文章编号:1000-8152(2009)01-0008-07

污水处理过程的递阶神经网络建模

丛秋梅1, 柴天佑1,2, 余 文3

(1. 东北大学 流程工业综合自动化教育部重点实验室, 辽宁 沈阳 110004;

2. 东北大学 自动化研究中心, 辽宁 沈阳 110004;

3. 墨西哥国立理工大学高级研究中心(CINVESTAV-IPN), Mexico D.F. 墨西哥 07360)

摘要:针对污水处理过程的多变量和多非线性子系统的串级结构特点,提出了一种基于活性污泥过程机理的递阶神经网络建模方法.该方法将神经网络与过程机理模型以串级方式连接,以神经网络辨识活性污泥过程模型中的非线性组分反应速率.分析各子过程建模误差的关系,给出了模型的稳定学习算法和稳定性理论分析.最后通过 某污水处理厂生化脱氢过程实际运行数据的实验表明所提出的建模方法是有效的.

关键词: 污水处理过程; 串级过程; 递阶神经网络; 稳定学习律

中图分类号: TP391.9 文献标识码: A

Modeling wastewater treatment plant via hierarchical neural networks

CONG Qiu-mei¹, CHAI Tian-you^{1,2}, YU Wen³

(1. Key Laboratory of Process Industry Automation, Northeastern University, Ministry of Education, Shenyang Liaoning 110004, China;

2. Automation Research Center, Northeastern University, Shenyang Liaoning 110004, China;

3. Departamento de Control Automatico, CINVESTAV-IPN, Mexico D.F. 07360, Mexico)

Abstract: A hierarchical neural networks based on the mechanism of activated sludge process is introduced for modeling the wastewater treatment plant (WWTP) which includes multivariable and multi-nonlinear subsystems with serial structure. This approach combines the neural network and the mechanism model in a serial configuration; and the nonlinear uncertainties of the activated sludge process are estimated by neural networks. A stable learning algorithm and the theoretical analysis are given for this model based on the relations of various modeling errors among sub-processes. Operational data of a wastewater treatment plant illustrate the efficacy of this modeling approach.

Key words: wastewater treatment plant; cascaded process; hierarchical neural networks; stable learning law

1 引言(Introduction)

大多数污水处理厂采用活性污泥工艺,污染物 去除率是影响环境保护的关键因素.但由于未知 的微生物活动、生化反应的复杂性和时变参数等 综合复杂性,关键水质指标难于在线检测,使得污 水处理过程模型的建立尤为重要.国际水协会提 出的ASM(activated sludge model)系列模型是典型的 活性污泥模型,但参数众多不利于模型的准确辨 识.神经网络方法已广泛应用于污水处理过程建模, 文 [1]建立了一类时滞神经网络的出水水质预报模 型,但未考虑微生物动态; 文 [2]采用神经网络辨识 简化ASM1的高灵敏度参数, 文 [3]将多种非参数模 型包括神经网络作为ASM1的误差补偿器, 但神经 网络未给出最优效果.

本文针对污水处理过程流程具有串级结构的特点,结合串级过程建模理论^[4,5],将递阶多层神经网络与各反应器子系统相结合提出一种基于活性污泥 过程机理的递阶神经网络建模方法,由输入--状态稳 定性(ISS, input-to-state stability)方法,研究各子过程 建模误差之间的关系,采用带有时变学习率的误差

收稿日期: 2007-12-09; 收修改稿日期: 2008-07-11.

基金项目:国家重点基础研究发展(973)计划资助项目(2002CB312201);国家自然科学基金重点资助项目(60534010);国家创新研究群体科 学基金资助项目(60521003);长江学者和创新团队发展计划资助资助(IRT0421);111工程资助项目(B08015).

反传类学习算法保证了该方法的稳定性.

2 脱氮污水处理流程描述(Descriptions of wastewater treatment process for nitrogen re-moval)

图1所示是活性污泥A/O脱氮过程流程图,由两 个反应器和二沉池组成,三部分具有串级连接的结 构特点.图中Q_{in},Q_m,Q_r,Q_R和Q_w分别表示待处 理污水流量、混合入水流量、内回流流量、外回流流 量和过剩污泥流量.xⁱⁿ表示待处理污水组分;x^m表 示混合入水组分;x^a表示缺氧池出水组分;x^o表示 好氧池出水组分;x^R表示二沉池浓缩区出水组分; x^e表示二沉池澄清区出水组分.活性污泥中的异 养菌和自养菌在缺氧池中将x^m硝化为x^a;在好氧池 中将x^a反硝化为x^o;二沉池利用固体物质的重力沉 降,将x^o中固体组分和可溶性组分分离,澄清区出 水x^e排入受纳水体,浓缩区污泥x^R一部分回流至缺 氧池,另一部分排到污泥处理区.





水质指标COD(chemical oxygen demand)是污水 中碳污染物组分的和,出水COD是反映碳去除效率 的重要指标,由于在线检测仪表和药剂昂贵,难于 实现连续在线检测.COD不但与控制输入Q_{in},Q_r, Q_R和Q_w有关,还与进水水质xⁱⁿ等边界条件有关,还 受到其它干扰因素如温度、流量分布、毒素冲击等 的影响,具有如下非线性关系:

$$COD = f(Q_{in}, Q_{r}, Q_{R}, Q_{w}, x^{in}).$$

3 串级污水处理过程的递阶神经网络建模(Cascaded WWTP process modeling via hierarchical neural networks)

一般的神经网络建模都是黑箱建模,它的缺点是 得到的模型只能简单模拟系统的输入-输出数据关 系,而没有深入研究系统行为的机理.在已知机理过 程的情况下,对于污水处理过程这类具有串级结构 特点的对象建模,结合机理知识和神经网络的灰箱 模型将在更好的精度上描述过程对象.

3.1 污水处理过程动态数学模型(Dynamic mathematical model of WWTP)

污水组分x由水质指标如COD, BOD₅(biological oxygen demand), NH₄-N, NO₃-N和SS(suspended solid) 按照一定的比例分解而成^[6], 即

$$\begin{aligned} x &= [x_i] = \\ [S_I S_S X_I X_S X_P X_{BH} X_{BA} \\ S_{NO} S_{NH} S_O S_{ND} X_{ND} S_{alk}], \\ i &= 1, \cdots, 13; \end{aligned}$$

 x_i^j 表示第i组分在位置j处的浓度.

缺氧池模型可写为:

$$\dot{x}_{i}^{a}(t) = \frac{u_{1}(t) + u_{2}(t) + u_{3}(t)}{V} (x_{i}^{m}(t) - x_{i}^{a}(t)) + r_{i}^{a}(x^{a}(t)),$$
 (1)

其中
$$x_i^{\mathrm{m}} = \frac{u_1(t)x_i^{\mathrm{m}} + u_2(t)x_i^{\mathrm{o}} + u_3(t)x_i^{\mathrm{R}}}{u_1(t) + u_2(t) + u_3(t)}.$$

好氧池模型可写为:
 $\dot{x}_i^{\mathrm{o}}(t) = \frac{u_1(t) + u_2(t) + u_3(t)}{V}(x_i^{\mathrm{a}}(t) - x_i^{\mathrm{o}}(t)) + r_i^{\mathrm{o}}(x^{\mathrm{o}}(t)).$ (2)

其中rⁱ表示第i组分在位置j的反应速率,是组分浓度的非线性函数,具体形式和其中的动力学参数、化学计量系数默认值见文 [7].二沉池采用理想压缩点模型,浓缩因子为

$$\lambda_{i} = \frac{x_{i}^{\mathrm{R}}}{x_{i}^{0}} = \begin{cases} \frac{u_{1} + u_{3} - \frac{v_{a} + v_{a}}{\theta}}{u_{3}}, i = 3, 4, 5, 6, 7, 12, \\ 1, & i = 1, 2, 8, 9, 10, 11, 13, \end{cases}$$

其中: θ 表示污泥龄, v_a和v_o分别表示缺氧池和好氧 池体积, 二沉池模型可写为:

$$x_{i}^{\mathrm{R}} = \begin{cases} \lambda_{i} x_{i}^{0}, i = 3, 4, 5, 6, 7, 12, \\ x_{i}^{0}, i = 1, 2, 8, 9, 10, 11, 13, \end{cases}$$
(3)
$$x_{i}^{\mathrm{e}} = \begin{cases} 0, i = 3, 4, 5, 6, 7, 12, \\ x_{i}^{0}, i = 1, 2, 8, 9, 10, 11, 13, \end{cases}$$
(4)

输出y为出水COD,满足

$$y^{\rm e} = \sum_{i=1}^{7} x_i^{\rm e}.$$
 (5)

由于微生物的未知生化活动,生化反应的复杂性和内外部影响因素,如组分浓度、温度、毒素冲击和运行方式等,不确定因素导致动力学反应速率是不确定的,因此r_i也具有不确定性.缺氧池和好氧池模型都可以由如下一般的非线性动态方程描述:

$$\dot{x}(t) = \boldsymbol{f}(x(t), u(t), \gamma(x(t))), \tag{6}$$

这里: **f**是函数向量, $\gamma(x(t))$ 为不确定非线性组分反应速率向量. 对应离散时间模型为:

$$\gamma(k+1) = \Psi[X_1(k)], \boldsymbol{y}(k) = h[X_2(k)].$$
 (7)

其中: Ψ 是表示 $\gamma(x(t))$ 的未知非线性函数, h是包含 活性污泥动态的已知模型, y即x是反应池出水组分:

$$\begin{cases} X_1(k) = [\boldsymbol{\gamma}(k), \boldsymbol{\gamma}(k-1), \cdots, \boldsymbol{\gamma}(k-n_1), \boldsymbol{u}(k), \\ \boldsymbol{u}(k-1), \cdots, \boldsymbol{u}(k-m_1)]^{\mathrm{T}}, \\ X_2(k) = [\boldsymbol{\gamma}(k), \boldsymbol{\gamma}(k-1), \cdots, \boldsymbol{\gamma}(k-n_2), \boldsymbol{u}(k), \\ \boldsymbol{u}(k-1), \cdots, \boldsymbol{u}(k-m_2)]^{\mathrm{T}}. \end{cases}$$
(8)

3.2 串级建模策略(Strategy of cascaded modeling)

如图2所示为串级污水处理过程的递阶神经网络 建模策略,采用神经网络辨识各子过程模型的不确 定组分反应速率,将前一个子过程模型的输出作为 下一个子过程模型的部分输入.

模型输入为xⁱⁿ, Q_{in}, Q_r, Q_R, Q_w;输出为COD. 通过分析缺氧和好氧条件下微生物生化反应机理, 确定分别采用单输出神经网络辨识缺氧条件下组 分[S_SX_{BA}S_{NO}]的反应速率[r^a₂ r^a₇ r^a₈],以及好氧条件 下组分[S_SX_{BH}S_{NH}S_O]的反应速率[r^o₂ r^o₆ r^o₉ r^o₁₀].若 缺氧池和好氧池模型和相应子过程之间的建模误 差e^a, e^o已知,则各子神经网络可以独立进行训练.





神经网络采用如下单输出三层感知器进行辨识:

$$\hat{r}(k) = W(k)\phi[V(k)\hat{x}(k)], \qquad (9)$$

其中: $\hat{r}(k)$ 为标量输出; $W(k) \in \mathbb{R}^{1 \times m}$ 为输出层权 值向量, $V(k) \in \mathbb{R}^{m \times n}$ 为隐含层权值矩阵; n为输 入层节点数, m为隐含层节点数, ϕ 为 m维函数向 量, ϕ_i 通常采用sigmoid函数.

动态活性污泥模型部分为:

$$\hat{\boldsymbol{y}}(k) = h[\hat{X}_2(k)]. \tag{10}$$

首先讨论如何采用结合活性污泥机理的神经 网络为串级污水处理过程中的单个反应器建模. 建模的目标是学习组分反应速率神经网络辨识 器的权值矩阵,使得神经网络模型(10)和对象模 型(7)之间的误差最小.以缺氧池模型为例,性能指

$$J^{\mathbf{a}} = \frac{1}{2} \|\boldsymbol{e}^{\mathbf{a}}(k)\|^{2} = \frac{1}{2 \times 13} \sum_{i=1}^{13} (\hat{y}^{\mathbf{a}}_{i}(k) - y^{\mathbf{a}}_{i}).$$

神经网络采用梯度下降法学习:

$$W(k) = [w_i], V(k) = [v_{i,j}],$$

其中:

$$\Delta w_i(k) = -\eta \frac{\partial J^{\mathbf{a}}}{\partial w_i}, \Delta v_{i,j}(k) = -\eta \frac{\partial J^{\mathbf{a}}}{\partial v_{i,j}}$$

输出层权值向量链式规则为:

$$\begin{aligned} \frac{\partial J^{\mathbf{a}}}{\partial w_i} &= \frac{\partial J^{\mathbf{a}}}{\partial \hat{\boldsymbol{y}}^{\mathbf{a}}} \frac{\partial \hat{\boldsymbol{y}}^{\mathbf{a}}}{\partial \hat{r}^{\mathbf{a}}} \frac{\partial \hat{r}^{\mathbf{a}}}{\partial w_i} = \\ \sum_{t=1}^{13} (e_t(k) \frac{\partial \hat{y}^{\mathbf{a}}}{\partial \hat{r}^{\mathbf{a}}}) \frac{\partial \hat{r}^{\mathbf{a}}}{\partial w_i} = \boldsymbol{e}^{\mathbf{a}\mathrm{T}}(k) h' \phi_i \end{aligned}$$

 ϕ_i 为隐含层第i个节点的输出值, r_a 为缺氧池组分

反应速率.

隐含层权值矩阵采用同样的方法:

$$\frac{\partial J^{a}}{\partial v_{i,j}} = \frac{\partial J^{a}}{\partial \hat{\boldsymbol{y}}^{a}} \frac{\partial \boldsymbol{y}^{a}}{\partial \hat{r}^{a}} \frac{\partial r^{a}}{\partial \phi_{i}} \frac{\partial \phi_{i}}{\partial v_{i,j}}$$
$$\sum_{t=1}^{13} (e_{t}(k)h_{t}')w_{i}\phi_{i}'x_{j}^{\mathrm{m}}.$$

因此缺氧池模型神经网络的学习算法为:
$$\begin{cases} W(k+1) = W(k) - \eta e^{aT} h' \phi^{T}, \\ V(k+1) = V(k) - \eta e^{aT} h' \phi^{T} W^{T}(k) x^{mT}. \end{cases}$$
(11)

其中η为学习率.

其次,讨论缺氧池和好氧池串级过程的递阶神 经网络建模,将好氧池模型建模误差反向传递给 缺氧池模型,根据各模型建模误差可独立训练缺 氧池和好氧池各神经网络.即若 e^o已知,当误差从 好氧池模型反传到缺氧池模型时,采用链式规则 法可从两反应器递阶模型中得到e^o和e^a之间的关 系.

定义

$$e^{\mathbf{a}}(k) = [e^{\mathbf{a}}_i(k)], \ e^{\mathbf{a}}_i(k) = \hat{y}^{\mathbf{a}}_i(k) - y^{\mathbf{a}}_i(k),$$

 $i = 1, \cdots, 13,$

其中: $\hat{y}_i^{a}(k)$ 为缺氧池模型输出, $y_i^{a}(k)$ 为缺氧池对 象输出. 计算缺氧池神经网络权值为

$$\frac{\partial J}{\partial w_i} = \frac{\partial J}{\partial \hat{\boldsymbol{y}}^{\mathrm{a}}} (\frac{\partial \hat{\boldsymbol{y}}^{\mathrm{a}}}{\partial \hat{r}^{\mathrm{a}}} \frac{\partial \hat{r}^{\mathrm{a}}}{\partial w_i})$$

其中*J*为活性污泥过程的性能指标.此时 $\frac{\partial J}{\partial \hat{y}^a}$ 不对应整个活性污泥过程的输出误差,因此采用好氧 池模型误差 $\frac{\partial J}{\partial \hat{u}^o} = e^o$,即

$$\frac{\partial J}{\partial w_i} = \frac{\partial J}{\partial \hat{\boldsymbol{y}^{\mathrm{o}}}} \frac{\partial \hat{\boldsymbol{y}^{\mathrm{o}}}}{\partial \hat{\boldsymbol{y}^{\mathrm{a}}}} (\frac{\partial \hat{\boldsymbol{y}^{\mathrm{a}}}}{\partial \hat{r}^{\mathrm{a}}} \frac{\partial \hat{r}^{\mathrm{a}}}{\partial w_i}),$$

两反应器过程输出项比值 $\frac{\partial \hat{y}^{o}}{\partial \hat{y}^{a}}$ 实现模型建模误差反传, 即

$$\frac{\partial \hat{\boldsymbol{y}}^{\mathrm{o}}}{\partial \hat{\boldsymbol{y}}^{\mathrm{a}}} = \frac{\partial \hat{\boldsymbol{y}}^{\mathrm{o}}}{\partial \hat{r}^{\mathrm{o}}} \frac{\partial \hat{r}^{\mathrm{o}}}{\partial \phi^{\mathrm{o}}} \frac{\partial \phi^{\mathrm{o}}}{\partial \hat{\boldsymbol{y}}^{\mathrm{a}}} = h^{\mathrm{o}\prime} \Phi^{\mathrm{o}\prime} W^{\mathrm{o}\mathrm{T}} V^{\mathrm{o}}.$$

因此e^o和e^a之间的关系为:

$$\boldsymbol{e}^{\mathrm{a}} = \boldsymbol{e}^{\mathrm{oT}} h^{\mathrm{o'}} \boldsymbol{\Phi}^{\mathrm{o'}} W^{\mathrm{oT}} V^{\mathrm{o}}.$$
 (12)

上式对于具有一般递阶结构的串级过程递阶 神经网络建模具有一般性.

4 稳定学习 (Stable learning)

当采用固定学习速率的梯度下降法时系统性 能较差,相比较时变学习速率具有更快的收敛 性^[8,9]. 文 [10]将这一想法扩展到神经网络,但不 能保证稳定性. 文 [11]采用Lyapunov理论,可以保 证稳定性,但收敛速度没有大幅度改进. 本文提出 一种新的时变学习算法,同时具备了文 [10,11]的 优点,是一类快速、稳定的学习律.

使用Taylor级数展开得到建模误差动态.在 具有两个独立变量的光滑函数*f*在[*x*⁰₁, *x*⁰₂]点附近 的Taylor级数具有如下形式:

$$f(x_1, x_2) = \sum_{k=0}^{l-1} \left[\frac{1}{k!} (x_1 - x_1^0) \frac{\partial}{\partial x_1'} + (x_2 - x_2^0) \frac{\partial}{\partial x_2'}\right]^k f(x_1', x_2')_{|x_1' = x_1^0, x_2' = x_2^0} + \varepsilon.$$
(13)

其中ε为Taylor公式的高阶项.由Stone-Weierstrass定理可知,式(9)和式(10)给出的基于活性污 泥模型的神经网络模型,以缺氧池为例,模型可写 为:

$$r^{a}(k) = W^{a*}\phi[V^{a*}x^{m}(k)] - \mu(k),$$

$$y^{a}(k) = h[X^{a}_{2}(k)].$$

其中 W^{a*} 和 V^{a*} 分别为建模误差最小时的缺氧神 经网络输出层和隐含层权值矩阵, 若 x_1 和 x_2 分别 对应 $W^{a}(k)$ 和 $V^{a}(k)$, x_1^0 和 x_2^0 分别对应 W^{a*} 和 V^{a*} ,

$$\begin{split} \hat{r}^{a}(k) = & W^{a*}\phi[V^{a*}x^{m}(k)] + [W^{a}(k) - W^{a*}]\phi + \\ & [V^{a}(k) - V^{a*}]\phi'W^{aT}(k)x^{mT}(k) + \varepsilon(k) = \\ & r^{a}(k) + [W^{a}(k) - W^{a*}]\phi + [V^{a}(k) - \\ & V^{a*}]\phi'W^{aT}(k)x^{mT}(k) + \varepsilon(k) + \mu(k). \end{split}$$

因此单输出三层神经网络的误差为:

$$(k) = \widetilde{W}^{\mathrm{a}}(k)\phi[V^{\mathrm{a}}(k)x^{\mathrm{m}}(k)] + \widetilde{V}^{\mathrm{a}}(k)\phi'W^{\mathrm{aT}}(k)x^{\mathrm{mT}}(k) + \zeta(k).$$
(14)

其中:

 e^{an}

$$\begin{split} \widetilde{W}^{\mathrm{a}}(k) &= W^{\mathrm{a}}(k) - W^{\mathrm{a}*}, \\ \widetilde{V}^{\mathrm{a}}(k) &= V^{\mathrm{a}}(k) - V^{\mathrm{a}*}, \\ \zeta(k) &= \varepsilon(k) + \mu(k). \end{split}$$

11

本文活性污泥串级模型是BIBO稳定的,即 $y^{a}(k), r^{a}(k), u(k)$ 有界.因为函数 ϕ 有界,可知 $\varepsilon(k),$ $\mu(k)$ 是有界的.若采用三层感知器神经网络(9)辨 识缺氧池不确定组分反应速率,学习算法为:

$$\begin{cases} W^{a}(k+1) = W^{a}(k) - \eta_{k}e^{an}(k)\phi, \\ V^{a}(k+1) = V^{a}(k) - \eta_{k}e^{an}(k)\phi'W^{aT}(k)x^{mT}(k). \end{cases}$$
(15)

其中

$$\eta_{k} = \frac{\eta_{0}}{1 + \left\| \phi' W^{\mathrm{aT}}(k) x^{\mathrm{mT}}(k) \right\|^{2} + \left\| \phi \right\|^{2}}, \\ 0 < \eta_{0} \leq 1;$$

ean为神经网络误差,神经网络平均建模误差满足:

$$\lim_{T \to \infty} \sup \frac{1}{T} \sum_{k=1}^{T} \|e^{\mathrm{an}}(k)\|^2 \leqslant \frac{\bar{\zeta}}{1 - \eta_0}.$$
 (16)

其中 $\bar{\zeta} = \max_{k} [\zeta^{2}(k)]$. 并且由Lipschitz条件可知 $\|h(x_{1}) - h(x_{2})\| \leq l \|x_{1} - x_{2}\|,$ 可得

$$\|\boldsymbol{e}^{\mathbf{a}}(k)\| = \|h[\hat{X}_{2}^{\mathbf{a}}(k)] - h[X_{2}^{\mathbf{a}}(k)]\| \leq l\|\hat{r}^{\mathbf{a}}(k) - r^{\mathbf{a}}(k)\| = l\|\boldsymbol{e}^{\mathbf{an}}(k)\|.$$

因此建模误差e^a(k)有界,并满足

 $\lim_{T \to \infty} \sup \frac{1}{T} \sum_{k=1}^{T} \|\boldsymbol{e}^{\mathbf{a}}(k)\|^2 \leq l \frac{\bar{\zeta}}{1 - \eta_0}.$

故由输出**y**^a(k)以及建模误差有界可知, 模型输出**ŷ**^a(k)有界; 同理, 好氧池模型的输出**ŷ**^o(k)也 是有界的, 因此活性污泥过程模型的所有状态是 稳定的.

5 仿真实验 (Numerical simulation)

以具有图 1 所示结构的沈阳某污水处理 厂A/O脱氮工艺过程实际运行数据建立递阶神 经网络模型.此污水处理厂共6条水线主要处理 生活污水,4~6号线采用A/O脱氮工艺,缺氧池 和好氧池体积分别为7772.5 m³和10326 m³;二 沉池高度为4.2 m,直径为57 m.表 1 是1999年 到2004年的主要运行参数,其中内、外回流比分别 为r = 2, R = 1.

在进行动态仿真之前,需进行稳态仿真,将训 练数据样本的入水水质均值作为稳态仿真输入值, 得到的缺氧池和好氧池各组分稳态值如表 2所示.

将各反应池组分稳态值作为动态仿真的初始 值进行动态仿真,水利停留时间为10.8 h,污泥龄 为15天.现有此污水处理厂2003年的运行数据,存 在很多离群点及缺失数据. 文 [12]用带有迭代 回归鲁棒最小二乘学习算法的EM (expectationmaximum)主元分析来移除离群点,并估计缺失 数据. 经预处理的运行数据如图3和图4所示,其 中8月上旬到10月中旬进行设备大修,导致出水 水质指标SS、氨氮值大量缺失,运行数据虽经过 协调仍存在很大偏差. 从运行数据可以看出,入 水BOD₅、SS呈现先上升后下降的趋势,这是由于 北方春天的积雪融化导致进水负荷的大幅度增加, NH₄-N受其影响较小. 出水BOD₅、SS通过二级生 化处理后趋势平缓,说明此污水处理厂对入水水 质波动有很好的冗余能力;而NH₄-N的去除率只 有51%,表明脱氮能力需通过优化过程操作而不 断提高.

表1 1999~2004年主要运行参数

Table 1 Main operational parameters

参数	COD	BOD_5	SS	氨氮
进水/(mg·l ⁻¹)	292	98	123	45
出水/ (mg·l ⁻¹)	61	17	17	22
去除率/%	80	83	86	51
单位	Q_{in}	Q_{R}	$Q_{ m r}$	$Q_{\rm w}$
$m^3 \cdot h^{-1}$	2778~3700	1389~3700	2778~7400	760

表 2 缺氧池和好氧池组分稳态值

Table 2 Steady values of components in

	an	mg·l ^{−1}			
反应池	S_S	X_{BH}	X_S	X_I	S_{NH}
缺氧池	1.2518	3249	74.332	642.4	7.9157
好氧池	0.6867	244.8	47.392	643.36	0.1896
反应池	S_I	S_{ND}	X_{ND}	S_O	X_{BA}
缺氧池	38.374	0.7868	5.7073	0.0001	220.86
好氧池	38.374	0.6109	3.7642	1.4988	222.39
反应池	S_{NO}	X_P	S_{alk}		
缺氧池	3.9377	822.19	4.9261		
好氧池	12.819	825.79	3.7399		

采用100组春末夏初的输入/输出数据对作为 训练数据,训练数据覆盖了温度的大幅度变化和 由于季节交替造成的进水水质波动,因此能较为 全面地反映过程运行状况.30组作为验证数据.每 个多层感知器神经网路的结构为13-30-1,其中隐 含层节点数m按经验选为30; 隐含层权值矩阵和 输出层权值向量的初始值取为 [0 1]之间的随机值; 学习律采用式(11)所示的误差反传类学习算法, 选 择激活函数 $\phi_i = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$, 因此 $\phi'_i = \frac{2}{e^x + e^{-x}}$. 选择 $\eta_0 = 1$, 对出水水质COD的仿真 结果如图所示. 均方根误差RMSE=1.5666, 预测精 度较高. 与文 [10]比较, η_0 应小于1, 选择 $\eta_0 = 0.8$, REMSE=1.6701. 与文 [11]比较, 因为不知道最佳 时变速率, 当选择 $\eta_0 = 3$, REMSE=1.9232.

建模误差产生的原因总结如下:1)活性污泥 过程受到外部干扰如温度、入水水质、入水流量 和操作状态,以及内部因素如活性污泥微生物活 性的影响;2)假设各生化反应器为完全混合式,未 考虑由于返混等液体流动现象对微生物分布、反 应速率的影响;3)划分为完全混合式的反应器分 级数少,模型精度受限;4)假设二沉池内不发生 生化反应;5)二沉池模型采用一维重力固体通量 模型,未考虑二沉池内扩散等液体流动现象对沉 降速率的影响;6)二沉池分层数少,一般认为分 为30~50层时精度高;7)现场运行数据存在噪声 及大量缺失数据和离群点;8)采用统计方法进行 数据协调和校正时引入偏差;9)非最优神经网络 结构.建模误差可采用智能方法如神经网络、模糊 规则、专家系统等作为误差补偿器来消除^[13].





图 5 递阶神经网络模型仿真结果



6 结论(Conclusion)

本文为具有串级结构的某污水处理厂A/O脱氮 过程提出一类结合活性污泥知识的递阶神经网络 建模方法,神经网络与过程机理模型以串级形式 连接.证明了辨识算法的稳定性,实验研究表明, 所提的建模方法具有稳定学习功能.本文提出的 递阶神经网络建模方法对解决复杂串级工业过程 的建模问题具有重要意义.

参考文献(References):

- ZHU J B, JIM Z, RAO M, et al. An on-line wastewater quality predication system based on a time-delay neural network[J]. *Engineering Applications of Artificial Intelligence*, 1998, 11(6): 747 – 758.
- [2] DAE S L, PETER A. Vanrolleghem, and Jong Moon Park. Hybird neural network modelling of a full-scale industrial wastewater treatment process[J]. *Biotechnology and Bioengineering*, 2002, 78(6): 670 – 682.

- [3] DAE S L, PETER A. Vanrolleghem, and Jong Moon Park. Parallel hybrid modeling methods for a full-scale cokes wastewater treatment plant[J]. *Journal of Biotechnology*, 2005, 115(3): 317 – 328.
- [4] DUAN J C, CHUNG F L. Cascaded fuzzy neural network model based on syllogistic fuzzy reasoning[J]. *IEEE Transactions on Fuzzy Systems*, 2001, 9(2): 293 – 306.
- [5] RICARDO J G, CAMPELLO B. Hierarchical fuzzy relational models: Linguistic interpretation and universal approximation[J]. *IEEE Transactions on Fuzzy Systems*, 2006, 14(3): 446 – 453.
- [6] ANDERSON J S, KIM H, MCAVOY T J, et al. Control of an alternating aerobic-anoxic activated sludge system - Part 1 Development of a linearization-based modeling approach[J]. *Control Engineering Practice*, 2000, 8(3): 271 – 278.
- [7] HENZE M, GRADY C, GUJER W, et al. Activated sludge model[C] //IAWQ Scientific and Technical Report. London: IAWQ, 1987.
- [8] YU W, MARCO A. MORENO A, et al. System identification using hierarchical fuzzy neural networks with stable learning algorithm[J]. Journal of Intelligent & Fuzzy System, 2007, 18(2): 171 – 183.
- [9] LJUNG L, SODERSTROM T. Theory and Practice of Recursive System Identification[M]. Cambridge: The MIT Press, 1983.
- [10] YU W, LI X O. Discrete-time neuro identification without robust modification[J]. *IEE Proceedings: Control Theory and Applications*, 2003, 150(3): 311 – 316.

- [11] MOODY J, DARKEN C J. Fast learning in networks of locally-tuned processing units[J]. *Neural Computation*, 1989, 1(2): 281 – 294.
- [12] ZHAO L J, CHAI T Y. Wastewater BOD forecasting model for optimal operation using robust time-delay neural network[J]. *Lecture Notes Computer Science*, 2005, 3498(3): 1028 – 1033.
- [13] 贾文君, 柴天佑. 稀土串级萃取分离过程元素组分含量的多模型软测量[J]. 控制理论与应用, 2007, 24(4): 569 573.
 (JIA Wenjun, CHAI Tianyou. Soft-sensor of element component content based on multiple models for the rare earth cascade extraction process[J]. Control Theory & Applications, 2007, 24(4): 569 573.)

作者简介:

丛秋梅 (1978—), 女, 博士研究生, 研究方向为复杂工业过程的智能建模, E-mail: cong_0828@tom.com;

柴天佑 (1947—), 男, 中国工程院院士, 教授, 博士生导师, 研 究方向为自适应控制、智能解耦控制、流程工业过程综合自动化系 统等;

余 文 (1965—), 男, 教授, 博士生导师, 研究方向为自适应控制、神经网络、模糊控制、递阶神经网络建模及其应用等.