

基于LM算法的溶解氧神经网络预测控制

李明河¹ 周磊¹ 王健²

(1. 安徽工业大学电气与信息工程学院, 马鞍山 243002; 2. 安徽华骐环保科技股份有限公司, 马鞍山 243000)

摘要: 针对污水处理溶解氧时变、非线性以及设定值难以跟踪控制的问题, 提出了一种基于 Levenberg - Marquardt 算法(LM 算法)的溶解氧浓度神经网络预测控制器的设计方法。首先在国际水协提出的活性污泥 1 号模型(ASM1)基础上, 经过合理的假设和约束, 得到简化的溶解氧浓度模型, 经过 BP 神经网络系统辨识和模型预测设计了溶解氧神经网络预测控制器。并采用 LM 算法改进了 BP 神经网络, 克服了容易陷入局部极小值、收敛速度慢的缺点, 提高了神经网络预测精度。仿真结果表明, 神经网络预测控制具有很好的自适应性和鲁棒性, 提高了溶解氧跟踪控制性能。

关键词: 污水处理; 溶解氧浓度; 神经网络预测控制; Levenberg - Marquardt 算法

中图分类号: TP183; X832 **文献标识码:** A **文章编号:** 1000-1298(2016)06-0297-06

Neural Network Predictive Control for Dissolved Oxygen Based on Levenberg - Marquardt Algorithm

Li Minghe¹ Zhou Lei¹ Wang Jian²

(1. School of Electrical and Information Engineering, Anhui University of Technology, Maanshan 243002, China

2. Anhui Huaqi Environment Protection Technology Co., Ltd., Maanshan 243000, China)

Abstract: The dissolved oxygen (DO) concentration is of great importance to wastewater treatment due to its influence on effluent quality and operational costs. However, the DO concentration is difficult to be controlled owing to the time-varying and nonlinear characteristics. Considering these issues, a neural network predictive controller (NNPC) based on Levenberg - Marquardt (LM) algorithm was proposed. Firstly, a simplified DO model was established after reasonable hypotheses and constrains in terms of activated sludge model No. 1 (ASM1) proposed by International Water Association (IWA). Then the NNPC was applied to the simplified DO model through system identification with BP neural network and model prediction. Furthermore, the LM algorithm integrated the advantages of the gradient steepest descent and Newton methods was used to improve the general BP neural network, which overcame the drawbacks of falling into local minimum easily and slow convergence speed. The simulation results indicated that the improved neural network had good performance in system identification with error less than 3%. Compared with conventional PID control and model predictive control (MPC), the NNPC achieved smoother and better tracking performance and brought obvious improvement. Finally, two measured disturbances were added and good adaptability and robustness were obtained by NNPC. In this way, this method not only can achieve the standard of effluent water quality, but also can reduce the energy consumption of aeration significantly.

Key words: wastewater treatment; dissolved oxygen concentration; neural network predictive control; Levenberg - Marquardt algorithm

收稿日期: 2015-11-29 修回日期: 2016-01-12

基金项目: “十二五”国家科技支撑计划项目(2014BAC01B04)、安徽省科技攻关重大项目(1301041023)和安徽省软科学研究项目(1502052034)

作者简介: 李明河(1963—),女,教授,主要从事复杂系统建模、智能控制和大型网络化控制系统研究, E-mail: limh@ahut.edu.cn

引言

曝气池中溶解氧浓度直接影响有机物的去除效率,并在活性污泥法污水处理过程中影响活性污泥的生长,同时也是影响运行费用和出水水质的重要因素,所以在运行中溶解氧浓度是过程控制和反应时间的重要控制参数^[1]。

根据不同的进水水质,溶解氧浓度的设定值是相应变化的,为实现对溶解氧设定值更为精确地跟踪控制,国内外学者做了大量研究^[2-5]。ZENG等^[6]采用反向传播(BP)神经网络建立了污染物的去除率和化学药物加量之间的非线性关系,并指出存在的问题是BP网络训练易陷入局部极小值。乔俊飞等^[7]针对活性污泥法污水处理过程能耗高的问题,设计了一种智能优化控制系统,利用神经网络预测污水处理过程的输出,在出水水质达标的前提下降低污水处理能耗。尽管国内外学者运用神经网络解决了诸多非线性系统的建模和预测问题,但不可避免的是神经网络仍存在过拟合、易陷入局部极小值、算法不成熟等缺陷。现有的控制方法中,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,在模型失配时会导致控制输出不能满足控制要求。

LM算法集成了梯度下降法和高斯-牛顿算法的优点,既有高斯-牛顿算法的局部收敛性,又有梯度下降法的全局特性^[8]。神经网络预测控制器充分利用了神经网络的非线性映射能力以及预测控制滚动优化、反馈校正的机理,更符合复杂系统控制的不确定性和时变性的实际情况。本文以LM算法改进的BP神经网络作为溶解氧的预测模型,克服传统BP神经网络收敛速度慢、容易陷入局部极小值的缺点,并将神经网络预测控制应用于溶解氧的跟踪控制,在控制过程中采用网络训练算法对网络权值和阈值进行滚动优化,以提高预测精度和稳定性。

1 污水处理系统数学模型

活性污泥法水处理系统如图1所示,主要包括:曝气池、二沉池、污泥回流系统以及剩余污泥排放系统^[9-10]。

在国际水协会推出的活性污泥1号模型(ASM1)的基础上,根据物料平衡原理,对系统作如下合理假设:

(1)假设活性污泥处理过程只发生自养菌好氧生长过程,微生物生长率大于死亡率并满足Monod规则。

(2)二沉池不发生生化反应。




图1 活性污泥法水处理系统基本流程

Fig.1 Process of activated sludge wastewater treatment system

(3) 进水生物量 $X_i = 0$ 和沉淀后出水生物量 $X_e = 0$ 。

(4) 有机底物浓度的饱和常数 $K_s \ll S$ 。

(5) 回流污泥影响污泥泥龄与生长系数。

在以上的假设条件下,可得到活性污泥水处理系统模型为

$$\begin{cases} \frac{dX}{dt} = \left(\tilde{\mu} - b_H - \frac{CQ_w}{V} \right) X + \delta O \\ \frac{dS}{dt} = -\frac{\tilde{\mu}}{Y_H} X + \frac{Q}{V} (S_i - S) \\ \frac{dO}{dt} = \frac{-\tilde{\mu}(1 - Y_H) - f_x Y_H b_H}{Y_H} X - \delta O + u_1 \end{cases} \quad (1)$$

式中 X ——微生物质量浓度, g/m^3

S ——底物质量浓度, g/m^3

O ——溶解氧的质量浓度, g/m^3

S_i ——进水底物质量浓度, g/m^3

u_1 ——曝气量, $g/(m^3 \cdot d)$

其他参数取值见表1。

表1 模型参数

Tab.1 Model parameters

参数	数值
异养菌生长速率 $\tilde{\mu}/d^{-1}$	3 ~ 6
异养菌衰减系数 b_H/d^{-1}	0.2 ~ 0.62
进水量 $Q/(m^3 \cdot d^{-1})$	20 000 ~ 21 000
反应器体积 V/m^3	2 000 ~ 2 500
二沉池浓度沉降因子 C	2
剩余污泥排放量 $Q_w/(m^3 \cdot d^{-1})$	20 ~ 50
底物消耗系数 f_x	0.02
微生物产率系数 Y_H	0.67
对溶解氧设置的冲量系数 δ	1

可以确定系统模型中各参数的上、下界为

$$\tilde{\mu} - b_H - \frac{CQ_w}{V} \in [2.355, 5.784]$$

$$-\frac{\tilde{\mu}}{Y_H} \in [-8.955, -4.477]$$

$$-\frac{Q}{V} \in [-10.5, -8]$$

$$\frac{-\tilde{\mu}(1 - Y_H) - f_x Y_H b_H}{Y_H} \in [-7.955, -5.477]$$

在上、下界范围内任意选择一组参数,方程(1)

可转换为

$$\begin{bmatrix} \dot{X}(t) \\ \dot{S}(t) \\ \dot{O}(t) \end{bmatrix} = \begin{bmatrix} 3.478 & 0 & 1 \\ -5.263 & -9.5 & 0 \\ -6.354 & 0 & -1 \end{bmatrix} \begin{bmatrix} X(t) \\ S(t) \\ O(t) \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} u(t)$$

$$y(t) = \begin{bmatrix} 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} X(t) \\ S(t) \\ O(t) \end{bmatrix}$$

由稳定性分析可知,该参数下的系统在右半平面存在极点,因此系统是不稳定的。经过可控性分析,系统是可控制的,从而系统可以通过状态反馈来配置极点改善系统的稳定性,将系统的期望极点确定为一对闭环主导极点 $p_{1,2} = -1 \pm j0.25$ 和一个远离虚轴的极点 p_3 ,从而可确定系统模型的状态反馈增益矩阵为 $K = [23.816 \quad 32.150 \quad 1.978]$ 。

2 神经网络预测控制

基于神经网络的模型预测即采用神经网络去近似被控对象模型,通过必要的训练建立预测信号 $y_m(k+j)$ 的神经网络模型。模型预测首先建立被控对象的神经网络模型,即系统辨识;第二步是使用控制器来预测未来神经网络的性能。基于神经网络的模型预测控制结构如图2所示^[11-17]。




图2 神经网络预测控制结构图

Fig. 2 Structure diagram of neural network predictive control

其中 $y_r(k+j)$ 为参考输入; $y(k)$ 为对象输出; $y_m(k+j)$ 为预测模型输出; $e_m(k)$ 为预测模型误差; $u(k)$ 为最优控制信号。

神经网络预测控制算法框图如图3所示。

2.1 系统辨识

模型预测第一步是训练神经网络,神经网络模型利用当前输入和当前输出预测神经网络未来输出值,并将预测误差,作为神经网络的训练信号。实际输出与模型预测之间的误差为

$$e_m(k) = y(k) - y_m(k) \quad (2)$$

则经过反馈校正后模型的预测输出为

$$y_p(k+j) = y_m(k+j) + h e_m(k) \quad (3)$$

式中 h ——误差修正系数

2.2 模型预测

模型预测方法是基于水平后退的方法,神经网

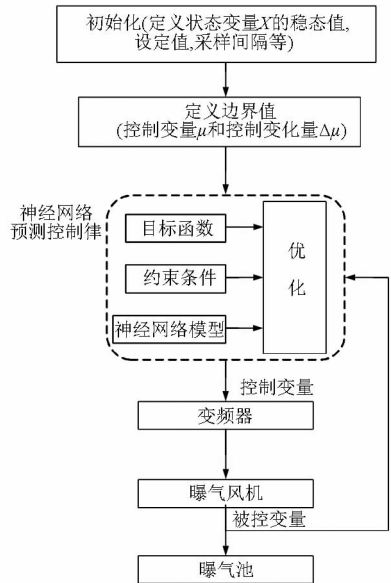


图3 神经网络预测控制算法框图

Fig. 3 Block diagram of neural network predictive control algorithm

络模型预测在指定时间内预测模型响应^[18-19]。引入滚动优化的性能指标,通过最小化 J 确定最优控制信号。

$$J = \sum_{j=1}^{N_2} (y_r(k+j) - y_p(k+j))^2 + \rho \sum_{j=1}^{N_u} (u(k+j-1) - u(k+j-2))^2 \quad (4)$$

式中 N_2 ——控制时域长度

N_u ——预测时域长度

ρ ——控制量加权系数

3 Levenberg - Marquardt 算法

LM 算法及其具体步骤如下^[20-23]：

设神经网络的误差指标函数为

$$E(x) = \frac{1}{2} \sum_{i=1}^N \| Y_i - \hat{Y}_i \|^2 = \frac{1}{2} \sum_{i=1}^N e_i^2(x) \quad (5)$$

式中 Y_i ——预期的网络输出向量

\hat{Y}_i ——实际的网络输出向量

$e_i(x)$ ——当前误差

设 x_k 为第 k 次迭代的网络权值向量,维数为 M ,根据牛顿算法新的权值向量 x_{k+1} 根据以下规则求得

$$x_{k+1} = x_k + \Delta x_k = x_k - H_k^{-1} g_k \quad (6)$$

式中 H_k ——Hessian 矩阵 g_k ——当前梯度

$$[\nabla E(x)]_j = \frac{\partial E(x)}{\partial x_j} = \sum_{i=1}^q e_i(x) \frac{\partial e_i(x)}{\partial x_j} \quad (7)$$

$$\nabla E(x) = J^T(x) e(x)$$

则 $H_k = \nabla^2 E(x) |_{x=x(k)} = J^T(x) J(x) + S(x)$

$$S(x) = \sum_{i=1}^N e_i(x) \nabla^2 e_i(x)$$

$$\mathbf{g}_k = \nabla \mathbf{E}(x) |_{x=x(k)} = \mathbf{J}^T(x) \mathbf{e}(x)$$

其中

$$\mathbf{J}(x) = \begin{bmatrix} \frac{\partial e_1}{\partial x_1} & \frac{\partial e_1}{\partial x_2} & \dots & \frac{\partial e_1}{\partial x_n} \\ \frac{\partial e_2}{\partial x_1} & \frac{\partial e_2}{\partial x_2} & \dots & \frac{\partial e_2}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_q}{\partial x_1} & \frac{\partial e_q}{\partial x_2} & \dots & \frac{\partial e_q}{\partial x_n} \end{bmatrix}$$

式中 \mathbf{J} ——雅可比矩阵

当靠近误差指标函数的最小值时,矩阵的 S 元素变得很小,则

$$\nabla^2 \mathbf{E}(x) = \mathbf{J}^T(x) \mathbf{J}(x) \quad (8)$$

从而

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\mathbf{J}^T(x_k) \mathbf{J}(x_k)]^{-1} \mathbf{J}^T(x_k) \mathbf{e}(x_k) = \mathbf{x}_k - \mathbf{H}^{-1}(x_k) \mathbf{J}^T(x_k) \mathbf{e}(x_k) \quad (9)$$

其中 \mathbf{H} 是 Hessian 矩阵 ($\mathbf{H} = \mathbf{J}^T \mathbf{J}$), 然而矩阵 \mathbf{H} 不一定总是可逆,为了解决这个问题,考虑引入一个系数 λ_k ,代入式(9)可得更新权值的 LM 算法

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\mathbf{J}^T(x_k) \mathbf{J}(x_k) + \lambda_k \mathbf{I}]^{-1} \mathbf{J}^T(x_k) \mathbf{e}(x_k) \quad (10)$$

或者

$$\Delta \mathbf{x}_k = -[\mathbf{J}^T(x_k) \mathbf{J}(x_k) + \lambda_k \mathbf{I}]^{-1} \mathbf{J}^T(x_k) \mathbf{e}(x_k) \quad (11)$$

当 λ_k 很大时,LM 算法近似于梯度下降法;当 λ_k 很小时,则是高斯-牛顿算法。

其具体算法流程如下:

- (1) 给出训练的允许误差值 ε , 初始化权值向量 $\mathbf{x}, k=0$ 。
- (2) 计算网络的输出及误差向量 $\mathbf{E}(x)$ 。
- (3) 计算误差向量对网络权值的梯度值并形成雅可比矩阵。
- (4) 训练完成后,更新选择。
- (5) 如果网络收敛则停止,否则返回步骤(2)。

4 仿真实验

Matlab 软件的神经网络工具箱提供了可以用于 Simulink 仿真的神经网络预测控制器模块,可以直接用于任意复杂系统的预测控制。

系统辨识首先要产生用于神经网络训练的数据,在模型辨识窗口设定输入系统模型的随机信号参数以及神经网络的结构。这里选用基于 LM 算法的 3 层 BP 神经网络,利用所建的溶解氧简化模型产生 8 000 组训练数据,如图 4 所示。

在指定训练迭代次数和训练算法后,开始神经

网络的训练。图 5 显示了神经网络的训练结果和校验结果。仿真结果显示,误差在 3% 以内,表明神经网络辨识效果好。




图 4 系统辨识数据

Fig. 4 System identification data

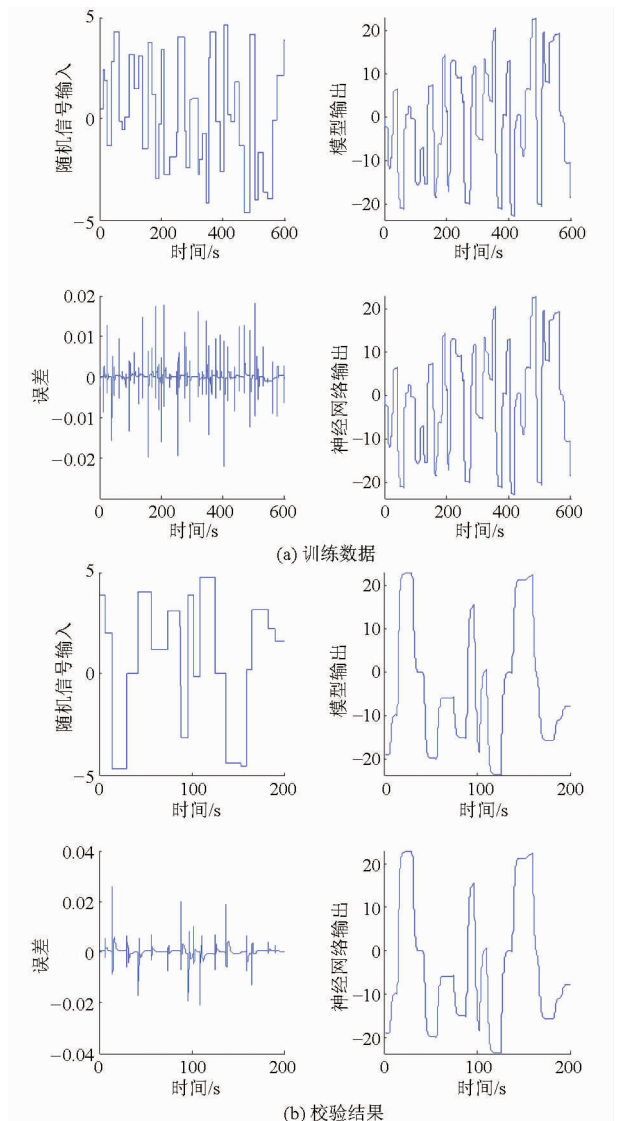


图 5 神经网络训练数据和校验结果

Fig. 5 Training data and validation results for neural network

在建立的神经网络模型之后,利用神经网络预测控制器预测未来的输出。优化算法使用这些预测

值来决定控制输入,以优化未来的性能^[24-25]。神经网络预测控制器的控制参数为:预测时域长度 10,控制时域长度为 8,控制量加权系数为 1.85,线性搜索参数为 0.02,神经网络预测控制结果如图 6 所示。




图 6 神经网络预测控制结果

Fig. 6 Result of NNPC

为了比较控制器的性能,本文选择了目前使用最为广泛的 PID 控制和模型预测控制 (MPC) 进行对比,仿真结果如图 7 所示。采用时间乘绝对误差积分准则 (ITAE)、绝对误差积分准则 (IAE)、时间乘平方误差积分准则 (ITSE) 和平方误差积分准则 (ISE) 4 个性能指标来对控制性能进行评价,即




图 7 NNPC、MPC、PID 溶解氧跟踪控制效果

Fig. 7 Tracking control performance of DO for NNPC, MPC and PID

$$I_{TAE} = \int_0^t t |y - y_{sp}| dt \quad (12)$$

$$I_{AE} = \int_0^t |y - y_{sp}| dt \quad (13)$$

$$I_{TSE} = \int_0^t t (y - y_{sp})^2 dt \quad (14)$$

$$I_{SE} = \int_0^t (y - y_{sp})^2 dt \quad (15)$$

性能指标量化结果如表 2 所示。从图 7 和表 2 可以看出神经网络预测控制表现了更好的跟踪控制精度。

表 2 PID, MPC and NNPC 性能指标

Tab. 2 Performance criteria for PID, MPC and NNPC

控制器	性能指标			
	ITAE	IAE	ISE	ITSE
PID	2 813. 700	48. 357 2	2 032. 7	32. 305 6
MPC	679. 007	14. 757 8	1 340. 9	28. 548 6
NNPC	536. 388	12. 705 1	1 160. 5	26. 389 6

为了进一步比较 3 种控制器的性能,分别在 $t = 7$ s 时刻加入 $d = -1$ 和 $t = 32$ s 时刻加入 $d = 1$ 的干扰。仿真结果表明神经网络预测控制具有更好的抗干扰性能,如图 8 所示。

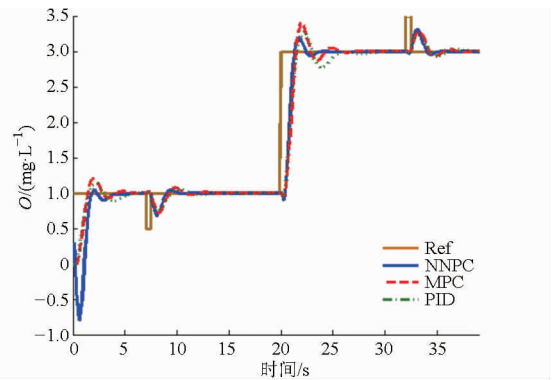


图 8 加干扰后的控制效果

Fig. 8 Control effect after exerting disturbance

5 结束语

以简化的活性污泥数学模型为基础,将神经网络预测控制应用于溶解氧的跟踪控制,结合 LM 算法对溶解氧模型进行预测,避免了一般 BP 神经网络容易陷入局部最小化的问题,加快了神经网络的收敛速度,所得训练的神经网络泛化能力强、拟合程度高。通过对比,发现神经网络预测控制相对于模型预测控制和传统的 PID 控制对溶解氧的跟踪控制效果好、抗干扰能力强。

参 考 文 献

- 王小文. 水污染控制工程[M]. 北京:煤炭工业出版社,2002.
- 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 Mingzhe, WANG Hong. Study on dissolved oxygen control method based on international evaluation benchmark[J]. Information and Control,2007,36(2):199-203. (in Chinese)
- SHEN Wenhao, CHEN Xiaoquan, JEAN Pierre Corriou. Application of model predictive control to the BSM1 benchmark of wastewater treatment process[J]. Computers and Chemical Engineering,2008,32(12):2849-2856.
- YANG Ting, QIU Wei, MA You, et al. Fuzzy model-based predictive control of dissolved oxygen inactivated sludge processes[J]. Neurocomputing,2014,136:88-95.

- 5 SANCHEZ E N, GONZALEZ J M, RAMIREZ E. Minimal PD fuzzy control of a wastewater treatment plant[C] // Proceedings of the 2000 IEEE International Symposium on Intelligent Control, 2000:169 - 173.
- 6 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.
- 7 乔俊飞, 逢泽芳, 韩红桂. 基于改进子群算法的污水处理过程神经网络优化控制[J]. 智能系统学报, 2012, 7(5):429 - 436. QIAO Junfei, PANG Zefang, HAN Honggui. Neural network optimal control for wastewater treatment process based on APSO[J]. CAAI Transactions on Intelligent Systems, 2012, 7(5):429 - 436. (in Chinese)
- 8 张娇, 邓贵仕. Levenberg - Marquardt 神经网络在煤矿作业人员人因可靠性评价中的应用研究[J]. 大连理工大学学报, 2015, 55(4):424 - 430. ZHANG Qiao, DENG Guishi. Investigation on application of Levenberg - Marquardt neural networks to human reliability evaluation of coalmine workers[J]. Journal of Dalian University of Technology, 2015, 55(4):424 - 430. (in Chinese)
- 9 刘超彬, 乔俊飞, 张芳芳. 污水处理过程中溶解氧的模糊神经网络控制[J]. 山东大学学报:工学版, 2005, 35(3):83 - 87. LIU Chaobin, QIAO Junfei, ZHANG Fangfang. Fuzzy neural network controls of dissolved oxygen in the wastewater treatment process[J]. Journal of Shandong University: Engineering Science, 2005, 35(3):83 - 87. (in Chinese)
- 10 黄银蓉, 张绍德. 污水处理曝气池溶解氧智能优化控制系统[J]. 信息与控制, 2011, 40(3):393 - 400. HUANG Yinrong, ZHANG Shaode. Dissolved oxygen intelligent optimization control system in aeration tank of wastewater treatment[J]. Information and Control, 2011, 40(3):393 - 400. (in Chinese)
- 11 席裕庚. 预测控制[M]. 2版. 北京:国防工业出版社, 2013.
- 12 韩敏. 基于微粒群的神经网络预测控制理论及应用[M]. 北京:中国水利水电出版社, 2013.
- 13 王爽心, 李朝霞, 刘海瑞. 基于小世界优化的变桨距风电机组神经网络预测控制[J]. 中国电机工程学报, 2012, 32(30):105 - 111. WANG Shuangxin, LI Zhaoxia, LIU Hairui. Neural network predictive control of variable pitch wind turbines based on small-world optimization algorithm[J]. Proceedings of the CSEE, 2012, 32(30):105 - 111. (in Chinese)
- 14 王世虎, 沈炯, 李益国. 基于逆模型区间优化的神经网络预测控制[J]. 中国电机工程学报, 2007, 27(26):115 - 120. WANG Shihu, SHEN Jiong, LI Yiguo. Neural networks predictive control using optimizing intervals of inverse models[J]. Proceedings of the CSEE, 2007, 27(26):115 - 120. (in Chinese)
- 15 周伟, 李永博, 汪小昆. 基于 CFD 非稳态模型的温室温度预测控制[J]. 农业机械学报, 2014, 45(12):335 - 340. ZHOU Wei, LI Yongbo, WANG Xiaochan. Model predictive control of air temperature in greenhouse based on CFD unsteady model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(12):335 - 340. (in Chinese)
- 16 张学阳, 项雷军, 林文辉, 等. 神经网络预测控制在污水处理溶解氧控制中的应用[J]. 华侨大学学报:自然科学版, 2015, 36(3):280 - 285. ZHANG Xueyang, XIANG Leijun, LIN Wenhui, et al. Application of neural network predictive control to dissolved oxygen control in sewage treatment process[J]. Journal of Huaqiao University: Natural Science, 2015, 36(3):280 - 285. (in Chinese)
- 17 朱成云, 刘星桥, 李慧, 等. 工厂化水产养殖溶解氧预测模型优化[J]. 农业机械学报, 2016, 47(1):273 - 278. ZHU Chengyun, LIU Xingqiao, LI Hui, et al. Optimization of prediction model of dissolved oxygen in industrial aquaculture[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(1):273 - 278. (in Chinese)
- 18 薛定宇, 陈阳泉. 控制数学问题的 MATLAB 求解[M]. 北京:清华大学出版社, 2007.
- 19 李国勇, 杨丽娟. 神经·模糊·预测控制及其 MATLAB 实现[M]. 3版. 北京:电子工业出版社, 2013.
- 20 赵弘, 周瑞祥, 林廷圻. 基于 Levenberg - Marquardt 算法的神经网络监督控制[J]. 西安交通大学学报, 2002, 36(5):523 - 527. ZHAO Hong, ZHOU Ruixiang, LIN Tingqi. Neural network supervised control based on Levenberg - Marquardt algorithm[J]. Journal of Xi'an Jiaotong University, 2002, 36(5):523 - 527. (in Chinese)
- 21 CHUNG-FENG Jeffrey Kuo, TSAI Wei Lun, SU Te-Li, et al. Application of an LM neural network for establishing a prediction system of quality characteristics for the LGP manufactured by CO₂ laser[J]. Optics & Laser Technology, 2011, 43(3):529 - 536.
- 22 张海辉, 陶彦蓉, 胡瑾. 融合叶绿素含量的黄瓜幼苗光合速率预测模型[J]. 农业机械学报, 2015, 46(8):259 - 263, 307. ZHANG Haihui, TAO Yanrong, HU Jin. Photosynthetic rate prediction model of cucumber seedlings fused chlorophyll content[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(8):259 - 263, 307. (in Chinese)
- 23 韩敏, 穆大芸. 回声状态网络 LM 算法及混沌时间序列预测[J]. 控制与决策, 2011, 26(10):1469 - 1478. HAN Min, MU Dayun. LM algorithm in echo state network for chaotic time series prediction[J]. Control and Decision, 2011, 26(10):1469 - 1478. (in Chinese)
- 24 吕学勤, 段利伟, 姜英杰. 基于自适应预测控制的 PEMFC 动态特性研究[J]. 农业机械学报, 2015, 46(5):350 - 356. LÜ Xueqin, DUAN Liwei, JIANG Yingjie. Dynamic behaviors of PEMFC based on adaptive prediction control[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(5):350 - 356. (in Chinese)
- 25 NEHA Sharma, KAILASH Singh. Model predictive control and neural network predictive control of TAME reactive[J]. Chemical Engineering and Processing: Process Intensification, 2012, 59:9 - 21.