

一种通用学习网络自适应算法及其在预测控制中的应用

韩 敏, 韩 冰

(大连理工大学 电子与信息工程学院 自动化系, 辽宁 大连 116023)

摘要: 针对黑箱过程的辨识与控制, 本文提出了一种选择通用学习网络(universal learning network, ULN)节点间延迟时间参数的自适应算法, 并将其应用于对控制对象中的纯滞后参数的辨识. 将通用学习网络与PID控制器相结合, 应用于包含大滞后的系统的模型预测控制(model predictive control, MPC)中. 仿真结果证明通用学习网络能够有效地辨识被控对象的纯滞后时间, 并能够作为预估器应用于模型预测控制系统中.

关键词: 系统辨识; 通用学习网络; 大滞后; 预测控制

中图分类号: TP13 **文献标识码:** A

Adaptive algorithm of universal learning network and its application to predictive control

HAN Min, HAN Bing

(School of Electronic and Information Engineering, Dalian University of Technology, Dalian Liaoning 116023, China)

Abstract: An adaptive algorithm of universal learning network (ULN) is presented for time-delay parameter setting in this paper. Firstly, the ULN with PID controller is used in model predictive control (MPC) for stabilizing a class of nonlinear systems with long time-delay. Its application in identifying pure time-delay of the black box plant is then studied. Finally, simulation results show that the adaptive algorithm of the ULN model can identify the time-delay of the object model and be used as a predictor in predictive control system.

Key words: system identification; universal learning network; long time delay; predictive control

1 引言(Introduction)

由于工业过程中存在滞后时间, 当前的控制信号需要经过较长的时间才能反映出来, 如果是非线性系统, 使用传统的PID控制器很难加以控制. 解决滞后控制问题的关键是消除滞后对系统的影响, 加快系统的反应速度, 因此预测控制成为控制滞后对象的有效方法之一. 传统的Smith预估器控制需要建立被控对象的精确数学模型, 这就限制了Smith预估器在工程领域中的应用^[1]. 现有针对大滞后对象的控制方法通常都是建立在对被控模型已知或部分已知基础上的, 其中对象的纯滞后时间是控制器设计过程中的重要参数. 陆燕等人^[2]利用BP神经网络建模过程中, 利用不同输入样本区间对网络学习误差所产生的影响辨识得到对象中包含的延迟时间. 但该方法在应用过程中网络结构选取对辨识结果影响很大, 得到的结果不稳定. Balestrino等人^[3]利用神经元辨识对象的延迟时间, 但该方法只是针对线性系

统的方法. 神经网络的应用为辨识滞后对象的延迟时间提供了新的思路.

静态神经网络已经应用到了系统辨识和控制等领域, 但静态神经网络只能做无记忆的模拟, 对动态延迟系统往往不能取得令人满意的结果. 因此动态神经网络^[4,5]引起了众多学者的广泛关注. 这些网络克服了传统静态神经网络的缺陷, 为系统辨识、预测和控制提供了新的途径.

通用学习网络^[6]是一种具有一般结构的动态递归神经网络. 网络的所有节点相互连接, 包括内部连接和外部连接; 节点间有多重分支; 分支上可以设置任意的延迟时间. 网络节点间的反馈和分支上的延迟时间设置使通用学习网络能够用一个简单的结构来充分体现辨识对象的动态特性和非线性特性. 此外, 通用学习网络的分支上具有任意设置的延迟时间, 可以通过改变网络训练后的输出延迟, 将网络作为预估器应用于大滞后系统的控制中.

本文根据通用学习网络对大滞后对象辨识过程中的特点, 提出了自适应选择网络分支上延迟时间的改进训练算法, 并与单神经元控制器相结合设计了模型预估控制系统. 对典型的非线性大滞后过程pH中和过程^[7], 进行了控制仿真. 仿真结果证明, 改进的自适应算法能够合理的选择网络的参数, 并能有效地辨识被控制对象的纯滞后时间. 所设计的模型预估控制系统能够对pH中和过程进行有效的辨识和控制, 是对未知对象模型的大滞后系统控制的有效方法.

2 通用学习网络的基本结构及其算法(Basic structure and algorithm of universal learning network)

通用学习网络的结构与以往神经网络相比, 具有显著的特点, 其结构如图1所示. 网络由多个节点以及节点之间带有延迟的分支组成.

在图1中, i, j, k 表示网络节点. 由图1可以看出该网络结构上的特点: 1) 网络的所有节点都是互连的; 2) 每两个节点之间可以具有多重分支; 3) 每个分支上具有任意的延迟时间, 使网络的时序特点更加明显, 即网络当前时刻的输出不仅取决于当前时刻网络的输入, 还与前几个时刻网络各节点的输出有关.




图1 通用学习网络的基本结构

Fig. 1 Basic structure of universal learning network

通用学习网络的一般方程式如下:

$$\begin{aligned} h_j(t) = f_j(\{h_i(t - D_{ij}(p)) \mid i \in JF(j), \\ p \in B(i, j)\}, \{\lambda_m(t) \mid m \in M(j)\}, \\ \{r_n(t) \in N(j)\})(t \in T). \end{aligned} \quad (1)$$

其中: $h_j(t)$ 表示节点 j 在 t 时刻的输出, $f_j(\cdot)$ 是节点 j 的非线性函数; $D_{ij}(p)$ 是节点 i 到节点 j 的分支连接中, 第 p 条分支上的延迟时间; $JF(j)$ 表示输出与节点 j 相连的节点的集合, $B(i, j)$ 表示从节点 i 到节点 j 的分支的集合, $\lambda_m(t)$ 表示网络第 m 个参数在 t 时刻的数值, $m \in M(j)$, $M(j)$ 表示可变参数的下标集合, $r_n(t)$ 代表 t 时刻的第 n 个外部输入, $N(j)$ 表示节点的集合, $t \in T$, T 是采样时间.

通用学习网络通过 $\frac{\partial^+ E}{\partial \lambda_m(t)}$ 的反向传播来调整

参数 $\lambda_m(t)$ 进行训练:

$$\lambda_m(t) \leftarrow \lambda_m(t) - \gamma \frac{\partial^+ E}{\partial \lambda_m(t)}. \quad (2)$$

其中 γ 是网络的学习速率, 为一个小的常数.

$\frac{\partial^+ E}{\partial \lambda_m(t)}$ 是 E 对 $\lambda_m(t)$ 的时序偏微分^[8]. 指在其他变量固定的情况下, 一个变量变化而引起的评价函数的变化. 时序偏微分同时考虑了直接和间接的因果关系.

网络学习的评价函数 E 如公式(3)所示:

$$E = \frac{1}{T} \sum_{t=1}^T (h(t) - \hat{h}(t))^2. \quad (3)$$

其中: $h(t)$ 是教师信号的输出, $\hat{h}(t)$ 为网络模型的输出, T 是训练样本数.

3 通用学习网络的自适应选择延迟时间算法(Adaptive algorithm of universal learning network for time-delay setting)

3.1 自适应选择延迟时间算法(Adaptive algorithm for time-delay setting)

神经网络的学习应该在最短的时间内达到最佳的学习效果, 因此本文根据通用学习网络在对滞后对象辨识过程中的特点, 设计了通用学习网络的自适应选择延迟时间的算法, 使网络在学习调整网络权值的同时对网络的延迟参数进行自适应的选择调整, 达到选择适合网络学习的参数的目的. 自适应算法的流程图如图2所示.




图2 自适应选择延迟时间算法流程

Fig. 2 Flow chart of the adaptive algorithm

图2中: N 是网络的最大学习次数, N_c 是网络达到初步收敛所需要的学习次数, D 表示与输出节点相连的分支上的延迟时间, E_c 是网络延迟参数调整

的评价指标函数, K 是对参数调整后的训练次数, 用于对改变参数后对网络学习效果的考察. 因为通用学习网络的学习速率值较小, 训练过程中取学习100次为一个考察单位.

自适应算法对网络的延迟实行单步调整, 下降搜索的原则. 对与输出节点相连的分支上的延迟参数设定一个相对较大的初值, 当网络学习误差下降较慢, 达到初步收敛的时候($N = N_c$), 开始对网络分支上的延迟参数进行调整. 直到 E_c 满足方程(4)时, 停止对网络延迟参数的调整.

$$E_c(t) > E_c(t - K) \quad \text{或} \quad D = 1. \quad (4)$$

其中: $E_c(t) = aE_l(t) + bE_g(t)$, $E_l(t)$ 和 $E_g(t)$ 分别表示 t 时刻网络的学习误差和泛化误差, a , b 分别是权重系数. 网络的延迟时间选定后, 则按照常规的方法和固定的延迟时间参数继续训练网络. 所选定的与输出节点相连的分支上的延迟时间参数即辨识得到的对象的纯滞后时间.

3.2 辨识仿真实例(Simulation example)

为证明3.1节给出的自适应算法的有效性, 本节给出两个仿真实例. 通过仿真实例说明, 该方法不仅能够体现被辨识系统的动态特性, 而且能够准确的辨识出系统的纯滞后时间, 为滞后对象的预测控制提供了有力的工具.

3.2.1 仿真实例1(Example 1)

pH中和过程是常见的工业过程. 由于酸、碱物质中和具有非线性特性, 而调节阀、管道、中和池及传感器等因素使pH中和过程表现出动态特性, pH中和过程通常可以由方程(5)和(6)表示的动态Hammerstein模型^[9]来描述:

$$v(k) = u(k) - 1.207u^2(k) + 1.15u^3(k), \quad (5)$$

$$y(k) - 1.588y(k-1) + 0.597y(k-2) = 0.0185v(k-20) + 0.017v(k-21) + 0.597v(k-22). \quad (6)$$

其中: $u(k) = u_m(k)u_s$, $u_m(k)$ 是酸剂流量阀位电流, $y(k) = y_m(k) - y_s$, $y_m(k)$ 为中和液pH值. u_s 和 y_s 是 $u_m(k)$ 和 $y_m(k)$ 的基值, $u_s = 2.5 \text{ mA}$, $y_s = 5.7 \text{ pH}$, 系统采样时间为1 min.

从方程(5)和(6)中可以看出, 模型是一个滞后为20到22之间的一个非线性大滞后对象. 利用PID控制器作为控制器对上述系统进行控制, 得到对象的输入输出序列作为训练通用学习网络的教师信号. 教师信号如图3所示, 前900组信号用来训练网络, 后900组信号用来检验网络的泛化能力. 图中 t 为系

统采样时间, $y(k)$ 为输出, $u(k)$ 为输入.




图3 用于训练和检验网络泛化能力的教师信号

Fig. 3 Learning and text cure of the network

在网络分支上的延迟时间固定的情况下, 对与输出节点相连的分支上的延迟参数分别设为15至30之间的不同定值, 得到通用学习网络在不同延迟参数条件下的学习曲线, 如图4所示. 从中可以看出网络延迟时间参数对网络学习效率的影响, 与输出节点相连的分支上的延迟时间参数较大有利于网络的快速收敛, 而延迟时间参数与被辨识对象的延迟相接近, 能使网络获得最佳的学习效果. 利用3.1节所描述的算法对上述对象进行辨识, 仿真条件如表1所示. 与输出节点相连的分支上的延迟的初始值设为30, 其他节点间分支上的延迟时间分别设为1, 2, 3, 对应节点间的分支重数. 对于一般的二阶系统, 选取5个节点的多分支网络便能达到辨识精度要求, 对于结构复杂的对象可适当增加节点的数目. 因此本文仿真过程中选用了包含6个节点3重分支的通用学习网络. 图中: E 为误差, n 为训练次数.




图4 不同延迟设定值对应的学习误差曲线

Fig. 4 Learning curves with different time-delay value set

网络学习10000次后, 与输出节点相连的延迟时间值下降到23, 网络的学习误差为0.00611, 泛化误差为0.01144. 在相同的学习次数条件下, 网络收敛速度和达到的误差终值都优于固定延迟设定的常规方法. 网络的学习误差曲线如图5所示, 图6给出网

络的泛化信号同教师信号的对比. 可以看出, 辨识后的网络模型很好地体现了被辨识模型的动态特性. 图中: n 为训练次数, E 为误差, t 为系统采样时间, $y(k)$ 为输出.

表 1 实例1的仿真条件

Table 1 Simulation conditions of example one

节点数 N	6	节点幅值 A	5
分支数 B	3	考察范围 K	200
初始权值	$-0.1 \sim 0.1$	误差系数 a	0.8
学习率 γ	0.000001	误差系数 b	0.2
节点函数 $f(x) = A(\frac{1-e^{-x}}{1+e^{-x}})$ 初步收敛学习次数 N_c 2000			




图 5 自适应选择延迟时间算法的学习曲线

Fig. 5 Learning curve by the adaptive algorithm




图 6 泛化信号同教师信号的比较

Fig. 6 Comparison between generalizing signal and teacher signal

3.2.2 仿真实例2(Example 2)

利用文献[10]中给出的动态模型来检验自适应算法的有效性. 模型的差分方程如公式(7)所示:

$$y(k+1) = \frac{y(k) \cdot y(k-1) \cdot y(k-2) \cdot u(k-1) \cdot [y(k-2) - 1] + u(k-10)}{1 + y^2(k-1) + y^2(k-2)} \quad (7)$$

表 2 实例2的仿真条件

Table 2 Simulation Conditions of example two

节点数 N	6	节点幅值 A	3
分支数 B	3	考察范围 K	200
初始权值	$-0.1 \sim 0.1$	误差系数 a	0.8
学习率 γ	0.000005	误差系数 b	0.2
节点函数 $f(x) = A(\frac{1-e^{-x}}{1+e^{-x}})$ 初步收敛学习次数 N_c 2000			




图 7 自适应算法学习曲线

Fig. 7 Learning curve by the adaptive algorithm




图 8 泛化信号同教师信号的比较

Fig. 8 Comparison between generalizing signal and teacher signal

从模型的方程来看, 当前的输出由先前的输出和输入决定, 相对输入有10个单位的滞后. 训练采用的教师信号由1000组输入输出序列组成. 前750组用于训练网络, 后250组用来检验网络泛化能力. 输入 $u(k)$ 为

$$u(k) = \begin{cases} \sin(\pi k/25), & 0 \leq k < 250, \\ 1, & 250 \leq k < 500, \\ -1, & 500 \leq k < 750, \\ 0.3 \sin(\pi k/25) + 0.1 \sin(\pi k/32) + 0.6 \sin(\pi k/10), & 750 \leq k < 1000. \end{cases} \quad (8)$$

采用自适应选择延迟参数的学习算法对该模型进行辨识, 仿真条件如表2所示. 图7给出了利用自适应算法得到的网络学习误差曲线. 从图7中可以看出延迟时间调整对网络学习的影响, 网络延迟参数的调整加快了网络的收敛速度. 调整后, 与输出节点相连的分支上的延迟时间值为10, 与被辨识对象的滞后相同. 图8给出了网络的泛化信号同教师信号的对比曲线, 从图中可以看出网络输出能与教师信号很好地拟合, 体现了被辨识对象的特性. 图中: n 为训练次数, E 为误差, t 为系统采样时间, $y(k)$ 为输出.

在通用学习网络对包含滞后对象的建模过程中, 网络的学习效果对分支上的延迟时间参数设置十分敏感, 特别是与输出节点相连的分支上的延迟时间参数. 仿真的结果证明: 与输出节点相连的分支上的延迟时间参数较大有利于网络的快速收敛, 而延迟时间参数与被辨识对象的延迟相接近, 能使网络获得最佳的学习效果, 特别在对大滞后的对象辨识过程中更加明显. 通用学习网络自适应算法不仅能够使网络体现被辨识对象的特性, 同样能够辨识出对象的延迟时间. 在通用学习网络学习过程中调整网络的延迟参数, 并没有影响到网络的稳定性. 自适应学习方法为模型预估控制提供了良好的基础.

4 预估控制系统设计(Design of predictor control system)

在上一节中, 利用自适应选择延迟时间的算法辨识得到了系统的延迟时间. 本节将通用学习网络作为预估器应用于预估控制系统中. 通用学习网络作为预估控制器只需要将输出分支上的延迟时间设为1, 便得到相当于消除了滞后的对象模型. 这样通用学习网络可根据模型当前的输入提供消除滞后的模型输出, 起到了预估的作用.

利用通用学习网络预估器设计的控制系统结构如图9所示, 这是一个变结构的Smith预估控制系统.

在图9中: G_c 是控制器, G 是被控对象, G_m 是利用通用学习网络得到的被控对象等价模型, G_{m0} 是消除滞后的通用学习网络模型预估器. 控制结构中的两个反馈分别起到预估反馈和消除扰动作用. 本文采用常规PID控制, 设控制偏差为位置指令信号与系统的位置输出信号之差 $e(t) = r(t) - y'(t) - y_0(t)$, 则控制器的比例、微分、积分信号分别为

$$x_{c1} = e(t), \quad (9)$$

$$x_{c2} = e(t) - e(t-1), \quad (10)$$

$$x_{c3} = \sum_{k=0}^t e(t). \quad (11)$$

控制器的输出为

$$u(t) = \omega_p x_{c1} + \omega_d x_{c2} + \omega_i x_{c3}. \quad (12)$$

$\omega_p, \omega_d, \omega_i$ 为相应的权系数.




图9 通用学习网络模型预估控制结构

Fig. 9 Structure of universal learning network model predictive control

5 控制系统仿真(Simulation of control system)

pH中和过程控制问题是工业控制过程中的一个难题. 不同情况下, 溶液pH值相对于加药量的变化差别非常大, 具有明显的非线性. 在实际反应过程中由于还存在着混合、测量等时滞环节, 更加重了这一过程的复杂程度. 描述pH中和过程的Hammerstein模型由公式(5)(6)给出. 利用本文第4部分设计的控制结构, 对pH中和过程进行了仿真实验, 并与传统的Smith模型预估控制^[11]方法相对比, 得到系统的输出曲线如图10所示. 其中实线表示Smith预估控制方法的结果, 虚线表示本文采用的通用学习网络预估方法的控制结果.

由图10可以看出, 本文提出的基于通用学习网络预估器的控制方法能够有效控制系统, 对阶跃信号的跟踪性能与精确模型Smith预估器的性能相近, 同时通用学习网络建模是基于系统输入输出数据, 并不需要预知系统的数学模型, 克服了Smith预估器需要预知对象数学模型的缺点, 对未知对象模型的滞后控制提供了新的方法. 图中: t 为系统采样时间, $y(k)$ 为输出.




图10 控制系统的输出曲线

Fig. 10 Output curve of the control system

分别加入扰动 $d_1=0.5, d_2=0.1$, 采用通用学习网络预估控制方法和Smith预估控制方法对系统进行

控制, 对比扰动对系统响应的影响. 系统的输出响应在扰动作用下的输出曲线如图11、图12所示. 可以看出, 两种方法的抗扰动能力相近, 这是因为外界扰动同时加在对象和预估模型的输入上, 使二者的输出发生变化. 只要预估模型具有足够的精度, 在PID控制器作用下, 输出就能保持与研究对象的行为同步, 实现对抗扰动的抑制作用. 从3.2.1节的仿真结果可知, 通用学习网络模型的精度可以和精确模型相比拟, 其预估控制方法的抗扰动能力与精确预估模型相近, 证明了通用学习网络模型的有效性. 图中: t 为系统采样时间, $y(k)$ 为输出.




图 11 扰动 d_1 作用下的系统响应曲线

Fig. 11 System response curve with disturbance d_1




图 12 扰动 d_2 作用下的系统响应曲线

Fig. 12 System response curve with disturbance d_2




图 13 滞后变化时的系统响应曲线

Fig. 13 System response curve when delay-time has been changed

大滞后工业过程中, 滞后时间通常是处于不断的变化中, 从而导致预估模型和被控对象间产生差异, 引起控制误差. 为考察系统对滞后时间变化的抗扰能力, 令对象滞后由20变到25, 系统输出的曲线如图13所示. 实线为滞后突变为25时系统的输出曲线, 虚线对应滞后未发生变化时系统的输出. 可见系统对被控对象滞后变化有较强的鲁棒性.

6 结论(Conclusion)

本文根据通用学习网络在对滞后对象辨识过程中所反映出的特点, 设计了自适应选择延迟时间的训练算法. 自适应算法不仅能够体现被辨识对象的特性, 而且能够准确辨识对象中包含的纯滞后时间. 将辨识得到的模型作为预估器与传统的PID控制器相结合, 得到一种新的模型预估控制方法. 仿真结果证明, 该方法能够有效的应用于pH中和过程控制, 具有较好的抗扰动能力和鲁棒性. 尤其当对象的滞后发生变化时, 通用学习网络预估控制系统能及时补偿变化所带来的影响, 保持控制稳定性, 得到较好的控制效果.

参考文献(References):

- [1] 田杰, 陈杰. Elman网络在Smith预估控制中的应用[J]. 控制理论与应用, 2003, 20(4): 585 – 588.
(TIAN Jie, CHEN Jie. Application of Elman neural network in Smith predictive control[J]. *Control Theory & Applications*, 2003, 20(4): 585 – 588.)
- [2] 陆燕, 杜继宏, 李春文. 延迟时间未知的延迟系统神经网络补偿控制[J]. 清华大学学报(自然科学版), 1998, 38(9): 67 – 69.
(LU Yan, DU Jihong, LI Chunwen. Neural networks compensate control for unknown systems with time delay[J]. *J of Tsinghua University (science and Technology)*, 1998, 38(9): 67 – 69.)
- [3] BALESTRINO A, VERONA F B, LANDI A. On-line process estimation by ANNs and Smith controller design[J]. *IEEE Proceeding: Control Theory and Applications*, 1998, 145(2): 231 – 235.
- [4] NARENDRA K S, PARTHASARATHY K. Identification and control of dynamical systems using neural networks[J]. *IEEE Trans on Neural Networks*, 1990, 1(1): 4 – 27.
- [5] BECERRA V M, GARCES F R, NASUTO S J, et al. An efficient parameterization of dynamic neural networks for nonlinear system identification[J]. *IEEE Trans Neural Networks*, 2005, 16(4): 983 – 988.
- [6] 韩敏, 席剑辉, 平泽宏太郎. 带有开关控制的通用学习网络的参数和时间延迟的学习[J]. 控制理论与应用, 2003, 20(2): 205 – 210.
(HAN Min, XI Jianhui, HIRASAWA K. Training of parameters and time delays of universal learning network with switching mechanism[J]. *Control Theory & Applications*, 2003, 20(2): 205 – 210.)
- [7] NORQUAY S J, PALAZOGLU A, ROMAGNOLI J A. Application of wiener model predictive control (WMPC) to a pH neutralization experiment[J]. *IEEE Trans on Control Systems Technology*, 1999, 7(4): 437 – 445.
- [8] WERBOS P J. Backpropagation through time: what it dose and how to do it[J]. *Proceedings of the IEEE*, 1990, 78(10): 1550 – 1560.

- [9] 陈捷, 钱清泉, 王宁. 适用于非线性对象的神经元非模型控制方法[J]. 西南交通大学学报, 1998, 33(2): 188 – 191.
(CHEN Jie, QIAN Qingquan, WANG Ning. Neuron model free control of nonlinear processes[J]. *J of Southwest Jiao tong University*, 1998, 33(2): 188 – 191.)
- [10] PARIS A M, JOHN B T. A recurrent fuzzy-neural model for dynamic system identification[J]. *IEEE Trans on System, Man and Cybernetics. Part B: Cybernetics*, 2002, 32(2): 176 – 189.
- [11] 田杰, 龚至豪, 任雪梅. 纯滞后系统的单神经元Smith预测控制[J]. 计算机仿真, 2001, 18(1): 40 – 42.
(TIAN Jie, GONG Zhihao, REN Xuemei. Single neuron with Smith predictor control of the dead-time systems[J]. *Computer Simulation*, 2001, 18(1): 40 – 42.)

作者简介:

韩 敏 (1959—), 女, 工学博士, 教授, 博士生导师, 从事神经网络、混沌系统、3S系统等研究, E-mail: minhan@dlut.edu.cn;

韩 冰 (1981—), 男, 博士研究生, 从事神经网络及预测控制研究.

(上接第899页)

参考文献(References):

- [1] 李希, 谢刚, 华卫琦. PTA技术国产化中的主要化学工程问题及其研究思路[J]. 聚酯工业, 2001, 40(1): 1 – 7.
(LI Xi, XIE Gang, HUA Weiqi. Key problems and research program for PTA process domestic development[J]. *Polyester Industry*, 2001, 40(1): 1 – 7.)
- [2] LINDAHL H A, ABRAMS K J, STARK L E, et al. Method and apparatus for controlling the manufacture of terephthalic acid to control the level and variability of the contaminant content and the optical density: US, 4835307[P]. 1989.
- [3] CAP G, SERVIDA A, PISU M, et al. Kinetics of p-Xylene liqui-phase catalytic oxidation[J]. *AIChE J*, 1994, 40(6): 1156 – 1166.
- [4] LIU Ruilan, SU Hongye, MU Shengjing, et al. Fuzzy neural network model of 4-CBA concentration for industrial PTA oxidation process[J]. *Chinese J of Chemical Engineering*, 2004, 12(2): 234 – 239.
- [5] 陈渭泉, 刘瑞兰, 苏宏业, 等. 基于贝叶斯方法的4-CBA含量的软测量研究[J]. 化工自动化及仪表, 2003, 30(5): 49 – 51.
(CHEN Weiquan, LIU Ruilan, SU Hongye, et al. The research on soft sensor of the concentration of 4-CBA based on bayesian approach[J]. *Control and Instruments in Chemical Industry*, 2003, 30(5): 49 – 51.)
- [6] 王丽军. PX氧化动力学研究及氧化反应器模拟[D]. 杭州: 浙江大学, 2001.
(WANG Lijun. *Studies on the kinetics of p-Xylene oxidation and the reactor simulation*[D]. Hangzhou: Zhejiang University, 2001.)
- [7] 牟盛静. 石化工业过程建模与优化若干问题研究[D]. 杭州: 浙江大学, 2004.
(MU Shengjing. *The studies of process modeling and optimization in petrochemical industry*[D]. Hangzhou: Zhejiang University, 2004.)
- [8] VAPNIK V. *The Nature of Statistical Learning Theory*[M]. New York: Springer, 1995.
- [9] VAPNIK V. *Statistical Learning Theory*[M]. New York: Springer, 1998.
- [10] CORTES C, VAPNIK V. Support vector networks[J]. *Machine Learning*, 1995, 20(4): 273 – 297.
- [11] GUYON I, WESTON J, BARNHILL S, et al. Gene selection for cancer classification using support vector machines[J]. *Machine Learning*, 2002, 46(6): 389 – 422.
- [12] KENNEDY J, EBERHART R C. Particle swarm optimization[C]// *Proc of IEEE Int Conf on Neural Networks*. Piscataway, NJ: IEEE Press, 1995: 1942 – 1948.
- [13] PARSOPOULOS K E, VRAHATIS M N. Recent approach to global optimization problems through particle swarm optimization[J]. *Natural Computing*, 2002, 1(2/3): 235 – 306.

作者简介:

刘瑞兰 (1972—), 女, 博士, 研究方向为工业建模与先进控制、智能软测量等, E-mail: ruilanl@sina.com;

牟盛静 (1977—), 男, 博士, 研究方向为石化工业、环境工程建模、先进控制与优化等;

苏宏业 (1969—), 男, 教授, 博士生导师, 研究方向为时滞系统控制理论、鲁棒控制、先进过程建模与控制等;

褚 健 (1963—), 男, 教授, 博士生导师, 研究方向为现代控制理论、现场总线控制系统等.