

# 基于神经网络的污水处理预测控制

逢泽芳,韩红桂,乔俊飞

(北京工业大学 电子信息与控制工程学院,北京 100124)

**摘要:**针对国际水协(IWA)开发的基准仿真模型(Benchmark simulation model No.1, BSM1)中第5分区溶解氧质量分数和第2分区硝态氮质量分数的控制问题,提出了一种基于神经网络的多变量预测控制系统。控制系统中主要包括两部分:神经网络辨识器,用于提取对象的输出数据;神经网络控制器,用于输出控制变量。仿真结果表明:基于神经网络的预测控制系统具有较好的适应性和鲁棒性。

**关键词:**神经网络预测控制;污水处理;溶解氧质量浓度;硝态氮质量浓度

**中图分类号:**TP183 **文献标志码:**A **文章编号:**1671-5497(2011)Sup.1-0280-05

## Predictive control for wastewater treatment process based on neural network

PANG Ze-fang, HAN Hong-gui, QIAO Jun-fei

(College of Electronic and Control Engineering, Beijing University of Technology, Beijing 100124, China)

**Abstract:** A new multi-objective predictive control system based on the neural network was proposed for activated sludge wastewater treatment process. Both the dissolved oxygen level in the fifth compartment and the nitrate level in the second anoxic tank were controlled in the benchmark simulation model No.1 (BSM1). The control system mainly consists of two parts: one part is the identifier used to predict the outputs of the object; another part is the controller applied to control the variables of the system. The simulation results demonstrate the proposed control system owning better adaptability and greater robustness.

**Key words:** neural network predictive control; wastewater treatment; dissolved Oxygen; nitrate

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,导致其过程控制十分困难。但随着对污水处理方法的深入研究,建立的数学模型也日趋成熟。2002年在欧盟科学技术与合作组织(COST)的682号和624号计划的研究人员,与国际水协合作的“基于呼吸运动计量法来控制活性污泥过程”的课题组开发的“1号基准仿真模型”(Benchmark simulation model No.1, BSM1)<sup>[1]</sup>,定义了一种污水处理的设备布局、

相应的仿真模型、污水负荷、仿真步骤和仿真结果的评价标准,为控制方案的开发提供了一个方便、快捷的平台。

目前很多学者在BSM1的基础上,对污水处理的过程控制进行了大量的研究<sup>[2-8]</sup>。其中Shen等<sup>[5]</sup>以BSM1活性污泥处理过程为对象,对最优控制和预测控制的曝气能耗进行比较。Holenda等<sup>[6]</sup>基于BSM1模型,采用预测控制策略,对溶解氧质量分数进行控制。张平等<sup>[8]</sup>以BSM1为平台,讨论了PID控制、增益调度控制和一般模

收稿日期:2010-02-13.

基金项目:国家自然科学基金项目(61034008).

作者简介:逢泽芳(1986-),女,硕士研究生.研究方向:控制科学与工程.E-mail:miya29@126.com

型控制 3 种控制方法的性能。基于研究发现模糊控制缺乏自学习能力、适应性比较差、控制精度不高;模型预测控制是基于数学模型的预测控制,模型精度不高,实际应用比较困难。而由神经元构成的神经网络具有强大的非线性映射能力和学习功能,可很好地对非线性系统进行预测控制。但目前大多数研究都是针对溶解氧质量分数的控制,关于硝态氮质量浓度控制的研究较少。

本文针对污水处理系统的非线性、大惯性、大时滞及时变等特点,采用神经网络预测控制算法,对溶解氧质量浓度和硝态氮质量浓度进行同时控制。介绍了活性污泥污水处理基准仿真模型 BSM1,给出了神经网络预测控制结构,最后给出了控制系统的仿真结果。

## 1 污水处理过程的预测控制

### 1.1 污水处理过程 BSM1 模型

活性污泥污水处理基准仿真模型 BSM1<sup>[1]</sup> 的总体布局如图 1 所示,包括生化反应池和二沉池两部分。生化反应池部分共包括 5 个单元,前 2 个单元是缺氧区,后 3 个单元是好氧区。

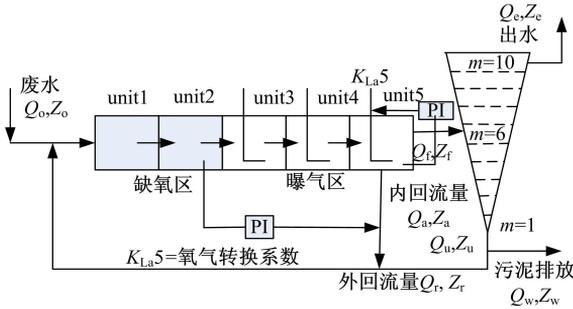


图 1 BSM1 的设备布局图

Fig.1 The equipment layout of BSM1

每个单元中,  $Q_k$  表示流量;  $Z_k$  表示各组分的质量分数,  $Z = (S_I, S_S, X_I, X_S, X_{B,H}, X_P, S_{NO}, S_{NH}, S_{ND}, X_{ND}, S_{ALK})$ ;  $r_k = v_{k1,\beta} + v_{k2,\beta} + \dots + v_{k8,\beta}$  表示各组分的反应速率;缺氧区 2 个单元的体积  $V_1 = V_2 = 1000 \text{ m}^3$ ,好氧区 3 个单元的体积  $V_3 = V_4 = V_5 = 1333 \text{ m}^3$ 。各单元的物料平衡方程如下。

单元一( $k=1$ ):

$$\frac{dZ_1}{dt} = \frac{1}{V_1} (Q_a Z_a + Q_r Z_r + Q_0 Z_0 + r_1 V_1 - Q_1 Z_1) \quad (1)$$

式中:  $Q_a$ 、 $Q_r$ 、 $Q_0$  分别为混合液回流量、污泥回流量和入水流量;  $Q_1 = Q_a + Q_r + Q_0$ 。

其他单元( $k=2\sim 5$ ):

$$\frac{dZ}{dt} = \frac{1}{V_k} (Q_{k-1} Z_{k-1} + r_k V_k - Q_k Z_k) \quad (2)$$

式中:  $Q_k = Q_{k-1}$ 。

### 1.2 神经网络预测控制系统

神经网络预测控制 (Neural network predictive control, NNPC) 系统包括 3 个神经网络:一个是神经网络辨识器 (NNI),用于预测对象的未来输出,另两个是神经网络控制器 (NPC),用于输出控制序列, NPC<sub>1</sub> 控制第 5 分区的氧转换系数  $K_{La,5}$  和 NPC<sub>2</sub> 控制内回流量  $Q_a$ 。控制结构框图如图 2 所示。图中  $u_1(k)$ 、 $u_2(k)$  为  $k$  时刻的系统控制量;  $y_1(k-1)$ 、 $y_2(k-1)$  为  $k-1$  时刻系统输出值;  $y_{r,1}$ 、 $y_{r,2}$  分别为溶解氧和硝态氮质量分数的期望值;  $y_1(k+p)$ 、 $y_2(k+p)$  为模型补偿后的系统预测值;  $\hat{y}_{1,2}(k+p)$  为预测在  $k$  时刻  $p$  步之后系统的输出值;  $y_{1,2}(k)$  为系统实际输出值;  $e(k)$  为预测值与实际输出的误差;  $J_1(k)$  为神经网络辨识器权值的学习指标函数。辨识器和控制器都由 BP 神经网络实现的。

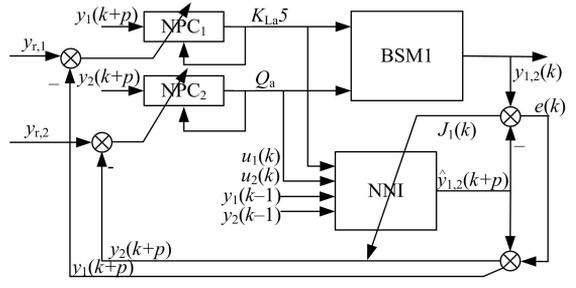


图 2 神经网络预测控制结构框图

Fig.2 Structure of neural network predictive control

#### 1.2.1 神经网络辨识器 (NNI)

(1) 基于神经网络的递推多步预测

设系统可以用以下的离散时间模型表示:

$$y(k) = f[u(k-N_d), \dots, u(k-n_u), y(k-1), y(k-2), \dots, y(k-n_y)] \quad (3)$$

式中:  $n_y$ 、 $n_u$  分别代表系统的离散表达式所用到的过去时刻输出量及输入量的个数;  $u(k)$  为离散系统的控制量;  $y(k)$  为期望输出;  $f(\cdot)$  表示前馈网络实现的非线性函数;  $N_d$  为非线性系统的滞后拍数。

系统(3)可用下面给出的模型来预测  $k+1$  时刻的系统预测输出值:

$$\hat{y}(k+1) = f[u(k-N_d+1), \dots, u(k-n_u+1), y(k), y(k-1), \dots, y(k-n_y+1)] \quad (4)$$

基于递推算法的原理<sup>[9]</sup>可以得到预测  $p$  步

时系统的预测输出值,即重复使用此模型向前多步预测。预测下一步时,将前面预测出来的结果作为输入的一部分。

$$\begin{aligned} & \text{根据归纳原理预测 } k+p \text{ 时刻的输出值为} \\ \hat{y}(k+p) &= f[u(k-N_d+p), \dots, u(k-n_u+p), \\ & y(k-1+p), y(k-2+p), \dots, y(k-n_y+p)] \end{aligned} \quad (5)$$

此处需要注意的是,建立神经网络的个数不需要与预测步长相等,只需要一个神经网络,输入系统的输入输出数据,通过训练建立系统的单步预测模型,将多个单步模型串联即可获得多步预测模型。

(2)神经网络预测模型(NNI)的描述和在线学习

①NNI 的描述

设系统可以用式(3)表示。对神经网络预测模型(NNI)进行训练使其学习非线性函数  $f(\bullet)$ 。神经网络采用三层 BP 神经网络,包括输入层( $i$ 层)、隐含层( $h$ 层)和输出层( $j$ 层),其输入为

$$x(k) = [u(k-N_d), u(k-N_d+1), \dots, u(k-n_u), y(k-1), y(k-2), \dots, y(k-n_y)]^T \quad (6)$$

神经网络的表述如下:

$$X_h(k) = W_{hi} \times x_i(k) \quad (7)$$

$$\hat{y}_h(k) = W_{jh} \times g_h(X_h(k)) =$$

$$W_{jh} \times \frac{1}{1 + e^{-X_h(k)}}, h=1, 2, \dots, n_h \quad (8)$$

式中: $x_i(k)$ 为输入层第  $i$  个神经元的输入; $W_{hi}$ 为输入层到隐含层的权值; $n_h$ 为隐含层神经元的数目; $g_h(\bullet)$ 为隐含层的传输函数,这里为 S 型函数; $W_{jh}$ 为隐含层到输出层的权值; $i=1, 2, \dots, n_y + n_u + 1$ 。

②NNI 的在线学习<sup>[10]</sup>

为了在线更新 NNI 的权值  $W_{hi}$  和  $W_{jh}$ ,定义以下性能指标函数:

$$J(k) = \frac{1}{2} [y(k) - \hat{y}(k)]^2 \quad (9)$$

通过动态 BP 算法迭代更新神经网络的各个权值,使性能指标函数  $J(k)$  达到其最小值。权值更新方式为

$$W(k+1) = W(k) - \eta \frac{\partial J(k)}{\partial W(k)} \quad (10)$$

式中: $\eta$ 为学习率, $\eta > 0$ 。

依次类推,可以构造预测  $k+1, k+2, \dots, k+p$  时刻的输出  $\hat{y}(k+1), \hat{y}(k+2), \dots, \hat{y}(k+p)$  的

神经网络,此处采用递推的模式来预测未来  $p$  个时刻的输出,只需要构建一个神经网络。

预测  $\hat{y}(k+p)$  时神经网络的输入为

$$x(k+p) = [u(k-N_d+p), \dots, u(k-n_u+p), y(k+p-1), \dots, y(k-n_y+p)]^T \quad (11)$$

输出为

$$\hat{y}(k+p)$$

对于  $u(k), u(k+1), \dots, u(k-N_d+p)$  等未知输入量,以 NPC 预测出来的值代替,如果超出预测范围,则以最后的预测值代替。

1.2.2 神经网络控制器(NPC)

(1) NPC 的描述

神经网络预测控制器(NPC)的目的是提高系统的跟踪特性和抗扰动性能。利用三层 BP 网络建立神经网络预测控制器(NPC),神经网络的输入为

$$z(k) = [u(k-1), y(k), \dots, y(k-n_y+1), y_r(k), y_r(p)]^T \quad (12)$$

输出为

$$U(k) = [u(k), u(k+1), \dots, u(k+M-1)]^T \quad (13)$$

式中: $y_r(k)$ 为期望的输出; $M$ 为控制时域长度。

神经网络的表述如下:

$$X_h^c(k) = W_{hi}^c \times z_i(k) \quad (14)$$

$$U(k) = W_{jh}^c \times g_h(X_h^c(k)) =$$

$$W_{jh}^c \times \frac{1}{1 + e^{-X_h^c(k)}}, h=1, 2, \dots, m_h \quad (15)$$

式中: $z_i(k)$ 为输入层第  $i$  个神经元的输入; $W_{hi}^c$ 为输入层到隐含层的权值; $m_h$ 为隐含层神经元的数目; $g_h(\bullet)$ 为隐含层的传输函数,这里为 S 型函数; $W_{jh}^c$ 为隐含层到输出层的权值; $i=1, 2, \dots, n_y + p + 1$ 。

(2) NPC 的权值调整

基于神经网络预测控制律,采用最小化式(16)中的性能函数,对神经网络控制器的权值进行在线调整。

$$\begin{aligned} J_c(k) &= \frac{1}{2} \sum_{p=N_d}^{N_p} [y_r(k+p) - \hat{y}(k+p)]^2 + \\ & \frac{1}{2} \sum_{i=0}^{M-1} \lambda [\Delta u(k+i)]^2 \end{aligned} \quad (16)$$

式中: $y_r(k+p)$ 为未来期望的输出值; $\hat{y}(k+p)$ 为

未来的预测输出值; $\lambda$ 为选择的控制量加权;  
 $\Delta u(k)=u(k)-u(k-1)$ ;  $N_p$  为预测时域长度。

通过动态 BP 算法 (DBP) 来修正神经网络预测控制器 (NPC) 的权值, 公式如下:

$$W^c(k+1)=W^c(k)-\eta \frac{\partial J_c(k)}{\partial W^c(k)} \quad (17)$$

式中: $\eta$  为一个正的学习率。

在只计算未来一步控制量的情况下, 即  $M=1$  时:

$$u(k)=u(k+1)=\dots=u(k+N_p-N_d),$$

$$\frac{\partial u(k+1)}{\partial u(k)}=0。$$

在  $M$  不为 1 的情况下, 即计算并且输出  $M$  步控制量, 则神经网络的输出为

$$U(k)=[u(k), u(k+1), \dots, u(k+M-1)]^T,$$

$$u(k+M)=\dots=u(k+N_p-N_d)=u(k+M-1)。$$

## 2 试 验

国际水协会 (IWA) 以污水处理厂实际的运行操作数据为基础, 设计了 3 个关于进厂污水情况的输入文件, 分别对应晴好天气、连绵雨天气和暴雨天气时的污水流量和组分变化<sup>[1]</sup>。这些数据的采样间隔为 15 min, 污水组分已经抽象为 ASM1 中对应的 13 种元素。在此采用晴天气下 7 天的数据来验证神经网络预测控制的效果。图 3~图 6 为仿真实验结果图。

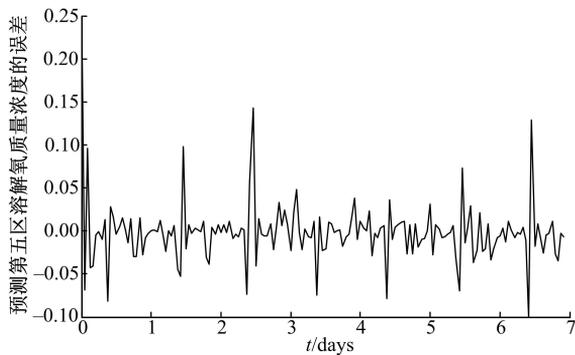


图 3 神经网络预测溶解氧质量浓度误差图

Fig. 3 The error of dissolved oxygen concentration in neural network prediction

在仿真试验中, 溶解氧质量浓度的常规增量式 PID 控制器的  $K_p, K_i, K_d$  分别取为 10, 2.0 和 0.5; 而硝态氮的质量浓度分别取为 20 000, 4000 和 500 mg/L。神经网络预测控制器的预测时域  $N_p=4$ , 控制时域  $M=2$ 。预测神经网络 (NNI) 选

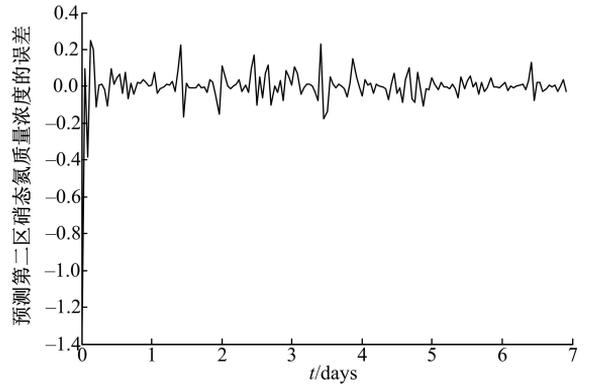


图 4 神经网络预测硝态氮质量浓度误差图

Fig. 4 The error of nitrate concentration in neural network prediction

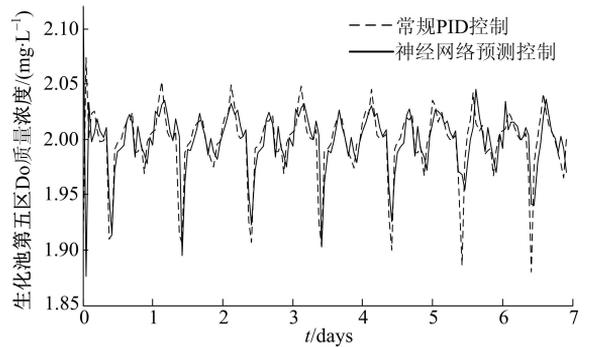


图 5 溶解氧质量浓度比较图

Fig. 5 Comparison of dissolved oxygen concentration

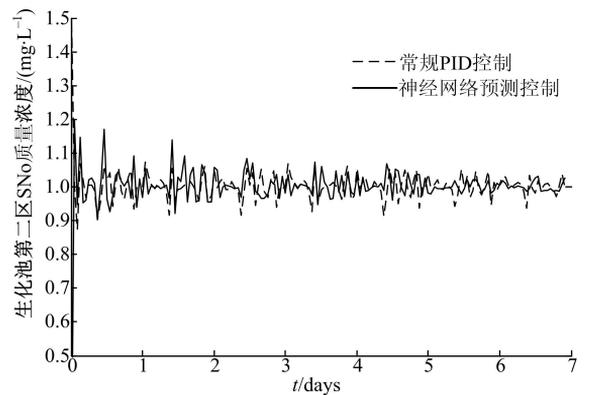


图 6 硝态氮质量浓度比较图

Fig. 6 Comparison of nitrate concentration

择 4-12-2, 两个预测控制神经网络 (NPC) 选择 2-5-1,  $n_h=2, n_y=2, n_b=12, m_h=5, \eta=0.5, \eta_f=0.2, \lambda=0.01$ , 滞后拍数  $N_d=0$ 。由仿真结果可知: 神经网络预测的精度较高, 误差基本上都控制在 0.1 内。溶解氧的质量浓度和硝态氮的质量浓度也均能较好地控制在 2 mg/L 和 1 mg/L 上。与文献[6]中只预测控制的溶解氧质量浓度相比, 不仅溶解氧控制在期望值范围内, 硝态氮也

控制在期望值上,且控制精度较高。而且从图 5 中可以看出,当达到稳定状态之后,神经网络预测控制溶解氧质量浓度的误差较常规 PID 的小,且能较好地将两个变量控制在设定值范围内,控制精度较高,具有良好的动态特性和抗干扰能力。

### 3 结束语

将神经网络预测控制方案应用到污水处理过程中,对溶解氧和硝态氮质量浓度的控制进行了仿真研究。仿真结果表明:该方案具备较强的可行性,虽然其算法比较复杂,但其动态性能和自适应性都优于常规 PID 控制算法,具有良好的自适应性和鲁棒性,解决了模型预测控制不精确和模糊控制缺乏自学习能力、适应性比较差的问题,提高了控制精度。在控制溶解氧质量浓度的同时对硝态氮质量浓度也进行了控制,解决了只控制溶解氧质量浓度而引起的内回流量增大的问题。

#### 参考文献:

[1] 刘大伟,沈文浩.活性污泥法污水处理基准仿真模型的开发及进展[J].中国给水排水,2007,23(20):20-25.  
Liu Da-we, Shen Wen-hao. Development of benchmark simulation model for activated sludge wastewater treatment [J]. China Water and Waste Water, 2007, 23(20): 20-25.

[2] 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.

[3] Leu S Y, Rosso D, Larson L E, et al. Real-time aeration efficiency monitoring in the activated sludge process and methods to reduce energy consumption and operating costs [J]. Water Environment Research, 2009, 81(12): 2471-2481.

[4] Ekman M. Bilinear black-box identification and MPC of the activated sludge process [J]. Journal of Process Control, 2008, 18(7/8): 643-653.

[5] Shen W H, Chen X Q, Corriou J P. Application of model predictive control to the BSM1 benchmark of wastewater treatment process [J]. Computers and Chemical Engineering, 2008, 32(12): 2849-2856.

[6] 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.

[7] Piotrowski R, Brdys M A. Hierarchical dissolved oxygen control for activated sludge processes [J]. Control Engineering Practice, 2008, 16(1): 114-131.

[8] 张平,苑明哲,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 Ming-zhe, Wang Hong. Study on dissolved oxygen control method based on international evaluation benchmark [J]. Information and Control, 2007, 36(2): 199-203.

[9] Su H T, McAvoy T J. Identification of chemical processes using recurrent networks [J]. Proceeding of American Control Conference, 1990: 2314-2319.

[10] Tan Y H, Cauwenbergh V A. Neural-network-based d-step-ahead predictors for Nonlinear systems with time delay [J]. Applications of Artificial Intelligence, 1999, 12(1): 21-35.