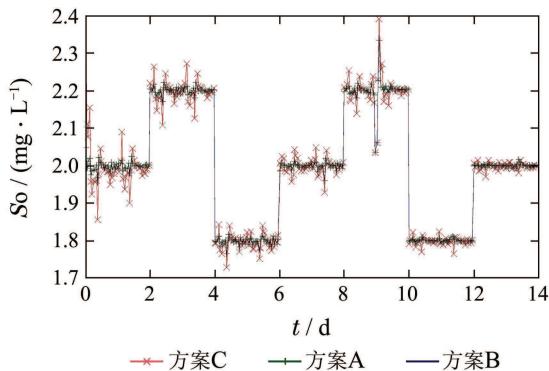


图6 DO设定值变化时的控制曲线

Fig. 6 Tacking curves of variable DO set-values

表2给出方案A、方案B、方案C与PID控制下的具体性能指标。

表2 不同控制方法下性能指标对比

Table 2 Performance comparisons under different controllers

| | IAE | ISE | DEV ^{max} |
|-----|---------|---------|--------------------|
| 方案A | 0.04981 | 0.00295 | 0.1635 |
| 方案B | 0.04731 | 0.00294 | 0.1636 |
| PID | 0.13426 | 0.00646 | 0.1971 |
| 方案C | 0.08973 | 0.00495 | 0.1805 |

通过性能指标比较发现,不同初始隐结点个数下DADNNC的IAE, ISE, DEV^{max}性能指标相当,而固定结构(方案C)情况下的3个性能指标明显变差,IAE和ISE数值约是DADNNC方法的2倍。由于PID控制没有自适应调节能力,性能指标IAE(0.13426)和ISE(0.00646)最不理想。仿真实验表明,DADNNC通过结构的动态调整可以适应和处理污水生化系统复杂的运行环境,而且,在不同初始隐结点个数设置下,均能获得较好的控制性能,具有较强的结构和参数自适应能力。选定初始9个隐结点的网络结构作为方案B,主要基于团队先前的研究成果作为参考^[6,8]。但从简化问题和避免预先确定网络结构角度考虑,选取较少隐结点作为初始结构则更为简便。

图7给出了污水过程控制中,初始2个隐结点(方案A)和初始9个隐结点(方案B)两种方案中隐层结点个数(对应模糊规则数)变化。由图7可见,随着外部环境变化,神经网络控制器的隐层结点个数(模糊规则数)动态调整,以适应不同工况。局部图展示了运行最初隐结点的变化情况。

图8给出了方案A情况下,溶解氧浓度控制量(氧气转换系数K_{La5})的变化曲线。从图8可以看出,整个控

制过程中控制量变化平稳,系统没有因为网络结构调整引起控制量大的变化。动态调整后获得的模糊规则,其对应的隶属函数中心、宽度以及规则后件参数可以通过if-then规则描述。方案A情况下最终得到的7条规则在控制过程中起不重要和重要作用的次数为

[1, 16, 37, 461, 167, 0, 0],

[1342, 1325, 1303, 877, 311, 477, 476],

无用率指标分别为[0.0007, 0.0119, 0.0276, 0.3445, 0.3494, 0, 0]。在实际生物神经网络中,神经元并不总是处于活跃状态,一直不活跃的神经元最终将会衰亡,因此,基于无用率的删减机制具有一定的生物学基础。

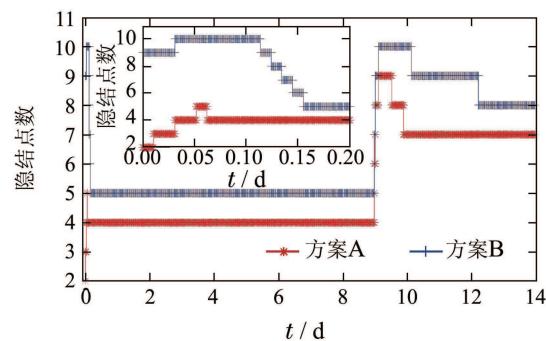


图7 隐结点个数变化

Fig. 7 Number variation of the hidden nodes

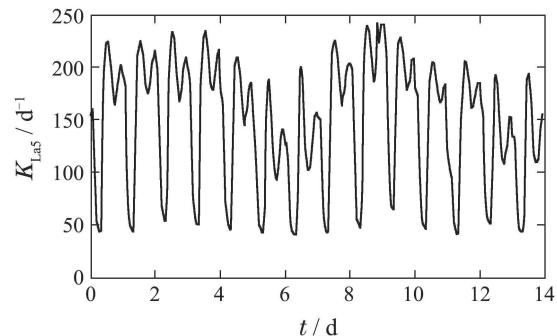


图8 控制量变化

Fig. 8 Curve of the manipulated variable

5 结论(Conclusions)

分析污水处理过程溶解氧浓度控制存在的难点问题,提出一种不需要精确建立过程模型的溶解氧浓度直接自适应动态神经网络控制方法(DADNNC)。得出的主要结论如下:1)设计了结构和参数可以在线学习的自组织神经网络控制器。提出一种基于规则无用率指标的结构删减算法,计算量小,适合在线控制。相比广泛采用的基于当前时刻采样信息进行删减的算法^[2,15],理论上具有更好的稳定性。虽然从实时性角度,未能立刻删减“冗余”结点,但更好地保证了系统稳定性和降低“误删”重要隐结点(规则)的可能性。2)为保证系统稳定,设计补偿控制器,并考虑了增减结点后的参数补偿问题,给出了结构调整后网络收敛的理论证明。3)基于国际基准仿真模型BSM1,应用

所提方法进行溶解氧浓度的跟踪实验, 获得了令人满意的控制性能。与现有相关控制方法比较, 在控制精度和自适应能力方面具有优越性。

此外, 所提方法为一类非线性慢时变、模型难以建立的多工况复杂系统的跟踪控制问题提供了一种新的解决思路。

参考文献(References):

- [1] 张平, 范明哲, 王宏. 基于国际评价基准的溶解氧控制方法研究 [J]. 信息与控制, 2007, 36(2): 199 – 203.
(ZHANG Ping, YUAN Mingzhe, WANG Hong. Study on dissolved oxygen control method based on international evaluation benchmark [J]. *Information and Control*, 2007, 36(2): 199 – 203.)
- [2] HAN H G, QIAO J F. Adaptive dissolved oxygen control based on dynamic structure neural network [J]. *Applied Soft Computing*, 2011, 11(4): 3812 – 3820.
- [3] CARLSSON B, REHNSTRM A. Control of an activated sludge process with nitrogen removal — a benchmark study [J]. *Water Science and Technology*, 2002, 45(4/5): 135 – 142.
- [4] AYESA E, 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): 193 – 201.
- [5] HOLEND A, DOMOKOS E. Dissolved oxygen control of the activated sludge wastewater treatment process using model predictive control [J]. *Computers and Chemical Engineering*, 2008, 32(6): 1270 – 1278.
- [6] HAN H G, QIAO J F, CHEN Q L. Model predictive control of dissolved oxygen concentration based on a self-organizing RBF neural network [J]. *Control Engineering Practice*, 2012, 20(4): 465 – 476.
- [7] TRAORE A, GRIEU S, PUIG S, et al. Fuzzy control of dissolved oxygen in a sequencing batch reactor pilot plant [J]. *Chemical Engineering Journal*, 2005, 111(1): 13 – 19.
- [8] 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 [J]. 控制理论与应用, 2013, 30(5): 585 – 591.
(HAN Guang, QIAO Junfei, BO Yingchun. Research on feedforward neural network modeling and controlling method for dissolved oxygen concentration [J]. *Control Theory & Applications*, 2013, 30(5): 585 – 591.)
- [9] 薄迎春, 乔俊飞. 启发式动态规划在污水处理过程控制中的应用 [J]. 控制理论与应用, 2013, 30(7): 828 – 833.
(BO Yingchun, QIAO Junfei. Application of heuristic dynamic programming to wastewater treatment process control [J]. *Control Theory & Applications*, 2013, 30(7): 828 – 833.)
- [10] BELCHIOR C A C, ARAUJO 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(2): 152 – 162.
- [11] SLOTINE J J E, LI W. *Applied Nonlinear Control* [M]. Englewood Cliffs, NJ: Prentice-Hall, 1991: 207 – 246.
- [12] HSU C F, LIN C M, YEH R G. Supervisory adaptive dynamic RBF-based neural-fuzzy control system design for unknown nonlinear systems [J]. *Applied Soft Computing*, 2013, 13(4): 1620 – 1626.
- [13] 韩红桂, 詹博然, 乔俊飞. 动态结构优化神经网络及其在溶解氧控制中的应用 [J]. 信息与控制, 2010, 39(3): 354 – 360.
(HAN Honggui, ZHEN Boran, QIAO Junfei. Dynamic structure optimization neural network and its applications to dissolved oxygenic (DO) control [J]. *Information and Control*, 2010, 39(3): 354 – 360.)
- [14] SASTRY S, BODSON M. *Adaptive Control: Stability, Convergence and Robustness* [M]. Englewood Cliffs, NJ: Prentice Hall, 2011: 17 – 25.
- [15] 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.
- [16] MAN Z, WU H R, LIU S, et al. A new adaptive backpropagation algorithm based on Lyapunov stability theory for neural networks [J]. *IEEE Transactions on Neural Networks*, 2006, 17(6): 1580 – 1591.

附录 神经网络收敛性分析(Appendix Convergence analysis of the neural network)

神经网络收敛性分析分为网络结构调整(增长和删减)阶段和网络结构不变阶段, 以下分别进行讨论。

A1 网络结构增长(Structure growing phase)

假设第 t 个采样时刻, 网络满足增长条件。计算增长前后, 神经网络的输出误差变化。

$$\varepsilon_{n+1}(t) = u_{nn} - u^* = \sum_{i=1}^{n+1} \alpha_i^T \xi h_i - u^* = \sum_{i=1}^n \alpha_i^T \xi h_i - u^* + \alpha_{n+1}^T \xi h_{n+1}. \quad (31)$$

代入参数设置公式(11), 可得

$$\varepsilon_{n+1}(t) = \sum_{i=1}^n \alpha_i^T \xi h_i - u^* = \varepsilon_n(t). \quad (32)$$

这表明增长结点, 采用式(11)的参数设置公式未改变网络的收敛性。

A2 网络结构删减(Structure pruning phase)

假设第 t 个采样时刻, 第 j 个神经元满足删除条件。考察删除该神经元前后, 神经网络的输出误差变化。

$$\begin{aligned} \varepsilon_{n-1} &= u_{nn} - u^* = \sum_{i=1}^{n-1} \alpha_i^T \xi h_i - u^* = \\ &\sum_{i=1}^n \alpha_i^T \xi h_i - u^* - \alpha_j^T \xi h_j = \\ &\sum_{i=1, i \neq j}^n \alpha_i^T \xi h_i - u^* - \alpha_j^T \xi h_j + \alpha_{j-j}^T \xi h_{j-j}. \end{aligned} \quad (33)$$

代入参数调整式(16), 可得

$$\begin{aligned} \varepsilon_{n+1}(t) &= \sum_{i=1, i \neq j}^n \alpha_i^T \xi h_i - u^* + \alpha_{j-j}^T \xi h_{j-j} = \\ &\sum_{i=1}^n \alpha_i^T \xi h_i - u^* = \varepsilon_n(t). \end{aligned} \quad (34)$$

表明删除结点, 采用式(16)进行参数补偿, 没有引起网络输出误差改变, 即未改变网络的收敛性。

A3 网络结构不变阶段(Structure non-changing phase)

神经网络结构不变阶段, 其参数学习采用梯度下降算法调整, 文[16]已经给出了完整的网络收敛性证明。

综合上述, 神经网络采用所提增减结点算法进行参数调整, 可以保证网络结构不变和调整阶段的收敛性。

作者简介:

张 伟 (1978–), 女, 博士研究生, 目前研究方向为污水处理系统的智能控制与优化控制, E-mail: zwei1563@126.com;

乔俊飞 (1968–), 男, 教授, 博士生导师, 目前研究方向为智能控制与智能信息处理等, Email: junfeiq@bjut.edu.cn;

李凡军 (1977–), 男, 博士研究生, 目前研究方向为智能信息处理及神经网络结构优化设计, E-mail: ss_lifj@ujn.edu.cn。