

溶解氧浓度的前馈神经网络建模控制方法

韩广, 乔俊飞[†], 薄迎春

(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)

摘要: 针对污水处理过程溶解氧(DO)浓度控制问题, 提出了一种基于前馈神经网络的建模控制方法(FNNMC). 本文构造了神经网络建模控制系统, 通过对建模神经网络和控制神经网络隐含层学习率的分析, 证明了学习算法的收敛性以及整个系统的稳定性. 最后, 本文基于国际基准的Benchmark Simulation Model No.1 (BSM1)进行了仿真实验, 验证了合理选取学习率的重要性, 并通过与PID和模型预测控制(MPC)等已有控制方法的比较, 验证了神经网络建模控制方法针对污水处理过程溶解氧浓度控制具有良好的建模能力, 更高的控制精度以及更好的动态响应能力.

关键词: 溶解氧; 前馈神经网络; 建模控制; 稳定性; 学习率

中图分类号: TP273 **文献标识码:** A

Feedforward neural network modeling and control for dissolved oxygen concentration

HAN Guang, QIAO Jun-fei[†], BO Ying-chun

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

Abstract: A feedforward neural network modeling and control (FNNMC) method is proposed, and its application system is designed for controlling the dissolved oxygen (DO) concentration in wastewater treatment process. The convergence of the learning algorithm and the stability of the feedforward neural network modeling and control system are proved based on the analysis of the learning rates of hidden layers in both controller neural network and modeling neural network. In applying this method to the Benchmark Simulation Model No.1 (BSM1), the simulation results reveal the importance of properly selecting the learning rates. Comparing with other control methods such as PID control method and model predictive control (MPC) method, we find that this method provides for the control process of DO concentration with desirable modeling ability and high control precision in steady-state as well as transient state.

Key words: dissolved oxygen; feedforward neural networks; modeling and control; stability; learning rate

1 引言(Introduction)

污水处理系统是一个大型的非线性系统, 它受到进水流量和污泥负荷中大的扰动以及进流污水中不确定的混合成分影响, 因此, 污水处理系统中的溶解氧浓度具有非线性、大时变、大滞后、干扰严重等特征^[1], 溶解氧浓度与进水组分浓度以及生化池组分的浓度具有非常强的耦合关系^[2]. 基于以上原因, 污水处理过程的溶解氧浓度控制问题存在较难达到控制精度和系统动态特性要求的难点. 针对污水处理过程溶解氧浓度的控制问题, 国内外学者做了大量的研究^[3-6]. 经典的PID控制在污水处理过程研究中得到了广泛应用^[3-4], 但是受限于污水处理过程的特点和建模精度问题, PID控制器的设计主要针对特定环境和运行工况. 很多学者对污水处理过程的模型预测控制(model predictive control, MPC)也进行了深入研究. Holender等人基于国际基

准的Benchmark Simulation Model No.1(BSM1)提出了针对污水处理溶解氧控制的MPC控制方法^[5]; Liu等人针对污水处理过程的特点提出了一种模型预测控制与PID串级的控制方法^[6], 但是目前模型预测控制研究的控制效果和建模精度仍然有待提高. 污水处理过程亟需先进的智能控制方法以提高控制效果和建模精度.

前馈神经网络因其结构特点, 近年来成为了国内外学者的研究热点, 合适的算法选取对于前馈神经网络的学习起着决定性的作用^[7]. 误差反向传播(BP)算法作为经典的神经网络训练算法, 一直以来都是国内外学者的研究热点^[8-9]. 神经网络权值的学习率对于应用BP算法的神经网络收敛性有很大的影响. Zhang等人通过采用动态学习率的方法证明了BP算法的全局收敛性^[8], Wang等人对输入样本进行周期化处理, 证明了误差反向传播算法在学习

率选取一定范围的情况下是收敛的^[9]. 研究表明, 采用BP算法的前馈神经网络在解决非线性、大时变系统的分析、控制与建模问题中是非常有效的工具^[10-12]. 国内外部分学者对于智能控制方法在污水处理过程中的应用做过一些先驱性的研究, Singh等人研究指出神经网络可以通过建模方法模拟污水处理过程的主要变量(溶解氧和生化需氧量等), 并且是非常有效的工具, 但是污水处理过程的控制仍然采用经典控制^[13]; 本课题组之前的研究中, Qiao等人提出利用一种动态结构的前馈神经网络(ACDSNN), 控制溶解氧的浓度, 取得了较好的控制效果, 但是污水处理过程的建模精度有待提高^[14].

本文针对污水处理过程的特点, 提出了一种基于前馈神经网络的建模控制方法, 并通过对神经网络学习率的研究, 对反向传播算法的收敛性和建模控制系统的稳定性进行了分析. 仿真研究表明, 神经网络建模控制方法针对污水处理过程中溶解氧浓度的控制问题, 具有良好的建模精度, 对比PID与MPC控制方法, 神经网络建模控制方法在污水处理过程溶解氧浓度控制中具有更高的控制精度以及更好的动态响应能力.

2 前置反硝化污水处理过程(Predinitrification wastewater treatment process)

为合理评价控制方法在污水处理系统中的性能, 国际水质协会(IWAQ)与欧盟科学技术与合作组织(COST)合作开发了活性污泥污水处理基准仿真

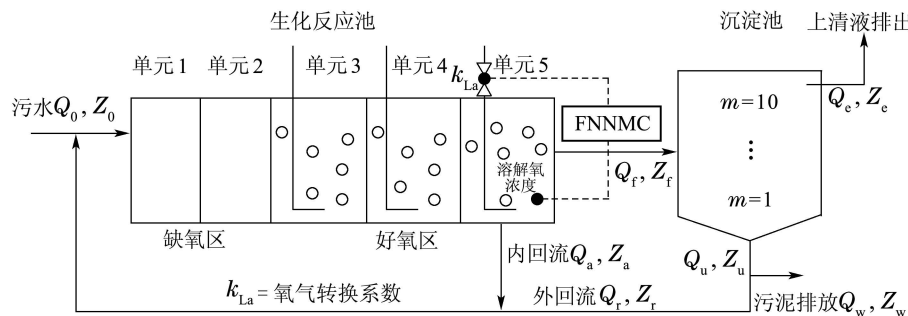


图1 BSM1布局结构

Fig. 1 General overview of BSM1

3 神经网络建模控制方法(Feedforward neural network modeling and control (FNNMC) method)

应用在污水处理过程中的神经网络建模控制方法结构如图2所示.

神经网络建模控制方法的原理是: 利用建模神经网络(modeling FNN)建立污水处理系统的神经网络模型, 并通过神经网络控制器(FNN controller)实现针对污水处理系统的控制. 神经网络控制器与建模神经网络均采用全连接的前馈神经网络,

模型BSM1(下面简称基准)^[1]. 基准仿真模型结合实际污水处理过程大时变、大滞后、非线性的特点和复杂的生化反应过程数学模型, 提供了模拟实际污水处理过程的仿真平台. 基准的总体布局如图1所示, 是典型的前置反硝化污水处理脱氮工艺. 系统由一个具有5个部分的生化反应池(6000 m³)和沉淀池(6000 m³)组成. 进水流量为20000 m³/天, 其中平均的可溶性化学需氧量(COD)浓度为300 mg/L. 取15°C作为温度值, 以保证出水组分对于系统运行的敏感度. 生化反应池前两个分区为缺氧区, 后3个分区为好氧区, 以IWAQ提出的活性污泥1号ASM1模型(activated sludge model No.1)为生化反应机理模型模拟生化反应过程^[15]; 二沉池分为10层, 采用二次指数沉淀速率模型模拟沉淀过程^[16]. 基准对生化反应池和二沉池的各个部分均做理想化处理.

研究表明, 第5分区的溶解氧浓度直接关系到出水的总氮(N_{tot})、氨氮(S_{NH})和硝态氮(S_{NO})的浓度, 对系统的脱氮效果起到决定性的影响^[1]. 在基准中, 对生化反应池第5分区的溶解氧浓度进行控制, 通过第5分区的氧气提供量(氧气传输系数K_{La5})实现. 第5分区的溶解氧浓度设定为2 mg/L. 对于生化池第5单元溶解氧浓度变化, 根据第5单元氧气量的物料守恒^[1],

$$\frac{dS_{O,5}}{dt} = \frac{1}{V_5} (Q_4 S_{O,4} + r_5 V_5 - Q_5 S_{O,5} + (K_{La5}) V_5 (S_{O,sat} - S_{O,5})). \quad (1)$$

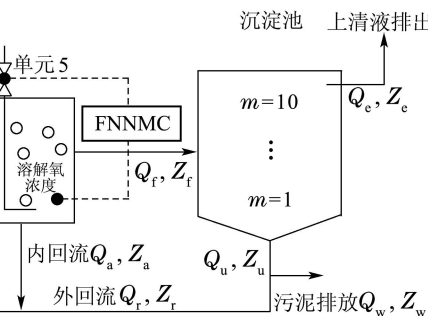


图2 神经网络建模控制系统

Fig. 2 Neural network modeling and controlling system

络, 隐层激活函数f采用sigmoid函数^[17]:

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (2)$$

3.1 建模神经网络设计(Modeling FNN design)

建模神经网络的设计针对污水处理过程模型未知的问题, 采用数据驱动的方法建立污水处理系统的数学模型, 其方法是: 建模网络输入为污水处理系统的控制量 $u(k)$, 并使得网络输出逼近污水处理系统的输出(溶解氧的设定值), 建模神经网络的输出可以表示为

$$y_m(k) = W_2^m(k)f(W_1^m(k)u(k)), \quad (3)$$

其中: $u(k)$ 为溶解氧的控制量, 作为建模神经网络的输入, $W_1^m(k)$ 代表建模神经网络输入层到隐含层之间的连接权值矩阵, $W_2^m(k)$ 代表建模神经网络隐含层到输出层之间的连接权值矩阵.

设置建模神经网络训练的性能指标为

$$J_m(k) = \frac{1}{2} e_m^2(k), \quad (4)$$

其中 $e_m(k) = y(k) - y_m(k)$ 为系统实际输出与网络输出的误差.

根据梯度下降算法, $W_1^m(k)$ 的变化量为

$$\begin{aligned} \Delta W_1^m(k) &= \frac{\partial J_m(k)}{\partial W_1^m(k)} = \\ &e_m(k) \frac{\partial (y(k) - y_m(k))}{\partial W_1^m(k)} = \\ &-e_m(k) \frac{\partial y_m(k)}{\partial W_1^m(k)} = \\ &-e_m(k) \frac{\partial W_2^m(k) f(W_1^m(k) u(k))}{\partial W_1^m(k)} = \\ &-e_m(k) W_2^m(k) \Phi(k) u(k), \end{aligned} \quad (5)$$

其中

$$\Phi(k) = f(W_1^m(k)u(k))(1 - f(W_1^m(k)u(k))). \quad (6)$$

所以, 权值 $W_1^m(k)$ 的更新可由式(7)表示:

$$\begin{aligned} W_1^m(k+1) &= W_1^m(k) - \eta_1^m(k) e_m(k) \Delta W_1^m(k) = \\ &W_1^m(k) + \eta_1^m(k) e_m(k) W_2^m(k) \Phi(k) u(k), \end{aligned} \quad (7)$$

其中 $\eta_1^m(k)$ 为权值 $W_1^m(k)$ 更新的学习率.

同理, 权值 $W_2^m(k)$ 的更新可由式(8)表示:

$$\begin{aligned} W_2^m(k+1) &= \\ &W_2^m(k) + \eta_2^m(k) e_m(k) f(W_1^m(k)u(k)), \end{aligned} \quad (8)$$

其中 $\eta_2^m(k)$ 为权值 $W_2^m(k)$ 更新的学习率.

3.2 神经网络控制器的设计(FNN controller design)

典型的非线性离散系统, 可以表述为

$$\mathbf{x}(k+1) = H(\mathbf{x}(k), \mathbf{u}(k)), \quad (9)$$

其中: $\mathbf{x}(k) \in \mathbb{R}^{D_x}$ 是状态变量, $\mathbf{u}(k) \in \mathbb{R}^{D_u}$ 是控

制变量, H 代表未知的非线性函数. 污水处理过程作为非线性离散系统, 可以由式(9)表征. 神经网络控制器的设计针对污水处理系统的非线性、大时变的特征, 实现对溶解氧浓度的高精度控制, 其方法是, 以溶解氧浓度设定值(DOsp)与系统实际输出的误差 $e(k) = r - y(k)$ 作为神经网络控制器的输入, 神经网络控制器的输出作为氧气传输系数 K_{La5} 的变化量, 实现溶解氧浓度的控制.

神经网络控制器的输出为

$$\mathbf{u}(k) = W_2^c(k)f(W_1^c(k)e(k)), \quad (10)$$

其中: $W_1^c(k)$ 代表神经网络控制器输入层到隐含层之间的连接权值矩阵, $W_2^c(k)$ 代表神经网络控制器隐含层到输出层之间的连接权值矩阵.

设置神经网络控制器的训练指标为

$$J_c(k) = \frac{1}{2} e^2(k). \quad (11)$$

根据梯度下降算法, $W_1^c(k)$ 的变化量为

$$\begin{aligned} \Delta W_1^c(k) &= \frac{\partial J_c(k)}{\partial W_1^c(k)} = e(k) \frac{\partial (r - y(k))}{\partial W_1^c(k)} = \\ &-e(k) \frac{\partial (y_m(k) + e_m(k))}{\partial W_1^c(k)} = \\ &-e(k) \frac{\partial W_2^m(k) f(W_1^m(k) u(k))}{\partial W_1^c(k)} = \\ &-e(k) W_2^m(k) \Phi(k) W_1^m(k) W_2^c(k) \Psi(k) e(k), \end{aligned} \quad (12)$$

其中

$$\Psi(k) = f(W_1^c(k)e(k))(1 - f(W_1^c(k)e(k))). \quad (13)$$

注1 建模神经网络的建模误差 $e_m(k)$ 是有界的, 所以, $e_m(k)$ 关于权值矩阵 $W_1^c(k)$ 的偏导数为0. 对于 $e_m(k)$ 有界性的讨论会在3.3节介绍.

权值 $W_1^c(k)$ 的更新可由式(14)表示:

$$\begin{aligned} W_1^c(k+1) &= \\ &W_1^c(k) + \eta_1^c(k) W_2^m(k) \Phi(k) W_1^m(k) W_2^c(k) \Psi(k) e(k), \end{aligned} \quad (14)$$

其中 $\eta_1^c(k)$ 为权值 $W_1^c(k)$ 调整的学习率.

同理, 权值 $W_2^c(k)$ 的更新可由式(15)表示:

$$\begin{aligned} W_2^c(k+1) &= \\ &W_2^c(k) + \eta_2^c(k) W_2^m(k) \Phi(k) W_1^m(k) f(W_1^c(k)e(k)), \end{aligned} \quad (15)$$

其中 $\eta_2^c(k)$ 为权值 $W_2^c(k)$ 更新的学习率.

3.3 神经网络建模控制系统的稳定性分析(Stability analysis of FNNMC system)

神经网络学习率的选取对于基于梯度下降算法的神经网络建模控制系统的稳定性有非常密切的关系^[8-9]. 通过李雅普诺夫定理对神经网络建模

系统的稳定性进行分析.

定理 1 对于建模神经网络, 当

$$0 < \eta_2^m(k) < \frac{2}{n_2},$$

建模神经网络的建模误差 $e_m(k)$ 是有界的. 其中 n_2 是建模神经网络隐含层神经元数目.

证 构造建模误差 $e_m(k)$ 的李雅普诺夫函数为

$$E(k) = \frac{1}{2}e_m^2(k) = \frac{1}{2}[e_m^2(k+1) - e_m^2(k)]. \quad (16)$$

明显地, $E(k) \geq 0$, 即 $E(k)$ 是半正定的.

$$\begin{aligned} \Delta E(k) &= E(k+1) - E(k) = \\ &= \frac{1}{2}[e_m^2(k+1) - e_m^2(k)], \end{aligned} \quad (17)$$

其中:

$$e_m(k+1) = e_m(k) + \Delta e_m(k), \quad (18)$$

$$\Delta e_m(k) = \sum_{i=1}^{n_2} \left[\frac{\partial e_m(k)}{\partial w_{2,i}^m(k)} \Delta w_{2,i}^m(k) \right], \quad (19)$$

其中 $w_{2,i}^m(k)$ 代表建模神经网络训练中隐含层的第 i 个神经元与输出层之间的连接权值.

$$\Delta w_{2,i}^m(k) = \eta_2^m(k) e_m(k) \frac{\partial y_m(k)}{\partial w_{2,i}^m(k)}. \quad (20)$$

将式(19)代入式(20), 有

$$\begin{aligned} \Delta e_m(k) &= \sum_{i=1}^{n_2} \left(\frac{\partial e_m(k)}{\partial w_{2,i}^m(k)} \eta_2^m(k) e_m(k) \frac{\partial y_m(k)}{\partial w_{2,i}^m(k)} \right) = \\ &= -\eta_2^m e_m(k) \sum_{i=1}^{n_2} \left(\frac{\partial y_m(k)}{\partial w_{2,i}^m(k)} \cdot \frac{\partial y_m(k)}{\partial w_{2,i}^m(k)} \right) = \\ &= -\eta_2^m(k) e_m(k) \left\| \frac{\partial y_m(k)}{\partial w_{2,i}^m(k)} \right\|^2, \end{aligned} \quad (21)$$

$$\begin{aligned} \Delta E(k) &= \\ &= \frac{1}{2} e_m^2(k) [(1 - \eta_2^m(k) \cdot \left\| \frac{\partial y_m(k)}{\partial w_{2,i}^m(k)} \right\|^2)^2 - 1]. \end{aligned} \quad (22)$$

因为建模神经网络的隐含层神经元采用sigmoid函数, 所以对于建模神经网络隐含层第 i 个神经元的输出值 $y_{i,Mhidden}$:

$$0 < y_{i,Mhidden} = \frac{\partial y_m(k)}{\partial w_{2,i}^m(k)} < 1. \quad (23)$$

对于具有 n_2 个隐含层神经元的建模神经网络:

$$0 < \left\| \frac{\partial y_m(k)}{\partial W_2^m(k)} \right\| < \sqrt{n_2}. \quad (24)$$

若 $0 < \eta_2^m(k) < \frac{2}{n_2}$, 那么

$$[(1 - \eta_2^m(k) \cdot \left\| \frac{\partial y_m(k)}{\partial w_{2,i}^m(k)} \right\|^2)^2 - 1] < 0. \quad (25)$$

又因为 $e_m^2(k) \geq 0$, 所以 $V(y(k)) \leq 0$.

当 $\|e_m(k)\| \rightarrow 0$ 时, $\|E(k)\| \rightarrow 0$.

所以由李雅普诺夫定理, 定理1得证. 建模神经网络的误差是有界的. 证毕.

定理 2 对于神经网络控制器, 当

$$0 < \eta_2^c(k) < \frac{2}{n_1 \cdot G(k)},$$

其中定义

$$G(k) = \|W_2^m(k)\|^2 \|W_1^m(k)\|^2 \Phi^2(k),$$

$$\Phi(k) = f(W_1^m(k)u(k))(1 - f(W_1^m(k)u(k))).$$

那么, 基于神经网络建模控制方法的控制系统是稳定的. 其中 n_1 是神经网络控制器隐含层神经元数目.

证 定义建模控制系统的李雅普诺夫函数为

$$V(y(k)) = \frac{1}{2}e^2(k) = \frac{1}{2}(r - y(k))^2. \quad (26)$$

明显地, $V(y(k)) \geq 0$.

$$\begin{aligned} \Delta V(y(k)) &= V(y(k+1)) - V(y(k)) = \\ &= \frac{1}{2}(e^2(k+1) - e^2(k)), \end{aligned} \quad (27)$$

其中

$$e(k+1) = e(k) + \Delta e(k). \quad (28)$$

对 $e(k)$ 展开有

$$\Delta e(k) = -\eta_2^c(k) e(k) G(k) \left\| \frac{\partial u(k)}{\partial w_{2,i}^c(k)} \right\|^2, \quad (29)$$

$$\begin{aligned} \Delta V(y(k)) &= \\ &= \frac{1}{2} e^2(k) [(1 - \eta_2^c(k) G(k) \left\| \frac{\partial u(k)}{\partial w_{2,i}^c(k)} \right\|^2)^2 - 1]. \end{aligned} \quad (30)$$

同样, 对于采用sigmoid函数作为隐含层激活函数并具有 n_1 个神经元的神经网络控制器:

$$0 < \left\| \frac{\partial u(k)}{\partial w_{2,i}^c(k)} \right\| < \sqrt{n_1}, \quad (31)$$

则有, 当 $0 < \eta_2^c(k) < \frac{2}{n_1 G(k)}$ 时,

$$[(1 - \eta_2^c(k) G(k) \left\| \frac{\partial u(k)}{\partial w_{2,i}^c(k)} \right\|^2)^2 - 1] < 0. \quad (32)$$

同时, $e_2(k) \geq 0$, 所以 $V(y(k)) \leq 0$.

当 $\|y(k)\| \rightarrow 0$, $\|V(y(k))\| \rightarrow 0$.

所以由李雅普诺夫定理, 定理2得证. 证毕.

神经网络建模控制方法根据定理1和定理2选取合适的 $\eta_2^c(k)$ 和 $\eta_2^m(k)$ 时, 能够保证控制系统的稳定性.

4 仿真实验(Simulations)

基准将仿真污水处理过程的运行工况分为3种

不同的类型: 晴好天气、阴雨天气和暴雨天气. 实验仿真平台软件为MATLAB.R2010b. 仿真数据选取时间14天, 采样时间为15 min, 本文选取阴雨天气的工况进行仿真. 阴雨天气包括前7天的晴好天气和在第8至11天的一个长段时间的持续降雨过程, 同时每周末(周六、周日)的进水数据与周中(周一至周五)也有较大变化(进水和组分浓度均减小, 范围在20%左右). 针对系统的控制效果评价, 基准主要基于以下几个指标: ISE(平方误差积分), IAE(绝对误差积分), Max Dev(最大偏差)^[1].

$$\begin{cases} \text{ISE}_i = \int_{t_0}^{t_f} e_i^2 dt, \\ \text{IAE}_i = \int_{t_0}^{t_f} |e_i| dt, \\ \text{Dev}_i^{\max} = \max |e_i|, \end{cases} \quad (33)$$

其中 e_i 代表误差.

4.1 神经网络建模控制系统的稳定性(Simulation of FNNMC system stability)

本文所选取的神经网络为固定结构的前向神经网络, 需要在仿真前进行神经网络结构的确定, 以保证网络的学习能力和泛化能力^[18-20]. 基于研究团队之前对于神经网络结构的研究^[18-19], 确定仿真试验中设定两个神经网络的结构均为1-10-1, 即 $n_1 = n_2 = 10$, 根据定理1和2, $\eta_2^c(k)$ 和 $\eta_2^m(k)$ 选取应该满足

$$\begin{cases} 0 < \eta_2^c(k) < \frac{2}{10G(k)} = \frac{0.2}{G(k)}, \\ 0 < \eta_2^m(k) < 0.2. \end{cases} \quad (34)$$

分别取 $\eta_2^m(k) = 0.1, 0.05, 0.15$, 此时, $\eta_2^m(k)$ 的选取满足定理1的要求, 建模神经网络的建模效果如表1和图3所示.

如图3和表1所示, 在 $\eta_2^m(k)$ 的选取满足定理1的要求时, 建模神经网络的学习和建模过程是收敛的, 建模神经网络实现了建模. 其中 $\eta_2^m(k) = 0.1$ 时, 建模神经网络取得了最好的建模效果. 仿真结果从实验的角度验证了定理1. 说明建模神经网络隐含层学习率的选取影响整个系统的建模精度.

基于图3和表1的实验结果, 取 $\eta_2^m(k) = 0.1$, 通过对 $\eta_2^c(k)$ 的选取比较验证系统的稳定性.

表 1 建模神经网络的建模效果

Table 1 Modeling results of modeling neural network

$\eta_2^m(k)$	ISE	IAE	Max Dev
0.1	4.37×10^{-4}	0.0035	0.0912
0.05	6.61×10^{-4}	0.0167	0.0988
0.15	1.25×10^{-3}	0.0232	0.1339






图3 建模神经网络的建模效果图

Fig. 3 Comparisons of modeling results of modeling NN

应用神经网络建模控制方法对污水处理系统进行800步(即800个采样时间, 约8天)的控制. 图4表示, 在 $\eta_2^m(k) = 0.1$ 时, $\eta_2^c(k)$ 的选取对于系统有着重要的影响. 如图4(c)与图4(d)所示, 当 $\eta_2^c(k) = \frac{0.19}{G(k)} < \frac{0.2}{G(k)}$ 时, 神经网络控制器的隐含层学习率与建模神经网络的隐含层权值是收敛的, 说明在这个条件下, 整个系统是稳定的; 如图4(a)与图4(b)所示, 当 $\eta_2^c(k) = \frac{0.21}{G(k)} > \frac{0.2}{G(k)}$ 时, 神经网络控制器的隐含层学习率与建模神经网络的隐含层权值是发散的, 说明在此情况下, 整个神经网络建模控制系统是不稳定的. 仿真结果从实验的角度验证了定理2, 说明神经网络控制器隐含层学习率的选取影响着整个系统的稳定性.



(a) $\eta_2^c(k) = \frac{0.21}{G(k)}$



(b) $\eta_2^c(k) = \frac{0.21}{G(k)}$




图4 $\eta_2^m(k) = 0.1$ 时, W_2^m 和 $\eta_2^c(k)$ 的收敛情况

Fig. 4 The convergence of W_2^m and $\eta_2^c(k)$ when $\eta_2^m(k) = 0.1$

4.2 溶解氧浓度控制效果(Control performance of DO concentration)

仿真试验中设定 $\eta_2^c(k)$ 和 $\eta_2^m(k)$ 选取如式(35):

$$\begin{cases} \eta_2^c(k) = \frac{0.1}{G(k)}, \\ \eta_2^m(k) = 0.1, \end{cases} \quad (35)$$

学习率选择满足定理1和定理2. 采用建模控制方法对生化池第5分区的溶解氧浓度进行控制, 并与Ayesa等^[3]研究的PID控制方法, Holenda等^[5]研究的MPC控制方法进行了比较, 神经网络建模控制方法基于的仿真环境与数据与以上两种控制方法相同.

如图5所示, 神经网络建模控制方法在学习率如式(35)所示的选取方式时, 整个系统是收敛的. 在图5中直观的表现出, 神经网络建模控制方法在控制精度上要明显优于Ayesa等人提出的PID控制方法.

表2通过ISE, IAE和最大偏差3个方面对神经网络建模控制方法与其他控制方法进行了对比. PID控制方法和MPC控制方法的结果分别在Ayesa^[3]和Holender^[5]的论文中给出. 从表中数据的直观比较可看出, 神经网络建模控制方法的ISE值 $4.37 \times$

10^{-4} , IAE值0.0035与最大偏差值0.0912, 要优于PID控制方法的ISE值 3.11×10^{-3} , IAE值0.218与最大偏差值0.1885及MPC控制方法的ISE值 2.60×10^{-3} , IAE值0.089与最大偏差值0.1254.

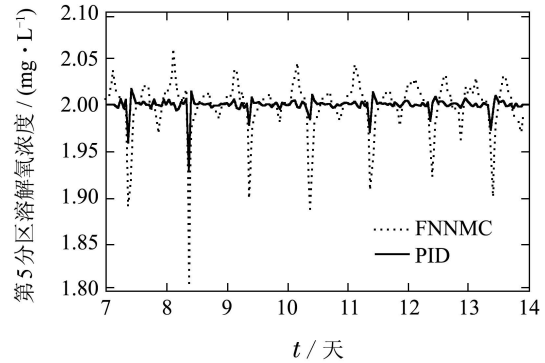


图5 神经网络建模控制方法的控制效果图

Fig. 5 Comparisons of DO control accuracy

表2 神经网络建模控制方法的控制效果

Table 2 Comparisons of DO control accuracy

	ISE	IAE	Max Dev
FNNMC	4.37×10^{-4}	0.0035	0.0912
PID	3.11×10^{-3} *	0.218*	0.1885
MPC	2.60×10^{-3} *	0.089*	0.1254

注: *表示原文如此.

图6从分析系统动态性能的角度, 展示了在溶解氧浓度发生阶跃变化时, 神经网络建模控制方法与PID控制方法的控制效果对比. 分别从溶解氧浓度设定值由2上升跃变至2.2, 及溶解氧浓度设定值从2.2降低跃变值1.8进行分析. 为反映系统的动态特性, 取浓度变化后的前12个小时作为分析依据, 如图6中两幅小图所示, 神经网络建模控制与PID控制^[3]动态性能数值比较在表3中列出, 两种控制方法的仿真基于同样的实验环境.

如图6与表3所示, 神经网络建模控制在溶解氧浓度设定值分别发生从2至2.2的阶跃跳变以及2.2至1.8的阶跃跳变时, 超调量和最大偏差分别为1.36%和0.03 mg/L以及1.28%和0.23 mg/L, 均优于PID控制的数据. 基于图6和表3, 可以得到这样的结论: 在系统溶解氧浓度设定值发生阶跃变化的时候, 神经网络建模控制方法对比于PID控制方法的动态性能更好, 响应后的超调量以及震荡幅度小, 能够更快的追踪设定值的变化. 这意味着在大时变、非线性、耦合严重的污水处理过程中, 神经网络建模控制方法能够更好的对污水处理系统中突发工况进行响应.




图6 神经网络建模控制方法的阶跃响应控制

Fig. 6 Step response control of dissolved oxygen

表3 阶跃响应系统动态性能的对比

Table 3 Dynamic performance analysis of step response control

	2至2.2的阶跃		2.2至1.8的阶跃	
	超调量	最大偏差	超调量	最大偏差
FNNMC	1.36%	0.03	1.28%	0.23
PID	3.18%	0.07	2.33%	0.042

注: 表中除超调量外的数据单位为浓度($\text{mg}\cdot\text{L}^{-1}$).

5 结论(Conclusions)

本文针对污水处理过程溶解氧浓度的控制问题, 提出了一种基于前馈神经网络的建模控制方法. 本文构造了神经网络建模控制系统, 通过对建模神经网络和控制神经网络隐含层学习率分析证明了算法的收敛性以及整个系统的稳定性, 并提出了一种保证控制系统稳定的学习率选取方法. 仿真基于国际标准的BSM1, 验证了建模控制方法的有效性, 说明前馈神经网络具有很高的建模精度, 并通过与PID和MPC等控制方法相比较, 验证了神经网络建模控制方法针对污水处理过程溶解氧浓度控制具有更高的精度以及更好动态响应能力.

参考文献(References):

- [1] *The cost simulation benchmark-description and simulator manual* [R]. Luxembourg: Office for Publications of the European Community, 2001.
- [2] GARRIDO J M, VAN BENTHUM W A J, VAN LOOSDRECHT M C M. Influence of dissolved oxygen concentration on nitrite accumulation in a biofilm airlift suspension reactor [J]. *Biotechnology and Bioengineering*, 1997, 53(2): 168 – 178.
- [3] AYESA E, SOTA A D, 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.
- [4] CARLSSON B, REHNSTROM A. Control of an activated sludge process with nitrogen removal—a benchmark study [J]. *Water Science and Technology*, 2002, 45(4/5): 135 – 142.
- [5] HOLENDA B, 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] LIU H, YOO C. Performance assessment of cascade controllers for nitrate control in a wastewater treatment process [J]. *Korean Journal of Chemical Engineering*, 2012, 28(3): 667 – 673.
- [7] WU W, WAN J, CHENG M, et al. Convergence analysis of online gradient method for BP neural networks [J]. *Neural Networks*, 2010, 24(1): 91 – 98.
- [8] ZHANG R, XU Z, HUANG G, et al. Global convergence of online BP training with dynamic learning rate [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2012, 32(2): 330 – 341.
- [9] WANG J, WANG J, WU W. Convergence of cyclic and almost-cyclic learning with momentum for feedforward neural networks [J]. *IEEE Transactions on Neural Networks*, 2011, 22(8): 1297 – 1306.
- [10] NARENDRA K S, PARTHASARATHY K. Identification and control of dynamical systems using neural networks [J]. *IEEE Transactions on Neural Networks*, 1990, 1(1): 4 – 27.
- [11] ZHANG H, CUI L, ZHANG X, et al. Data-driven robust approximate optimal tracking control for unknown general nonlinear systems using adaptive programming method [J]. *IEEE Transactions on Neural Networks*, 2011, 1(1): 2226 – 2236.
- [12] 王伟, 吴敏, 雷琪, 等. 炼焦生产过程综合生产指标的改进神经网络预测方法 [J]. *控制理论与应用*, 2009, 26 (12): 1419 – 1424. (WANG Wei, WU Min, LEI Qi, et al. An improved neural network method for the prediction of comprehensive production indices in coking process [J]. *Control Theory & Applications*, 2009, 26(12): 1419 – 1424.)
- [13] SINGH K P, BASANT A, MALIK A, et al. Artificial neural network modeling of the river water quality-A case study [J]. *Ecological Modelling*, 2009, 220(6): 888 – 895.
- [14] HAN H, QIAO J. Adaptive dissolved oxygen control based on dynamic structure neural network [J]. *Applied Soft Computing*, 2011, 11(4): 3812 – 3820.
- [15] HENZE M, GRADY C P L J, GAUJER W, et al. *Activated sludge model No.1* [R]. London, UK: IAWPRC, 1987.
- [16] TAKACS I, PARTY G, NOLASCO D. A dynamic model of the clarification thickening process [J]. *Water Research*, 1991, 25(10): 1263 – 1271.
- [17] LRIE B, MIYAKE S. Capabilities of three layer perceptrons [C] // *The 2nd IEEE International Conference on Neural Networks*. New York: IEEE, 1998: 641 – 648.
- [18] HAN H, QIAO J. A self-organizing fuzzy neural network based on a growing-and-pruning algorithm [J]. *IEEE Transactions on Fuzzy Systems*, 2010, 18(6): 1129 – 1143.
- [19] 乔俊飞, 韩红桂. 神经网络结构动态优化设计的分析与展望 [J]. *控制理论与应用*, 2010, 27(3): 350 – 357. (QIAO Junfei, HAN Honggui. Dynamic optimization structure design for neural networks: review and perspective [J]. *Control Theory & Applications*, 2010, 27(3): 350 – 357.)
- [20] 何述东, 瞿坦, 黄献青, 等. 多层前向神经网络的研究进展 [J]. *控制理论与应用*, 1998, 15(3): 313 – 319. (HE Shudong, QU Tan, HUANG Xianqing, et al. Survey of Architecture for Multilayer Feedforward Neural Networks [J]. *Control Theory & Applications*, 1998, 15(3): 313 – 319.)

作者简介:

韩广 (1987-), 男, 博士研究生, 目前研究方向为污水处理智能优化控制、神经网络分析与设计, E-mail: nerual07@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、神经网络分析与设计, E-mail: isibox@sina.com;

薄迎春 (1977-), 男, 博士研究生, 目前研究方向为过程控制、智能优化控制、神经网络分析与设计, E-mail: boyingchun@sina.com.