

基于自适应递归模糊神经网络的污水处理控制

韩改堂, 乔俊飞[†], 韩红桂

(北京工业大学电子信息与控制工程学院, 北京 100124; 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具有的非线性、大时变等特征, 提出了一种基于自适应递归模糊神经网络(recurrent fuzzy neural network, RFNN)的污水处理控制方法。该方法利用自适应RFNN识别器建立污水处理过程的非线性动态模型, 建立的模型可以为RFNN控制器提供污水处理过程中的状态变量信息, 保证了控制器根据系统响应调整操作变量的精确性; 并且RFNN辨识器及RFNN控制器基于自适应学习率进行学习, 确保了递归模糊神经网络的收敛精度和速度, 并通过构造李雅普诺夫函数证明了此算法的收敛性; 最后, 基于基准仿真模型(benchmark simulation model 1, BSM1)平台进行仿真实验。结果表明, 与PID、模型预测控制及前馈神经网络相比, 该方法对污水处理中溶解氧浓度和硝态氮浓度的跟踪控制精度具有明显的提升。

关键词: 污水处理; 递归模糊神经网络; 自适应学习率; 基准仿真模型(BSM1)

中图分类号: TP273 文献标识码: A

Wastewater treatment control method based on adaptive recurrent fuzzy neural network

HAN Gai-tang, QIAO Jun-fei[†], HAN Hong-gui

(College of Electronic Information & Control Engineering, Beijing University of Technology, Beijing 100124, China;
Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing 100124, China)

Abstract: Due to the nonlinear and highly time-varying issues of wastewater treatment processes, a wastewater treatment control method based on adaptive recurrent fuzzy neural network (RFNN) is proposed. Firstly, the adaptive RFNN identifier is used to establish the nonlinear dynamic model of wastewater treatment process. The model can afford the state variable information of wastewater treatment process to RFNN controller, which can ensure the accuracy of manipulated variable is adjusted by controller. Secondly, RFNN identifier and RFNN controller are learning through gradient descent algorithm with an adaptive learning rate, which guarantee the convergence of learning process of RFNN, and a function is constructed by lyapunov theory to prove the convergence of this algorithm. Finally, the simulation experiment carried out based on BSM1 platform. Compared with PID, model predictive control and forward neural network control techniques, the simulation results show that the proposed method can improve obviously the control accuracy of wastewater treatment.

Key words: wastewater treatment; recurrent fuzzy neural network; adaptive learning rate; benchmark simulation model 1 (BSM1)

1 引言(Introduction)

活性污泥法是污水处理厂中常见的污水处理方法, 其过程机理是利用微生物的生化反应降解污水中所含污染物, 具有非线性、大时变的特点, 是一个复杂动态系统。因此, 采用常规控制方法^[1]以及模型预测控制(model predictive control, MPC)技术^[2]很难有效地对污水处理过程进行精确控制。

近年来, 随着智能控制理论的发展, 智能仿生技术在非线性系统建模及控制方面的有效性引起了国内外研究学者的广泛关注, 其中尤以模糊系统和神经网

络的应用最为流行^[3-7]。Belchior等设计了一种结合自适应模糊控制策略和监督模糊控制的反馈跟踪方法对溶解氧控制, 实验表明此方法性能优于PI控制器及常规模糊控制方法, 提高了溶解氧浓度的跟踪控制精度, 但模糊系统中固定的模糊参数难以适应进水污染物浓度及进水流量的剧烈变化, 因此控制精度有待提高^[8]。Zeng等人采用反向传播(back propagation, BP)神经网络模型建立了污染物的去除率和化学药物添加量之间的非线性关系, 并提出对BP网络训练复杂且存在局部极小值进行研究可以提高网络的建模精度,

收稿日期: 2015-12-07; 录用日期: 2016-06-16。

[†]通信作者。E-mail: junfeiq@bjut.edu.cn; Tel.: +86 13801263545。

本文责任编辑: 吴敏。

国家自然科学基金项目(61622301, 61533002, 61225016), 北京市教育委员会科研计划项目(KZ201410005002, km201410005001), 教育部博士点基金项目(20131103110016)资助。

Supported by National Natural Science Foundation of China (61622301, 61533002, 61225016), Beijing Municipal Education Commission Science and Technology Development Program under Grant (KZ201410005002, km201410005001) and Ph.D. Programs Foundation of Ministry of Education of China (20131103110016).

但BP神经网络作为前馈静态网络难以模拟污水处理中的动态信息^[9]。Qiao等通过BP神经网络对污水处理进行在线建模控制策略, 辨识器为控制器提供模型信息, 提升了溶解氧的控制精度, 但由于污水处理中硝态氮的生化反应机理比较复杂、动态性比较强, 因此采用BP神经网络对硝态氮浓度的控制效果并不理想^[10]。张等针对污水处理过程溶解氧浓度的控制问题, 基于模糊神经网络提出一种直接自适应控制方法, 该方法有效提高了溶解氧浓度的控制精度, 但此文没有针对硝态氮控制进行研究^[11]。总之, 基于模糊控制和基于前馈神经网络的污水处理控制方法虽然在一定程度上提高了污水处理过程控制精度, 但污水处理过程是一个大时变动态系统, 模糊控制系统和前馈神经网络很难把握污水处理过程中的动态特性, 因此控制精度有待提高。

文中针对模糊控制技术和前馈神经网络无法拟合污水处理过程中动态特性的问题, 提出一种基于递归模糊神经网络在线建模污水处理控制方法, 递归模糊神经网络集合了模糊系统的模糊推理能力和递归神经网络的动态响应能力, 能够有效地模拟非线性动态系统中状态变量的变化, 已经被广泛应用于非线性动态系统^[12-17]。所提方法包含RFNN辨识器和RFNN控制器, 辨识器对污水处理过程进行建模, 并为控制器提供控制对象的模型信息, 控制器根据模型信息和反馈误差自适应调整控制量的输出。神经网络学习中, 采用自适应学习率的方法保证了网络的收敛速度, 并通过构造李雅普诺夫函数证明了网络的收敛性。最后, 基于BSM1平台进行实验验证了所提方法的有效性。

2 前置反硝化污水处理工艺(A/O wastewater treatment process)

在污水处理厂中, 污水处理过程多采用活性污泥法清除污水中的污染物, 其中最常用的工艺为前置反硝化(A/O)生物脱氮技术, 其工艺布局如图1所示。A/O工艺主要包含生化反应池和二沉池两部分。生化反应池是消除有机污染物的主要阶段, 通过生化反应A/O工艺可以分解污水中的含氮化合物。二沉池主要通过物理沉降原理使泥水分离, 上层清水排入受纳水体, 下层沉淀污泥一部分通过外回流返回生化反应池循环利用以节省成本。

A/O工艺中溶解氧浓度和硝态氮浓度的控制非常重要, 能否对其有效控制直接决定了污水处理的运行状态。由于A/O工艺主要依赖于生化反应分解有机污染物, 致使溶解氧浓度和硝态氮浓度的控制过程中存在非线性动态特性和控制耦合现象, 因此对这一过程的控制具有很大的难度。针对这些问题, 笔者提出基于递归模糊神经网络的在线建模污水处理控制方法, 通过辨识器建立了精确的污水处理过程模型, 为控制器调整控制量输出提供污水处理过程中的状态变量

信息, 保证了控制系统的控制精度, 并通过对RFNN神经网络的结构拆分调整, 一定程度上缓解了溶解氧浓度和硝态氮浓度控制之间的耦合现象, 取得了良好的控制效果。

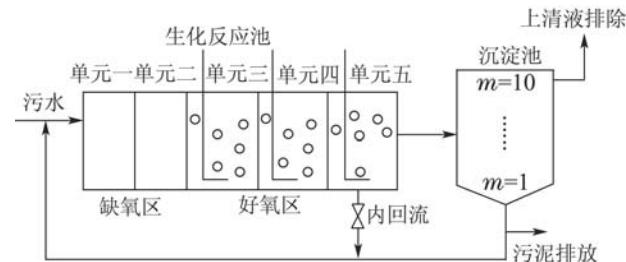


图1 AO工艺布局图

Fig. 1 The layout of AO

3 控制系统设计(Control system design)

3.1 控制系统结构设计 (Control system architecture design)

污水处理过程具有非线性、大时变的特点, 是一个复杂的动态系统, 其机理模型用常规方法难以建立, 而复杂系统控制的稳定性在生产运行中尤为重要, 因此, 能否掌握污水处理过程中的模型信息, 从而使污水处理控制稳定有效的进行具有重要意义。通过递归模糊神经网络对污水处理过程进行建模, 建立的模型可以为控制器提供污水处理过程的对象信息, RFNN神经网络很好地模拟了污水处理过程中状态变量的变化。控制系统结构如图2所示。

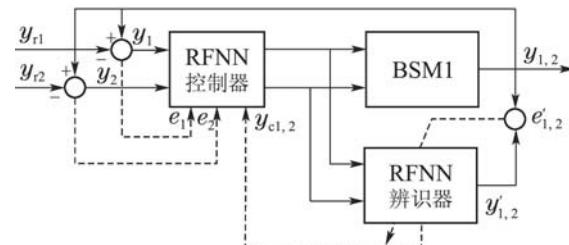


图2 基于RFNN的污水处理在线建模控制系统

Fig. 2 The online modeling control system of wastewater treatment based on RFNN

图2中: y_{r1}, y_{r2} 分别为溶解氧浓度和硝态氮浓度的设定值, y_1, y_2 分别为溶解氧和硝态氮的实际输出值, y'_1, y'_2 分别为神经网络的溶解氧和硝态氮预测值, $y_{c1,2}$ 代表神经网络辨识器为神经网络控制器反传的模型信息, e 为设定值与实际输出值之间的误差, e' 为神经网络预测值与实际输出值之间的误差, u_1, u_2 分别为 k_{La} 与 Q_a 。

3.2 RFNN结构设计(RFNN structure design)

3.2.1 RFNN 辨识器结构设计 (RFNN identifier structure design)

递归模糊神经网络同时具备模糊系统的模糊推理能力和递归神经网络的动态响应能力, 能够有效地模

拟污水处理过程的动态特性,因此采用递归神经网络作为辨识器对污水处理过程进行建模。一个典型的MIMO RFNN网络拓扑结构如图3所示。

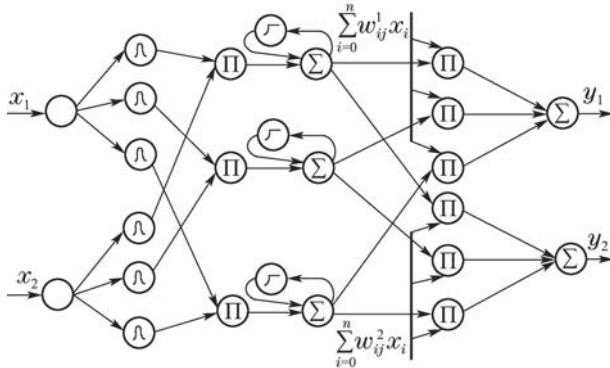


图3 典型MIMO RFNN网络结构

Fig. 3 Network structure of the general MIMO RFNN

通过污水处理过程中产生的实际输入输出数据对,经过如图3所示网络结构的RFNN辨识器,可以建立污水处理过程的动态模型。RFNN辨识器输入输出关系表达式为

$$\dot{\mathbf{Y}}(k) = \mathbf{G}(\mathbf{X}(k), \mathbf{u}(k)), \quad (1)$$

其中:

$$\mathbf{X}(k) = (\mathbf{w}(k), \boldsymbol{\mu}(k), \boldsymbol{\sigma}(k)), \quad (2)$$

$$\mathbf{u}(k) = [k_{La} \ Q_a]^T, \quad (3)$$

$$\dot{\mathbf{Y}}(k) = [Q_0 \ S_{NO}]^T. \quad (4)$$

\mathbf{w} 为RFNN网络后件权值矩阵, $\boldsymbol{\mu}$ 和 $\boldsymbol{\sigma}$ 分别为隶属函数层中隶属度函数的均值和方差, \mathbf{u} 为RFNN辨识器的输入向量, k_{La} 为氧传递系数, Q_a 为内回流量, Q_0 为溶解氧浓度, S_{NO} 为硝态氮浓度。

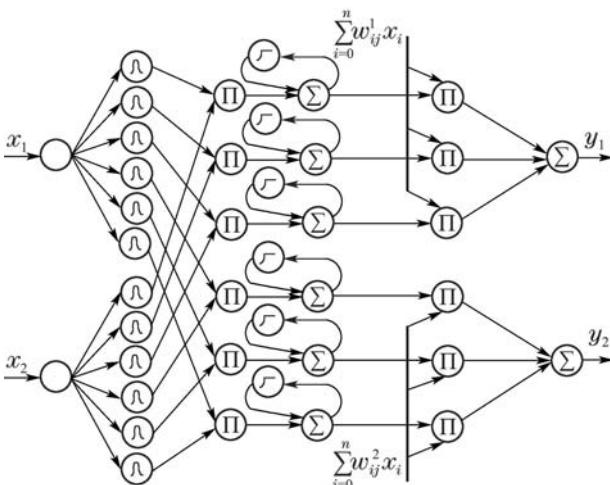


图4 拆分MIMO RFNN网络结构

Fig. 4 Network structure of the Split MIMO RFNN

RFNN辨识器通过状态变量 \mathbf{X} 映射 k_{La} , Q_a 与 Q_0 , S_{NO} 之间的非线性关系。由于 \mathbf{X} 需同时映射多个输入

与多个输出之间的非线性关系,因此在学习过程中,各个输出变量的逼近容易互相干扰,从而导致逼近精度降低。针对此问题,通过把神经网络进行拆分来消除这个影响,拓扑结构如图4所示。

拆分后RFNN的输入输出关系表达式为

$$\dot{\mathbf{Y}}(k) = \mathbf{G}(\mathbf{X}_1(k), \mathbf{X}_2(k), \mathbf{u}(k)), \quad (5)$$

其中:

$$\mathbf{X}_1 = (\mathbf{w}_1(k), \boldsymbol{\mu}_1(k), \boldsymbol{\sigma}_1(k)), \quad (6)$$

$$\mathbf{X}_2 = (\mathbf{w}_2(k), \boldsymbol{\mu}_2(k), \boldsymbol{\sigma}_2(k)), \quad (7)$$

式中 \mathbf{X}_1 和 \mathbf{X}_2 均为未知的状态变量,分别模拟一个网络输出对应于网络输入的非线性动态关系。拆分后信号在网络的传输过程中各层的输入输出关系描述如下:

第1层 输入层. 该层的各输入为输入变量, 网络的输入输出关系为

$$o_i^{(1)} = x_0. \quad (8)$$

第2层 隶属函数层. 每个节点代表一个隶属函数, 采用高斯函数作为隶属函数:

$$o_{p,ij}^{(2)} = \exp\left[\frac{1}{2}\left(\frac{u_j^{(2)} - \mu_{ij}^{(p)}}{\sigma_{ij}^{(p)}}\right)\right], \quad j = 1, 2, \dots, m, \quad (9)$$

其中: $\mu_{ij}^{(p)}$ 和 $\sigma_{ij}^{(p)}$ 分别代表第 p 个输出映射关系的第 i 个输入变量的第 j 个隶属函数的均值和方差, m 为每个输入变量的隶属度函数个数。

第3层 规则层. 此层每个节点代表一个迷糊逻辑规则, 采用乘积函数作为激活函数:

$$o_{pj}^{(3)} = \prod_{i=1}^n u_{p,ij}^{(3)}. \quad (10)$$

第4层 递归层. 在此层加入动态反馈, 反馈环节引入内部变量 q_{pj} , 选用线性加和函数作为激活函数:

$$o_{pj}^{(4)} = u_{pj}^{(4)} + q_{pj}(k), \quad (11)$$

$$q_{pj}(k+1) = \frac{1}{1 + \exp(o_{pj}^{(4)}(k))}. \quad (12)$$

第5层 后件层. 在此层的每个节点执行TS型模糊规则的线性求和. 数学表达式如下:

$$o_{pj}^{(5)} = o_{pj}^{(4)} \sum_{i=0}^n w_{ij}^p x_i. \quad (13)$$

第6层 输出层, 即去模糊化层. 该层节点对其输入量进行求和操作.

$$y_p = \sum_{j=1}^m o_{pj}^{(5)} / \sum_{j=1}^m o_{pj}^{(4)}. \quad (14)$$

在式(8)–(14)中: $i = 1, 2, \dots, n$, $p = 1, 2, \dots, N_0$, n 为神经网络输入维数, m 为神经网络规则数, N_0 为神经网络输出维数。

3.2.2 RFNN 控制器结构设计 (RFNN controller structure design)

RFNN控制器结构同图4所示拓扑方式, 其输入输出关系表达式为

$$\mathbf{Y}^C(k) = \mathbf{G}^C(\mathbf{X}_1^C(k), \mathbf{X}_2^C(k), \mathbf{u}^C(k)), \quad (15)$$

其中:

$$\mathbf{u}^C(k) = [e_1 \ e_2]^T, \quad (16)$$

$$\mathbf{Y}^C(k) = [\Delta k_{La} \ \Delta Q_a]^T. \quad (17)$$

e_1 为溶解氧设定值与实际输出值之间的误差, e_2 为硝态氮设定值与实际输出值之间的误差, \mathbf{X}_1^C 表示为 e_1 , e_2 与 Δk_{La} 之间的非线性映射关系, \mathbf{X}_2^C 表示为 e_1 , e_2 与 ΔQ_a 之间的非线性映射关系.

3.3 参数学习(Parameter learning)

RFNN辨识器的参数学习算法采用梯度下降法, 在线学习参数包括前件参数和后件参数. 设置辨识器在线学习性能指标为

$$J(k) = \frac{1}{2} \sum_{p=1}^2 (y_p - y'_p)^2. \quad (18)$$

根据第3.2节中RFNN辨识器的结构设计, y'_1 对 y_1 的逼近及 y'_2 对 y_2 的逼近在学习时互不干扰, 因此辨识器网络的参数更新分为两部分同时进行. 各参数更新公式为

$$w_{ij}^p(k+1) = w_{ij}^p(k+1) - \eta_{p,ij}^w \frac{\partial J(k)}{\partial w_{ij}^p}, \quad (19)$$

$$\mu_{ij}^p(k+1) = \mu_{ij}^p(k+1) - \eta_{p,ij}^\mu \frac{\partial J(k)}{\partial \mu_{ij}^p}, \quad (20)$$

$$\sigma_{ij}^p(k+1) = \sigma_{ij}^p(k+1) - \eta_{p,ij}^\sigma \frac{\partial J(k)}{\partial \sigma_{ij}^p}. \quad (21)$$

根据梯度算法, 各参数 k 时刻的梯度值如式(22)–(24)所示. RFNN控制器的参数学习同样采用梯度下降法, 在线学习参数包括前件参数和后件参数. 辨识器为控制器提供的污水处理过程模型信息如式(25)所示. 控制器参数更新过程在式(25)的模型信息的基础上与式(17)–(22)一致, 只需把 e_p 替换为式(25)即可, 在此不再详述.

$$\begin{aligned} \Delta w_{ij}^p &= \eta_{p,ij}^w \frac{\partial J(k)}{\partial w_{ij}^p} = \\ &\eta_{p,ij}^w \frac{\partial J(k)}{\partial y_p} \frac{\partial y_p}{\partial o_{pj}^{(5)}} \frac{\partial o_{pj}^{(5)}}{\partial w_{ij}^p} = -e_p \frac{o_{pj}^{(4)}}{\sum_{j=1}^m o_{pj}^{(4)}}, \end{aligned} \quad (22)$$

$$\begin{aligned} \Delta \mu_{ij}^p &= \eta_{p,ij}^\mu \frac{\partial J(k)}{\partial \mu_{ij}^p} = \\ &\eta_{p,ij}^\mu \frac{\partial J(k)}{\partial y_p} \frac{\partial y_p}{\partial u_{pj}^{(5)}} \frac{\partial u_{pj}^{(5)}}{\partial \mu_{ij}^p} \frac{\partial u_{pj}^{(4)}}{\partial u_{pj}^{(3)}} \frac{\partial u_{pj}^{(3)}}{\partial \mu_{ij}^p} = \end{aligned}$$

$$-2\eta_{p,ij}^\mu \beta(o_j^{(2)} - \mu_{ij}^p) \frac{o_{pj}^{(3)}}{(\sum_{j=1}^m o_{pj}^{(4)})^2 (\sigma_{ij}^p)^2}, \quad (23)$$

$$\begin{aligned} \Delta \sigma_{ij}^p &= \eta_{p,ij}^\sigma \frac{\partial J(k)}{\partial \sigma_{ij}^p} = \\ &\eta_{p,ij}^\sigma \frac{\partial J(k)}{\partial y_p} \frac{\partial y_p}{\partial u_{pj}^{(5)}} \frac{\partial u_{pj}^{(5)}}{\partial \mu_{ij}^p} \frac{\partial \mu_{ij}^p}{\partial u_{pj}^{(4)}} \frac{\partial u_{pj}^{(4)}}{\partial u_{pj}^{(3)}} \frac{\partial u_{pj}^{(3)}}{\partial \sigma_{ij}^p} = \\ &-2\eta_{p,ij}^\sigma \beta(o_j^{(2)} - \mu_{ij}^p)^2 \frac{o_{pj}^{(3)}}{(\sum_{j=1}^m o_{pj}^{(4)})^2 (\sigma_{ij}^p)^2}, \end{aligned} \quad (24)$$

$$\hat{y}_p = -2\beta(o_j^{(2)} - \mu_{ij}^p) \frac{o_{pj}^{(3)}}{(\sum_{j=1}^m o_{pj}^{(4)})^2 \sigma_{ij}^p}, \quad (25)$$

$$\beta = e_p(w_{ij}^p x_i o_{pj}^{(4)} - o_{pj}^{(5)}). \quad (26)$$

3.4 自适应学习算法及其收敛性分析(Adaptive learning algorithm and convergence analysis)

神经网络学习过程中学习率的大小具有重要的决定性作用, 学习率过小会导致整个学习过程缓慢, 学习率过大又会造成网络不稳定从而破坏整个学习过程. 针对此问题, 本文学习算法采用基于李雅普诺夫构架下的自适应变化方法, 公式如下:

$$\eta_p^w(t) = \frac{1}{\max_k (\frac{\partial y^p(t)}{\partial w_{ij}^p})^2}, \quad (27)$$

$$\eta_p^\mu(t) = \frac{1}{\max_k (\frac{\partial y^p(t)}{\partial \mu_{ij}^p})^2}, \quad (28)$$

$$\eta_p^\sigma(t) = \frac{1}{\max_k (\frac{\partial y^p(t)}{\partial \sigma_{ij}^p})^2}. \quad (29)$$

自适应学习率的变化可以加快收敛过程, 并能保证网络的收敛性. 本文通过构造李雅普诺夫函数的方法来获得其收敛性证明. 首先构造如下式所示的李雅普诺夫函数:

$$V(t) = J(t) = \frac{1}{2} \sum_{p=1}^{N_0} e_p^2. \quad (30)$$

由上式可以得出

$$\begin{aligned} \Delta V(t) &= V(t+1) - V(t) = \\ &\frac{1}{2} \sum_{p=1}^{N_0} (e_p^2(t+1) - e_p^2(t)), \end{aligned} \quad (31)$$

那么根据李雅普诺夫稳定性原理, 只要能证明 $\Delta V \leq 0$ 成立, 那么此算法就是稳定的. 由模型结构可得下式:

$$\Delta V(t) = \Delta V_1(t) + \Delta V_2(t) + \cdots + \Delta V_{N_0}(t), \quad (32)$$

$$\begin{aligned}\Delta V_p(t) &= V_p(t+1) - V_p(t) = \\ \frac{1}{2} (e_p^2(t+1) - e_p^2(t)).\end{aligned}\quad (33)$$

根据文献[11], 可得到式(34):

$$\Delta e(t) = e(t+1) - e(t) \cong [\frac{\partial e(t)}{\partial X}]^T \Delta X, \quad (34)$$

其中:

$$[\frac{\partial e(t)}{\partial X}] = [\frac{\partial e(t)}{\partial w} \quad \frac{\partial e(t)}{\partial \mu} \quad \frac{\partial e(t)}{\partial \sigma}], \quad (35)$$

$$\Delta X = [\Delta w \quad \Delta \mu \quad \Delta \sigma]^T. \quad (36)$$

定理1 当满足

$$\eta_p^w(t) \leq \frac{2}{\max_k (\frac{\partial y_p(t)}{\partial w_{ij}^p})^2}, \quad (37)$$

$$\eta_p^\mu(t) \leq \frac{2}{\max_k (\frac{\partial y_p(t)}{\partial \mu_{ij}^p})^2}, \quad (38)$$

$$\eta_p^\sigma(t) \leq \frac{2}{\max_k (\frac{\partial y_p(t)}{\partial \sigma_{ij}^p})^2} \quad (39)$$

时, 此学习算法是收敛性的.

证 由式(19)–(24)(31)–(36)可得下式:

$$\begin{aligned}\Delta e_p(t) &= \\ -e_p(t) [\sum_{j=1}^{N_p} \sum_{i=0}^n \eta_{p,ij}^w (\frac{\partial y_p(t)}{\partial w_{ij}^p})^2 + \\ \sum_{j=1}^{N_p} \sum_{i=0}^n \eta_{p,ij}^\mu (\frac{\partial y_p(t)}{\partial \mu_{ij}^p})^2 + \sum_{j=1}^{N_p} \sum_{i=0}^n \eta_{p,ij}^\sigma (\frac{\partial y_p(t)}{\partial \sigma_{ij}^p})^2],\end{aligned}\quad (40)$$

$$\begin{aligned}\Delta V_p(t) &= \\ -\frac{1}{2} e_p^2(t) \{ \sum_{j=1}^{N_p} \sum_{i=0}^n \eta_{p,ij}^w (\frac{\partial y_p(t)}{\partial w_{ij}^p})^2 [2 - \eta_{p,ij}^w (\frac{\partial y_p(t)}{\partial w_{ij}^p})^2] + \\ \sum_{j=1}^{N_p} \sum_{i=1}^n \eta_{p,ij}^\mu (\frac{\partial y_p(t)}{\partial \mu_{ij}^p})^2 [2 - \eta_{p,ij}^\mu (\frac{\partial y_p(t)}{\partial \mu_{ij}^p})^2] + \\ \sum_{j=1}^{N_p} \sum_{i=1}^n \eta_{p,ij}^\sigma (\frac{\partial y_p(t)}{\partial \sigma_{ij}^p})^2 [2 - \eta_{p,ij}^\sigma (\frac{\partial y_p(t)}{\partial \sigma_{ij}^p})^2] \}.\end{aligned}\quad (41)$$

在式(41)中可以看出 $e_p^2 \geq 0$, 只要使式(41)中大括号中的式子不小于零, 就能保证 $\Delta V \leq 0$, 因此得出如下条件:

$$\eta_{p,ij}^w(t) \leq \frac{2}{(\frac{\partial y_p(t)}{\partial w_{ij}^p})^2}, \quad (42)$$

$$\eta_{p,ij}^\mu(t) \leq \frac{2}{(\frac{\partial y_p(t)}{\partial \mu_{ij}^p})^2}, \quad (43)$$

$$\eta_{p,ij}^\sigma(t) \leq \frac{2}{(\frac{\partial y_p(t)}{\partial \sigma_{ij}^p})^2}. \quad (44)$$

为了使每一类参数具有统一的学习率标准, 计算每类参数 t 时刻的最大梯度值, 可以通过式(45)–(47)来制定每类参数学习率的统一标准:

$$\eta_p^w(t) \leq \frac{2}{\max_k (\frac{\partial y_p(t)}{\partial w_{ij}^p})^2}, \quad (45)$$

$$\eta_p^\mu(t) \leq \frac{2}{\max_k (\frac{\partial y_p(t)}{\partial \mu_{ij}^p})^2}, \quad (46)$$

$$\eta_p^\sigma(t) \leq \frac{2}{\max_k (\frac{\partial y_p(t)}{\partial \sigma_{ij}^p})^2}. \quad (47)$$

由此证得, 当学习率变化满足式(45)–(47)时, 此算法是收敛的, 定理1证毕.

3.5 性能分析(Performance analysis)

性能分析标准采用基准仿真平台BSM1定义的评价标准^[18], 其底层评价指标主要是对控制精度、控制量波动情况等进行评价, 包括平方误差积分ISE、绝对误差积分IAE和最大绝对误差Dev^{max}, 公式如下所示:

$$IAE = \int_{t=t_0}^{t=t_f} |e_i| dt, \quad (48)$$

$$ISE = \int_{t=t_0}^{t=t_f} e_i^2 dt, \quad (49)$$

$$Dev^{max} = \max |e_i|. \quad (50)$$

IAE对应动态响应评价; ISE代表能量消耗的评估; Dev^{max}某种程度上表示了系统的稳定性.

4 仿真研究(Simulation research)

仿真实验基于 BSM1 平台进行, 实验数据采用 BSM1 中定义的 14 天进水数据, 前 7 天数据作为训练样本训练网络, 后 7 天数据作为测试样本来验证方法的有效性. 辨识器网络输入为 k_{La} , Q_a , 输出为 D_O , S_{NO} , 采用在线建模的形式进行辨识. 控制器网络输入为设定值与实际输出值之间的误差, 输出为 k_{La} 的变化量和 Q_a 的变化. 为了更好的测试所提方法的性能, 实验采用设定值变动的方式进行, 在 8–9 天设置溶解氧设定值为 1.8 mg/L, 在 9–10 天将溶解氧设定值设计为 2.2 mg/L, 其他时间固定为 2 mg/L; 硝态氮浓度设定值在 8–9 天设置为 0.8 mg/L, 在 10–14 天设计为 1.2 mg/L, 其他时间固定为 1 mg/L. 仿真结果如图 5–8 所示. 从图中可以看出, 一方面, 即使设定值在变化时, RFNN 辨识器也可以很好地对溶解氧和硝态氮进行辨识, 且具有很高的逼近精度; 另一方面, 控制器也可以很好地控制溶解氧浓度和硝态氮浓度在很小的误差范围内.

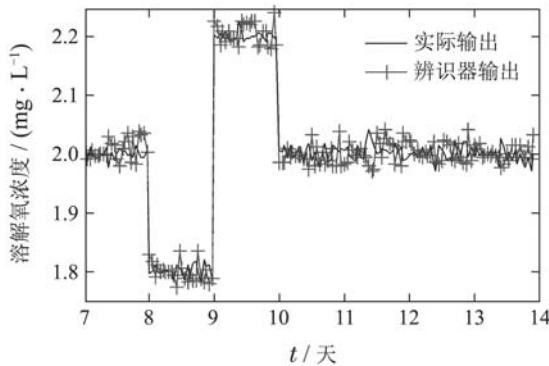


图 5 溶解氧辨识器建模效果

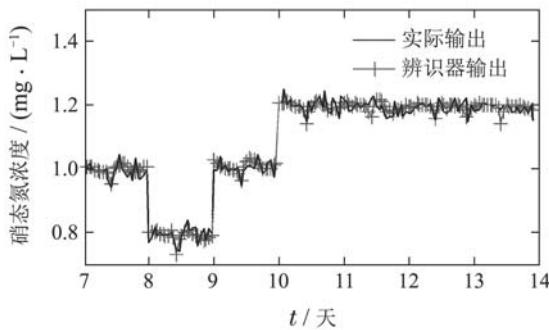
Fig. 5 Modeling result of D_O identifier

图 6 硝态氮辨识器建模效果

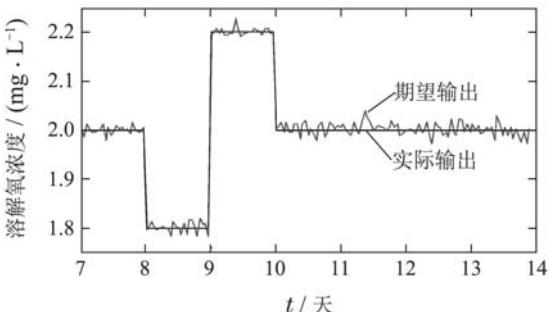
Fig. 6 Modeling result of S_{NO} identifier

图 7 溶解氧浓度控制效果

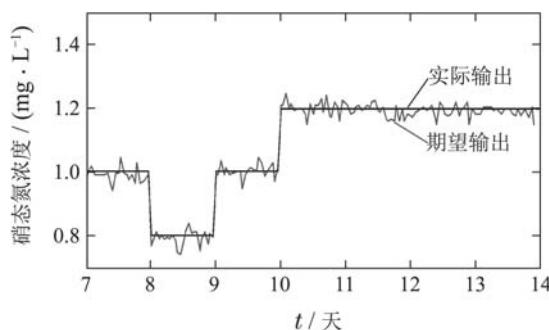
Fig. 7 Control result of D_O concentration

图 8 硝态氮浓度控制效果

Fig. 8 Control result of S_{NO} concentration

表1为溶解氧在不同控制方法下的性能比较,相较于PID, MPC和NNOMC对于溶解氧浓度的控制,基

于RFNN的在线建模控制方法在IAE, ISE和 Dev^{max} 3个指标方面都具有很大地提高。表2为硝态氮在不同控制方法下的性能对比,相较于PID, MPC和NNOMC对于硝态氮浓度的控制,基于RFNN的在线建模控制方法在IAE, ISE和 Dev^{max} 3个指标方面也有很大地提高。因此,实验验证了基于RFNN的在线建模控制方法的有效性,所提方法可以提高对溶解氧浓度和硝态氮浓度的跟踪控制精度。

表 1 溶解氧在不同控制方法下性能指标对比

Table 1 Performance comparisons of D_O under different controllers

	IAE	ISE	Dev^{max}
RFNNMNC	0.024	2.40×10^{-4}	0.0563
PID ^[1]	0.218*	3.11×10^{-3} *	0.1885*
MPC ^[2]	0.089*	2.60×10^{-3} *	0.1254*
NNOMC ^[10]	0.039*	5.31×10^{-4} *	0.0725*
DADNNC ^[11]	0.032*	3.95×10^{-4} *	0.0606*

“*”表示原文中数据

表 2 硝态氮在不同控制方法下性能指标对比

Table 2 Performance comparisons of S_{NO} under different controllers

	IAE	ISE	Dev^{max}
RFNNMNC	0.026	3.18×10^{-4}	0.0827
PID ^[10]	0.220*	1.44×10^{-2} *	0.2584*
MPC ^[10]	0.095*	7.46×10^{-3} *	0.2048*
NNOMC ^[10]	0.049*	7.18×10^{-4} *	0.1626*

“*”表示原文中数据

5 结论(Conclusions)

文中通过分析污水处理的特点,提出了一种基于递归模糊神经网络的在线建模控制方法。该方法基于RFNN对污水处理过程进行在线建模,控制器可以根据模型提供的反馈信息调整控制量增量,从而提升了跟踪控制精度。针对基于神经网络的多个变量控制及辨识问题,相对简单的拆分了网络结构,一定程度上对耦合变量进行了解耦,但没有从根本上解决控制变量的耦合问题,以后研究将关注如何解耦问题。最后仿真实验表明,溶解氧浓度可以控制在0.0563 mg/L的误差范围之内,硝态氮浓度可以控制在0.0827 mg/L的误差范围之内。总之,该方法能够有效提升溶解氧和硝态氮的跟踪控制精度。

参考文献(References):

- [1] AYESA E, SOTA A D L, 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 & Technology, 2006, 53(4/5): 193 – 201.
- [2] HOLEND A, DOMOKOS E, RÉDEY Á, et al. Dissolved oxygen control of the activated sludge wastewater treatment process using

- model predictive control [J]. *Computers & Chemical Engineering*, 2008, 32(6): 1270 – 1278.
- [3] ZOU Quan, QIAN Linfang, JIANG Qingshan. Prescribed performance adaptive neural backstepping control for nonlinear system with uncertainties and unknown control directions [J]. *Control Theory & Applications*, 2015, 32(6): 817 – 822.
(邹权, 钱林方, 蒋清山. 永磁同步电机伺服系统的自适应模糊滑模控制 [J]. 控制理论与应用, 2015, 32(6): 817 – 822.)
- [4] GENG Baoliang, HU Yun'an. Adaptive fuzzy sliding-mode control for permanent magnet synchronous motor servo system [J]. *Control Theory & Applications*, 2014 (3): 397 – 403.
(耿宝亮, 胡云安. 控制方向未知的不确定系统预设性能自适应神经网络反演控制 [J]. 控制理论与应用, 2014 (3): 397 – 403.)
- [5] JIANG Zhaohui, LI Xiyue, GUI Weihua, et al. Blast furnace stockline prediction by segmented linear-regression and dynamic weighting neural network [J]. *Control Theory & Applications*, 2015, 32(6): 801 – 809.
(蒋朝辉, 李晞月, 桂卫华, 等. 分段线性回归和动态加权神经网络融合的高炉料位预测 [J]. 控制理论与应用, 2015, 32(6): 801 – 809.)
- [6] HAN Honggui, qiao Junfei. Nonlinear model-predictive control for industrial processes: an application to wastewater treatment process [J]. *IEEE Transactions on Industrial Electronics*, 2014, 61(4): 1970 – 1982.
- [7] HAN Honggui, QIAO Junfei, CHEN Qili. Model predictive control of dissolved oxygen concentration based on a self-organizing RBF neural network [J]. *Control Engineering Practice*, 2012, 20(4): 465 – 476.
- [8] 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 and Chemical Engineering*, 2012, 37(4): 152 – 162.
- [9] ZENG G M, QIN X S, HE L, et al. A neural network predictive control system for paper mill wastewater treatment [J]. *Engineering Applications of Artificial Intelligence*, 2003, 16(2): 121 – 129.
- [10] QIAO J F, HAN G, HAN H G. Neural network on-line modeling and controlling method for multi-variable control of wastewater treatment processes [J]. *Asian Journal of Control*, 2013, 16(4): 1213 – 1223.
- [11] ZHANG Wei, QIAO Junfei, LI Fanjun. Direct adaptive dynamic neural network control for dissolved oxygen concentration [J]. *Control Theory & Applications*, 2015, 32(01): 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 [J]. 控制理论与应用, 2015, 32(01): 115 – 121.)
- [12] HSU C F, CHENG K H. Recurrent fuzzy-neural approach for nonlinear control using dynamic structure learning scheme [J]. *Neurocomputing*, 2008, 71(16): 3447 – 3459.
- [13] CHEN C S. TSK-type self-organizing recurrent-neural-fuzzy control of linear microstepping motor drives [J]. *IEEE Transactions on Power Electronics*, 2010, 25(9): 2253 – 2265.
- [14] EL-SOUSY F F M. Adaptive hybrid control system using a recurrent rbf-based self-evolving fuzzy-neural-network for pmsm servo drives [J]. *Applied Soft Computing*, 2014, 21(8): 509 – 532.
- [15] LIN F J, YANG K J, SUN I F, et al. Intelligent position control of permanent magnet synchronous motor using recurrent fuzzy neural cerebellar model articulation network [J]. *Electric Power Applications, IET*, 2015, 9(3): 248 – 264.
- [16] WU G D, ZHU Z W. An enhanced discriminability recurrent fuzzy neural network for temporal classification problems [J]. *Fuzzy Sets & Systems*, 2014, 237(2): 47 – 62.
- [17] MON Y J, LIN C M. 3-Dimensional sliding mode adaptive MIMO recurrent fuzzy neural network control for two-link manipulator system [J]. *Journal of Intelligent & Fuzzy Systems*, 2014, 27(3): 1325 – 1334.
- [18] XAVIER F A, IGNASI R R, GÜRKAN S, et al. Uncertainty and sensitivity analysis of control strategies using the benchmark simulation model No.1 (BSM1) [J]. *Water Science & Technology: A Journal of the International Association on Water Pollution Research*, 2009, 59(3): 491 – 499.

作者简介:

韩改堂 (1988–), 男, 博士研究生, 从事计算智能与智能系统的研究, E-mail: hangaitang@emails.bjut.edu.cn;

乔俊飞 (1968–), 男, 教授, 从事智能信息处理、智能优化控制的研究, E-mail: junfeiq@bjut.edu.cn;

韩红桂 (1983–), 男, 教授, 从事智能信息处理、智能控制理论及应用的研究, E-mail: rechardhan@bjut.edu.cn.