

研究论文

一类化工过程多变量系统的自适应 非线性预测控制

杨剑锋^{1,2}, 赵 均¹, 钱积新¹, 牛 健¹

¹ 浙江大学工业控制技术国家重点实验室, 工业控制研究所, 浙江 杭州 310027;

² 兰州交通大学自动化与电气工程学院, 甘肃 兰州 730070

摘要: 针对化工过程的一类多变量非线性系统, 提出了一种自适应非线性预测控制 (ANMPC) 算法。在采用递归最小二乘法进行预测模型参数在线辨识的基础上, 将系统的静态非线性关系用一个反向传播 (BP) 神经网络稳态模型来表示, 通过稳态模型求得的动态增益来进一步校正预测模型的参数。详述了 ANMPC 控制器设计步骤, 通过在一个多变量 pH 中和过程中的仿真验证了本算法的可行性和有效性。

关键词: 自适应控制; 非线性预测控制; 递归最小二乘法; pH 中和过程

中图分类号: TP 273

文献标识码: A

文章编号: 0438-1157 (2008) 04-0934-07

Adaptive nonlinear model predictive control for a class of multivariable chemical processes

YANG Jianfeng^{1,2}, ZHAO Jun¹, QIAN Jixin¹, NIU Jian¹

¹ State Key Laboratory of Industrial Control Technology, Institute of Industrial Process Control, Zhejiang University, Hangzhou 310027, Zhejiang, China; ² School of Automation and Electrical

Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: An adaptive nonlinear model predictive control (ANMPC) algorithm was proposed for a class of multivariable nonlinear systems in chemical processes. By on-line identifying the parameters of the predictive model with recursive least-squares algorithm, a BP (back propagation) neural network steady-state model was developed to represent the static nonlinearity of the systems, and the parameters of the ARX predictive model were also modulated according to the dynamic gain calculated from the steady-state model. The design procedure of ANMPC controller was elaborated. The simulation results in a multivariable pH neutralization process demonstrated the feasibility and effectiveness of the ANMPC.

Key words: adaptive control; nonlinear model predictive control; recursive least-squares algorithm; pH neutralization process

引 言

模型预测控制 (MPC) 是直接在工业现场产生的一种基于模型的计算机优化控制算法, 它是目前过程控制应用最成功, 也最具有前途的先进控制策略^[1]。线性 MPC 技术虽然已得到了很好的发展

和大量应用^[2-3], 但对于化工过程中普遍存在的具有强非线性特性的系统, 当过程受到较大干扰或设定值发生较大变化时, 基于线性模型的控制往往不能产生满意的效果。

现有的非线性预测控制 (NMPC) 算法按其预测模型的不同, 可分为 3 类。(1) 线性化方法: 在

2007-06-24 收到初稿, 2007-09-11 收到修改稿。

联系人: 钱积新。第一作者: 杨剑锋 (1980—), 男, 博士研究生。

基金项目: 国家自然科学基金项目 (60504004); 国家重点基础研究发展计划项目 (2002CB312200); 国家高技术研究发展计划重点项目 (2007AA041402)。

Received date: 2007-06-24.

Corresponding author: Prof. QIAN Jixin. E-mail: jxqian@iipc.zju.edu.cn

Foundation item: supported by the National Natural Science Foundation of China (60504004), the National Basic Research Program of China (2002CB312200) and the High-tech Research and Development Program of China (2007AA041402).

工作点附近进行 Taylor 展开、反馈线性化^[3-4]，以及多模型方法^[5-6]；(2) 基于特殊模型的 NMPC：如 Wiener 模型、Hammerstein 模型、NARX 模型等^[3]；(3) 基于神经网络、模糊模型以及组合模型的 NMPC^[1,3,7]。上述算法要求受控对象的机理模型已知，或者模型的参数在整个工作时域内保持不变或变化很小。然而，工业控制中模型的不确定性、时变性，以及外界干扰等因素的影响是不可避免的，这使得模型的在线修正成为必需。已有文献中的非线性自适应预测控制算法多是采用在不同工作点对模型进行线性化^[4,8]或者针对非线性离散系统^[9]展开讨论，且其控制对象多是单输入单输出系统。为此，本文针对化工过程中常见的多变量非线性连续系统，提出了一种自适应非线性预测控制 (ANMPC, adaptive NMPC) 算法，详述了模型的在线辨识策略及控制器设计步骤，通过在一个 pH 中和过程中设定值跟踪效果、抗干扰能力、模型失配时的设定值跟踪效果三方面的仿真验证了本算法的有效性。

1 模型参数的在线辨识

在系统初始条件下，对装置施加伪随机二进制信号进行测试，用最小二乘法^[10]可辨识出如下二阶具有外界输入的自回归 (auto-regressive with external input, ARX) 模型来描述被控对象的动态变化关系

$$\mathbf{y}(k) = \sum_{i=1}^2 [-\mathbf{A}_i \mathbf{y}(k-i) + \mathbf{B}_i \mathbf{u}(k-i)] \quad (1)$$

式中 $\mathbf{y}(k) = [y_1(k) y_2(k) \cdots y_n(k)]^T$ 是系统输出， $\mathbf{u}(k) = [u_1(k) u_2(k) \cdots u_m(k)]^T$ 是系统输入， m, n 是输入、输出变量个数， $\mathbf{A}_i \in R^{n \times n}$ ， $\mathbf{B}_i \in R^{n \times m}$ 。

当被控对象的参数慢时变，或系统工作点发生变化后模型参数发生改变时，可用递归最小二乘法 (recursive least-squares algorithm, RLS)^[11] 对上述 ARX 模型的参数进行在线辨识。取

$$\boldsymbol{\theta}(k) = [\mathbf{A}_1 \quad \mathbf{A}_2 \quad \mathbf{B}_1 \quad \mathbf{B}_2] \quad (2)$$

$$\boldsymbol{\phi}(k) = [-\mathbf{y}^T(k-1) \quad -\mathbf{y}^T(k-2) \quad \mathbf{u}^T(k-1) \quad \mathbf{u}^T(k-2)] \quad (3)$$

式中 $\boldsymbol{\theta}(k) \in R^{n \times 2(n+m)}$ ， $\boldsymbol{\phi}(k) \in R^{1 \times 2(n+m)}$ 。则模型参数 $\boldsymbol{\theta}$ 可按下式进行更新

$$\boldsymbol{\theta}(k) = \boldsymbol{\theta}(k-1) + [\mathbf{y}(k) - \boldsymbol{\theta}(k-1)\boldsymbol{\phi}^T(k)]\mathbf{L}(k) \quad (4)$$

$$\mathbf{L}(k) = \frac{\boldsymbol{\phi}(k)\mathbf{P}(k-1)}{\rho + \boldsymbol{\phi}(k)\mathbf{P}(k-1)\boldsymbol{\phi}^T(k)} \quad (5)$$

$$\mathbf{P}(k) = \frac{1}{\rho} \mathbf{P}(k-1) [\mathbf{I} - \boldsymbol{\phi}^T(k)\mathbf{L}(k)] \quad (6)$$

式中 $0 < \rho \leq 1$ 是遗忘因子； $\mathbf{L}(k)$ 是权因子； $\mathbf{P}(k)$ 是正定的协方差阵， $\mathbf{P}(0) = \alpha \mathbf{I}$ ， \mathbf{I} 是单位矩阵，对于具有高信噪比的系统 α 常取一个较小的值，对于具有低信噪比的系统 α 常取一个足够大的正数^[11]。

由于 RLS 算法能及时反映系统输入、输出的最新变化，在系统趋于稳定时 RLS 算法可提高模型精度和实际控制效果。但是，对非线性系统来说，在输出设定值发生较大变化后的一段时间内，RLS 算法辨识的模型参数误差较大，控制器将会体现较慢的跟踪特性；当系统受到外界干扰偏离平衡状态时，控制器将会先跟踪干扰的影响实施控制，然后再向期望控制目标实施控制。

为了克服上述两个缺点，ANMPC 通过自适应指数来判别系统实际输出值接近设定值到何种程度时，RLS 算法才起作用，且定义自适应指数 ξ 是一个正的常数，主要用来在 ANMPC 中约束 RLS 算法的作用时间，当且仅当在线计算得到的 ξ 值小于用户给出的设定值时，ANMPC 的在线优化才包含 RLS 算法。 ξ 值按式 (7) 计算

$$\xi = \max \left\{ \left| \frac{y_1(k) - y_{1,sp}(k)}{y_{1,sp}(k)} \right|, \dots, \left| \frac{y_n(k) - y_{n,sp}(k)}{y_{n,sp}(k)} \right| \right\} \quad (7)$$

式中 $|\cdot|$ 表示取绝对值， $\max\{\cdot\}$ 表示取最大值， $\mathbf{y}_{sp} = [y_{1,sp} \quad y_{2,sp} \quad \cdots \quad y_{n,sp}]^T$ 是输出设定值，若 $y_{j,sp} = 0$ 则不计算第 j 个输出的 ξ 值。

当通过 PRBS 测试得到的 ARX 模型 (1) 中的参数 \mathbf{A} 、 \mathbf{B} 存在一定程度的误差或受到干扰时，对初始时刻的控制精度有较大影响；当 RLS 算法切入进行模型参数在线辨识后，噪声对控制效果的影响将逐渐减小。

2 ANMPC 控制器设计

2.1 预测模型

在过程工业中，有两类数据易于获得^[7]。(1) 历史数据：多数工业生产过程的输入输出数据都以一定的时间间隔保存到数据库中，而且，多数公司还保存有几年内的历史数据。(2) 测试数据：反映过程动态特性的开环测试数据可通过测试获得，从而可根据系统的稳态输入输出数据单独建立一个稳态模型来描述系统的静态非线性关系，用根据稳态模型求得的动态增益来进一步校正在线辨识得到的

ARX 模型的参数，以提高实际控制效果。

在每个输入变量的输入约束 $[u_{i,\min}, u_{i,\max}]$, ($i=1, 2, \dots, m$) 间取 N_i 个数据, 再分别从这 m 组数据中取一个数据组成一个 m 维的输入向量, 从历史数据或开环测试数据中获得其对应的稳态输出向量, 则可得到 N 组稳态输入输出样本数据

$$N = \prod_{i=1}^m N_i \quad (8)$$

去除不满足输出约束 $[y_{j,\min}, y_{j,\max}]$, ($j=1, 2, \dots, n$) 的样本数据, 用反向传播 (BP, back propagation) 网络算法^[3] 训练神经网络, 可建立输入到输出的三层 BP 网络稳态模型

$$y_s = f_2 [W_{2,1} \cdot f_1 (W_{1,1} \cdot u_s + \theta_1) + \theta_2] \quad (9)$$

式中 $u_s = [u_{1,s} \ u_{2,s} \ \dots \ u_{m,s}]^T$ 、 $y_s = [y_{1,s} \ y_{2,s} \ \dots \ y_{n,s}]^T$ 分别是系统稳态输入、输出; f_1 、 f_2 、 $W_{1,1}$ 、 $W_{2,1}$ 、 θ_1 、 θ_2 分别是隐含层、输出层的传递函数、权值和阈值。

将稳态输出样本数据作为神经网络的输入, 稳态输入样本数据作为神经网络的输出, 进行新的训练, 可得输出到输入的 BP 网络稳态模型

$$u_s = f_2 [W_{2,1} \cdot f_1 (W_{1,1} \cdot y_s + \theta_1) + \theta_2] \quad (10)$$

式中各符号的意义与式 (9) 相同, 但权值矩阵 $W_{1,1}$ 、 $W_{2,1}$ 及神经元阈值向量 θ_1 、 θ_2 的取值与式 (9) 不同。

BP 网络稳态模型通过离线训练获得, 工程应用中可根据系统的实际运行数据每隔一段时间更新稳态输入、输出样本数据重新训练 BP 网络。

根据上述稳态模型可求得输入变量 $u_i(k)$ 对应于输出变量 y_j 的动态增益为

$$K^s [u_i(k)] = \frac{\partial y_j(k)}{\partial u_i(k)} = \frac{y_j(u_i + \Delta u_i) - y_j(u_i)}{\Delta u_i} \quad (11)$$

式中 $i=1, 2, \dots, m$; $j=1, 2, \dots, n$; $y_j(u_i + \Delta u_i)$ 、 $y_j(u_i)$ 根据式 (9) 计算; Δu_i 为一个足够小的正数。

预测时域 P 内的动态增益可用式 (12) 所示的当前时刻的实际输出值 $y(k)$ 所对应的动态增益和下一个输出设定值 $y_r(k+1)$ 所对应的动态增益的线性插值来表示

$$K_j [u_i(k+p)] = K_{ji}^c + \frac{(K_{ji}^n - K_{ji}^c) \cdot \Delta u_i(k+p)}{u_{si}(k+1) - u_{si}(k)} \quad (12)$$

式中 $u_s(k+1)$ 、 $u_s(k)$ 分别是依 BP 网络稳态模型 (10) 求得的 $y_r(k+1)$ 、 $y(k)$ 所对应的稳态输入向量; K^n 、 K^c 分别是 $u_s(k+1)$ 、 $u_s(k)$ 根据式

(11) 计算的动态增益矩阵; $\Delta u_i(k+p)$ 是第 i 个输入在 $k+p$ 时刻输入增量值, $p=0, 1, \dots, P-1$; K_{ji} 表示从第 i 个输入到第 j 个输出的动态增益。

ARX 模型 (1) 中的 A_1 、 A_2 表征系统的固有特性, 与系统稳定性有关, B_1 、 B_2 主要表征系统的稳态特性, 与系统的快速性有关。从而, 可在不影响系统稳定性, 保持 A_1 、 A_2 不变的情况下, 用根据稳态模型求得的动态增益来修正 B_1 、 B_2 , 以改善系统的稳态特性和快速性。ANMPC 的预测模型就可使用式 (13) 这一个包含二次平方项的 ARX 模型表示

$$y(k) = \sum_{i=1}^2 [-A_i \Delta y(k-i) + B_{1i} \Delta u(k-i)] + \sum_{i=1}^2 B_{2i} \Delta u^2(k-i) + y(k-1) \quad (13)$$

式中

$$\begin{aligned} B_{1i} &= (I + A_1 + A_2) \cdot [B'_i / (B'_1 + B'_2)] \cdot K^c \\ B_{2i} &= (I + A_1 + A_2) \cdot [B''_i / (B''_1 + B''_2)] \cdot K^c \\ B'_i &= (I + A_1 + A_2) \cdot [B_i / (B_1 + B_2)] \\ K^c &= (K^n - K^c) / [u_s(k+1) - u_s(k)] \end{aligned} \quad (14)$$

A_i 、 B_i 与式 (4) 中的取值相同, 其他符号的取值与式 (12) 相同, B_1/B_2 表示矩阵 B_1 和矩阵 B_2 中对应位置的元素相除, $B_1 \cdot B_2$ 表示矩阵 B_1 和矩阵 B_2 中对应位置的元素相乘, K/u_s 表示增益矩阵 K 中每一行的元素和向量 u_s 中对应位置的元素相除。 B'_i 是中间变量, 其作用是使得经式 (14) 计算后的预测模型 (13) 的动态增益与式 (12) 相一致。

2.2 在线优化

令

$$\begin{aligned} S(n) &= -A_1 S(n-1) - A_2 S(n-2) \\ T(n-1) &= S(n-1) B_{11} + S(n-2) B_{12} \\ H(n-1) &= S(n-1) B_{21} + S(n-2) B_{22} \end{aligned} \quad (15)$$

式中 $n=3, 4, \dots, P+1$, 各符号的取值与式 (13) 相同, 且 $S(1) = I$, $S(2) = -A_1$, $T(1) = B_{11}$, $H(1) = B_{21}$ 。

取预测时域为 P , 控制时域为 $M(M \leq P)$, 根据式 (13) 进行递推计算, 即可得多步输出的预测值矢量表示式

$$\begin{aligned} \hat{Y}(k) &= VG_{11} \Delta U(k) + VG_{12} \Delta U^2(k) + VG_{21} \Delta u(k-1) + \\ &VG_{22} \Delta u^2(k-1) + VF_1 \Delta y(k) + VF_2 \Delta y(k-1) + Wy(k) \end{aligned} \quad (16)$$

式中

$$\hat{\mathbf{Y}}(k) = [\hat{\mathbf{y}}(k+1|k) \quad \hat{\mathbf{y}}(k+2|k) \quad \cdots \quad \hat{\mathbf{y}}(k+P|k)]^T$$

$$\Delta \mathbf{U}(k) = [\Delta \mathbf{u}(k) \quad \Delta \mathbf{u}(k+1) \quad \cdots \quad \Delta \mathbf{u}(k+M-1)]^T$$

$$\Delta \mathbf{U}^2(k) = [\Delta \mathbf{u}^2(k) \quad \Delta \mathbf{u}^2(k+1) \quad \cdots \quad \Delta \mathbf{u}^2(k+M-1)]^T$$

$$\Delta \mathbf{u}(k-1) = [\Delta u_1(k-1) \quad \Delta u_2(k-1) \quad \cdots \quad \Delta u_m(k-1)]^T$$

$$\Delta \mathbf{u}^2(k-1) = [\Delta u_1^2(k-1) \quad \Delta u_2^2(k-1) \quad \cdots \quad \Delta u_m^2(k-1)]^T$$

$$\mathbf{V} = \begin{bmatrix} \mathbf{I} & & & & \\ \mathbf{I} & \mathbf{I} & & & \\ \vdots & \vdots & \ddots & & \\ \mathbf{I} & \mathbf{I} & \cdots & \mathbf{I} & \end{bmatrix}_{(n \times P) \times (n \times P)}, \quad \mathbf{W} = \begin{bmatrix} \mathbf{I} \\ \vdots \\ \mathbf{I} \end{bmatrix}_{(n \times P) \times n}$$

$$\mathbf{F}_1 = [S(2) \quad S(3) \quad \cdots \quad S(P+1)]^T$$

$$\mathbf{F}_2 = -[S(1) \quad S(2) \quad \cdots \quad S(P)]^T \cdot \mathbf{A}_2$$

$$\mathbf{G}_{11} = \begin{bmatrix} T(1) & & & & \\ T(2) & T(1) & & & \\ \vdots & \vdots & \ddots & & \\ T(M) & T(M-1) & \cdots & T(1) & \\ \vdots & \vdots & \vdots & \vdots & \\ T(P) & T(P-1) & \cdots & T(P-M+1) & \end{bmatrix}$$

$$\mathbf{G}_{12} = \begin{bmatrix} H(1) & & & & \\ H(2) & H(1) & & & \\ \vdots & \vdots & \ddots & & \\ H(M) & H(M-1) & \cdots & H(1) & \\ \vdots & \vdots & \vdots & \vdots & \\ H(P) & H(P-1) & \cdots & H(P-M+1) & \end{bmatrix}$$

$$\mathbf{G}_{21} = [S(1) \quad S(2) \quad \cdots \quad S(P)]^T \cdot \mathbf{B}_{12}$$

$$\mathbf{G}_{22} = [S(1) \quad S(2) \quad \cdots \quad S(P)]^T \cdot \mathbf{B}_{22}$$

取参考轨迹为

$$\mathbf{Y}_r(k) = [\mathbf{y}_r^T(k+1) \quad \mathbf{y}_r^T(k+2) \quad \cdots \quad \mathbf{y}_r^T(k+P)]^T \quad (17)$$

式中 $\mathbf{y}_r(k+j) = \mathbf{C}\mathbf{y}_r(k+j-1) + (\mathbf{I}-\mathbf{C})\mathbf{y}_{sp}$, $j = 1, 2, \dots, P$, $\mathbf{y}_r(k) = \mathbf{y}(k)$ 为当前时刻的测量输出, $\mathbf{C} = \text{diag}\{c, c^2, \dots, c^n\}$ ($0 \leq c \leq 1$) 为柔性系数阵。

引入如下性能指标及优化命题

$$\min J(k) = [\hat{\mathbf{Y}}(k) - \mathbf{Y}_r(k)]^T \mathbf{Q} [\hat{\mathbf{Y}}(k) - \mathbf{Y}_r(k)] + \Delta \mathbf{U}(k)^T \mathbf{R} \Delta \mathbf{U}(k)$$

$$\text{s. t. } \Delta \mathbf{u}_{\min} \leq \Delta \mathbf{u}(k+i) \leq \Delta \mathbf{u}_{\max}$$

$$\mathbf{u}_{\min} \leq \mathbf{u}(k+i) \leq \mathbf{u}_{\max} \quad (i = 0, 1, \dots, M-1)$$

$$\mathbf{y}_{\min} \leq \hat{\mathbf{y}}(k+j) \leq \mathbf{y}_{\max} \quad (j = 1, 2, \dots, P) \quad (18)$$

式中 $\mathbf{Q} = \mathbf{q}\mathbf{I}$, $\mathbf{R} = \mathbf{r}\mathbf{I}$ 分别是输出误差和控制增量的加权矩阵。

因预测模型 (13) 中包含二次平方项, 式 (18) 是一个非线性优化命题, 而序列二次优化算法 (sequential quadratic programming, SQP) 是目前最重要的求解强非线性规划问题的方法之一,

具有函数评价次数少、收敛速度快、可适用于具有不同结构的广泛的过程系统工程问题的特征, 所以, 联立式 (13) ~ 式 (18), 用 SQP 算法求得最优控制增量 $\Delta \mathbf{U}(k)$, 取第一组最优控制增量 $\Delta \mathbf{u}(k)$, 即得所需最优控制输入

$$\mathbf{u}(k) = \mathbf{u}(k-1) + \Delta \mathbf{u}(k) \quad (19)$$

ANMPC 算法基本原理如图 1 所示。

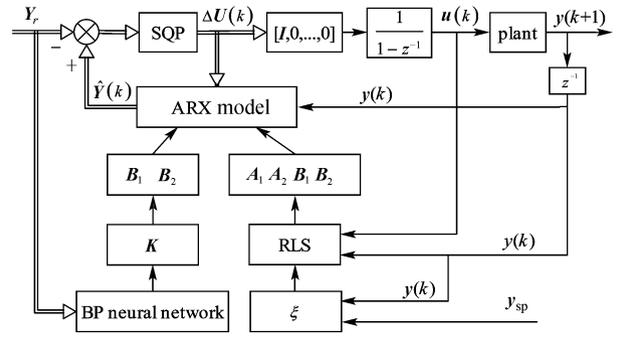


图 1 ANMPC 算法原理图

Fig. 1 Block diagram of ANMPC

3 仿真对比

pH 值的控制对许多工业过程来说有着重要意义, 已得到了大量研究并提出了很多控制算法^[1,3-4,6]。然而, 多数文献中只研究了 pH 值的控制, 是单输入单输出的控制算法, 多变量 pH 中和反应过程的控制将更为复杂和具有挑战性。多变量 pH 中和反应过程控制系统^[12]如图 2 所示, 图中 W_{a1} 、 W_{a2} 、 W_{a3} 、 W_{a4} 和 W_{b1} 、 W_{b2} 、 W_{b3} 、 W_{b4} 分别是酸流、缓冲流、碱流和输出流的电荷平衡因子和物料平衡因子。

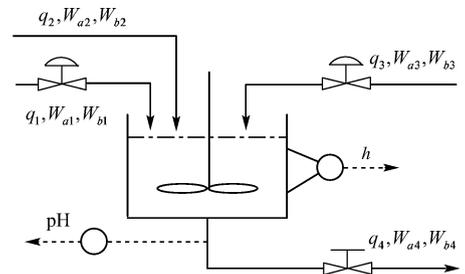


图 2 中和反应过程控制系统

Fig. 2 Control of neutralization system

控制目标是在缓冲流 q_2 流量发生波动时, 通过调节酸流 q_1 和碱流 q_3 来控制液面高度 h 和输出流的 pH 值。输入液流的浓度分别为: 酸流: $0.003 \text{ mol} \cdot \text{L}^{-1} \text{ HNO}_3$, 缓冲流: $0.03 \text{ mol} \cdot \text{L}^{-1}$

表 1 系统操作参数

Table 1 Operation parameters of system

A /cm ²	C_v /ml · cm ⁻¹ · s ⁻¹	q_1 /ml · s ⁻¹	q_2 /ml · s ⁻¹	q_3 /ml · s ⁻¹	W_{a1} /mol · L ⁻¹	W_{a2} /mol · L ⁻¹	W_{a3} /mol · L ⁻¹
207	8.75	16.6	0.55	15.6	3×10^{-3}	-3×10^{-2}	-3.05×10^{-3}
W_{b1} /mol · L ⁻¹	W_{b2} /mol · L ⁻¹	W_{b3} /mol · L ⁻¹	pK ₁	pK ₂	h /cm	pH	
0	3×10^{-2}	5×10^{-5}	6.35	10.25	14.0	7.0	

NaHCO₃, 碱流: 0.003 mol · L⁻¹ NaOH 和 0.00005 mol · L⁻¹ NaHCO₃。过程模型包括 3 个非线性常微分方程和 1 个非线性代数方程^[12]

$$\dot{h} = \frac{1}{A} (q_1 + q_2 + q_3 - C_v h^{0.5})$$

$$\dot{W}_{a1} = \frac{1}{Ah} [(W_{a1} - W_{a4})q_1 + (W_{a2} - W_{a4})q_2 + (W_{a3} - W_{a4})q_3]$$

$$\dot{W}_{b1} = \frac{1}{Ah} [(W_{b1} - W_{b4})q_1 + (W_{b2} - W_{b4})q_2 + (W_{b3} - W_{b4})q_3]$$

$$W_{a1} + 10^{pH-14} + W_{b1} \cdot \frac{1 + 2 \times 10^{pH-pK_2}}{1 + 10^{pK_1-pH} + 10^{pH-pK_2}} - 10^{-pH} = 0$$

该系统表现出强烈的非线性特性, 系统操作参数列于表 1。输入变量 $u_1 = q_1$ 、 $u_2 = q_3$ 的约束分别为 [14, 18]、[0, 30], 输出变量 $y_1 = h$ 、 $y_2 = \text{pH}$ 的约束分别为 [0, 20]、[0, 14], 系统初始工作参数为: $\mathbf{u}_0 = [16.6, 15.6]$, $\mathbf{x}_0 = [h, W_{a1}, W_{b1}] = [14, 0, 0]$, $\mathbf{y}_0 = [14, 7]$, 采样时间为 10 s。

u_1 、 u_2 分别在区间 [14, 15.5]、[15.5, 17]、[17, 18] 和 [0, 10]、[10, 20]、[20, 30] 内均匀地取 20、80、20 个值, 可获得 14400 组输入样本数据。解过程模型的微分方程组可得到 14400 组稳态输出样本数据。利用输出约束, 移除不合格样本数据后可得 13866 组有效样本数据, 用这些样本数据训练 BP 网络, 网络的隐含层节点数取为 15 个, 可得到输入到输出的 BP 稳态模型以及输出到输入的 BP 稳态模型。该过程的稳态非线性特性如图 3 所示。

广义预测控制 (generalized predictive control, GPC) 是实施自适应控制的一种极好选择, 得到了广泛应用^[13]。用文献 [13] 所述的不包含模型在线校正的多变量 GPC 算法不能将该 pH 中和过程控制到期望目标; 文献 [11] 将 RLS 算法与 GPC 算法相结合, 提出的递归广义预测控制 (RGPC) 算法在 3 个实际系统中的实验证明其具有极佳的控制能力和应用价值。因此, 本文与 RGPC 算法在

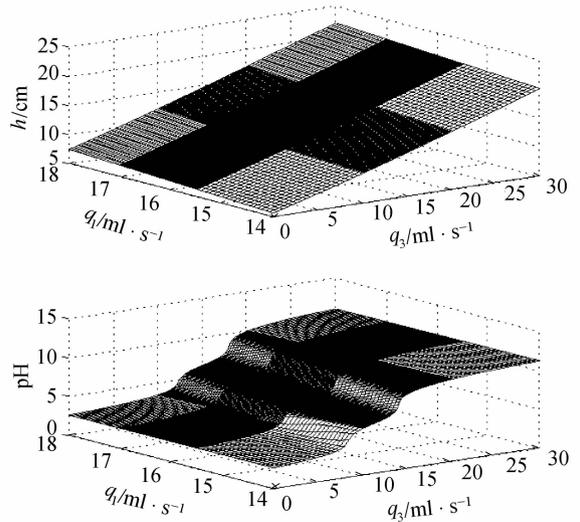


图 3 pH 中和过程稳态非线性特性
Fig. 3 Steady-state characteristics of pH neutralization process

设定值跟踪效果、抗干扰能力、模型失配时的设定值跟踪效果三方面进行了对比。

保持液面高度在 14 cm 不变, pH 值从初始值变化到 8。ANMPC 算法控制参数取为: $P = 5$, $M = 3$, $c = 0.5$, $q = 1$, $r = 1$, $\alpha = 100$, $\rho = 0.98$, $\xi = 0.13$, RGPC 算法的输出权矩阵中元素的取值为 10^4 , 其他参数和 ANMPC 算法相同, 两者的控制效果如图 4 所示。由图 4 可见, ANMPC 能抑制系统非线性特性以及液面高度和 pH 值的耦合关系的影响, 使液面高度保持不变的同时使 pH 值迅速上升到期望值, 且不会产生超调。

当缓冲流 q_2 受到干扰, 每隔 10 min 依次发生如下变化时: $0.55 \rightarrow 1.2 \rightarrow 2.0 \rightarrow 1.0 \rightarrow 0 \rightarrow 0.55$ ml · s⁻¹, ANMPC 算法和 RGPC 算法的控制效果如图 5 所示, 图 6 为相应的控制输入。图中 ANMPC 算法的控制参数为: $P = 5$, $M = 3$, $c = 0.5$, $q = 1$, $r = 0.08$, $\alpha = 100$, $\rho = 0.98$, $\xi = 0.01$ 。RGPC 算法的输出权矩阵中元素的取值为

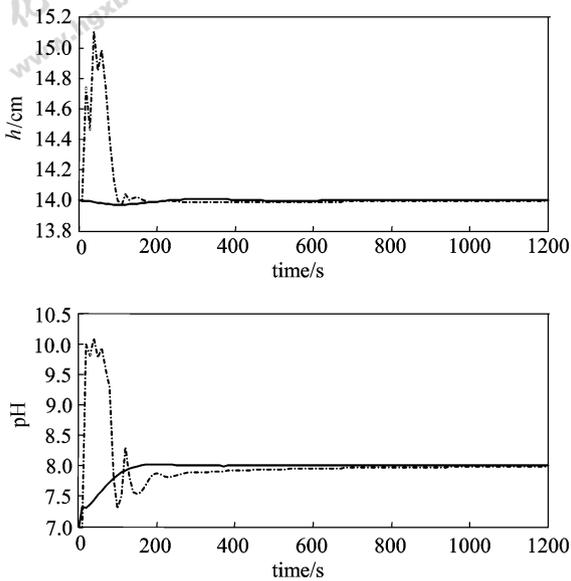


图 4 设定值阶跃变化时控制效果

Fig. 4 Response to a step change in pH set-point
----- RGPC; —— ANMPC

250000, 其他参数和 ANMPC 算法相同。由图 5 可见, ANMPC 算法虽然具有较多的波动但没有稳态误差, 而且其最大超调量小于 $(14 - 13.8) / 14 = 0.014$ 。由图 6 可见, RGPC 算法输入量的变化过于迅速, 且当输出权重矩阵取值变小时将产生更大的波动和稳态误差, 甚至不能实现控制。

当缓冲流 q_2 发生较大干扰时, 比如在初始时刻由其正常值 $0.55 \text{ ml} \cdot \text{s}^{-1}$ 变化为 $5.5 \text{ ml} \cdot \text{s}^{-1}$, 预测模型仍根据其正常值 $0.55 \text{ ml} \cdot \text{s}^{-1}$ 实施控制, 即模型存在失配时, ANMPC 算法和 RGPC 算法对液面高度变化的跟踪效果如图 7 所示, 图 8 为相应的控制输入。图中 ANMPC 算法的控制参数基本同上, 但 $q = 100$, $r = 0.001$ 。RGPC 算法的输出权重矩阵中元素的取值为 10^6 , 其他参数和 ANMPC 算法相同。由图 7 可见, 在初始时刻, ANMPC 算法比 RGPC 算法稳定得多, 且 RGPC 算法使液面高度接近设定值需要较长的时间。由图 8 可见, ANMPC 算法的控制输入变化较少, 且变化幅度也较小; 酸流 q_1 达到约束最大值, 这也正是液面高度产生稳态误差的原因。

4 结 论

本文提出了一种基于递归最小二乘法模型参数在线辨识策略的自适应非线性预测控制 (ANMPC) 算法。针对化工过程中常见的多变量

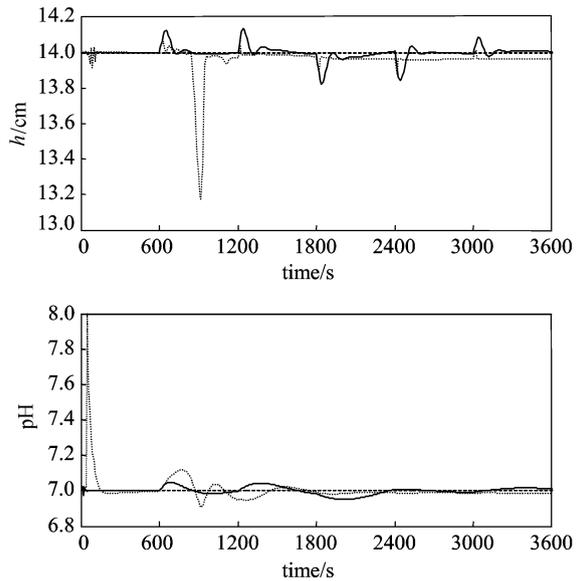


图 5 缓冲流受到干扰时 ANMPC 和 RGPC 控制效果
Fig. 5 Performance of ANMPC and RGPC for disturbance in q_2
----- RGPC; —— ANMPC; - - - - set-point

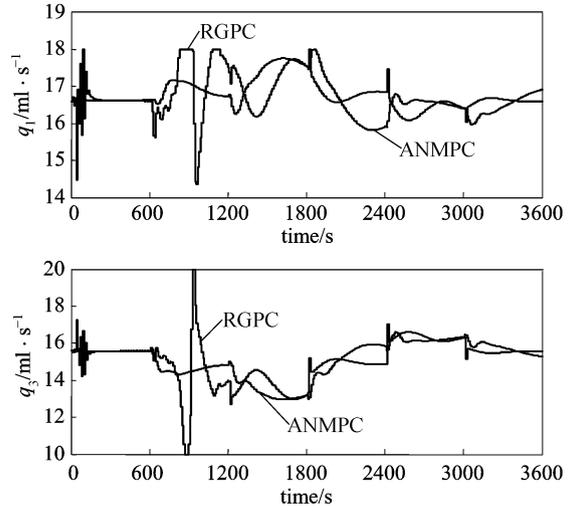


图 6 ANMPC 和 RGPC 控制输入

Fig. 6 Manipulated variables of ANMPC and RGPC

非线性连续系统, 将系统的稳态非线性关系用一个 BP 神经网络稳态模型来表示, 利用稳态模型求得的动态增益来进一步校正模型参数, 提高了 ANMPC 的响应速度。利用自适应指数来约束 RLS 算法的作用时间, 进一步提高了 ANMPC 算法的稳态品质和鲁棒性。

实际仿真结果表明该算法能迅速响应输出设定值的变化, 对不确定性干扰有较好的抵抗能力, 且在模型失配时也具有较好的设定值跟踪效果。

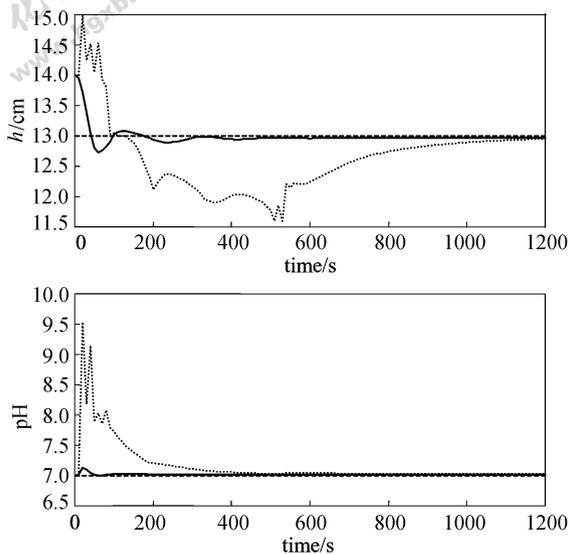


图 7 缓冲流发生变化模型产生失配时设定值跟踪效果

Fig. 7 Response to step change in pH set-point in presence of modeling error in buffer flow rate

----- RGPC; —— ANMPC; - - - - set-point

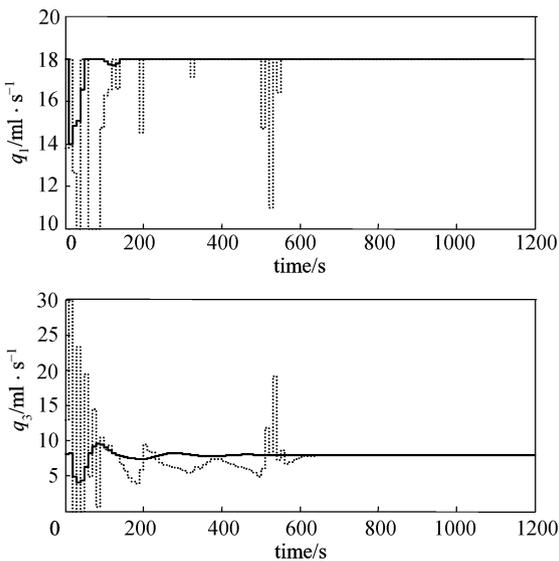


图 8 ANMPC 和 RGPC 控制输入

Fig. 8 Manipulated variables of ANMPC and RGPC

----- RGPC; —— ANMPC

References

[1] Wang Shuqing (王树青), et al. Industry Process Control Engineering (工业过程控制工程). Beijing: Chemical Industry Press, 2002: 197

[2] Qin S J, Badgwell T A. A survey of industrial model predictive control technology. *Control Engineering Practice*, 2003, **11**: 733-764

[3] Zhu Jing (诸静), et al. Intelligent Predictive Control and Its Application (智能预测控制及其应用). Hangzhou: Zhejiang University Press, 2000: 12

[4] Xu Feng (许锋), Zhang Yi (张艺), Luo Xionglin (罗雄麟), Ji Dewei (季德伟), Chen Yukun (陈育昆). Varying model based adaptive predictive control of highly nonlinear process in chemical process. *Control and Instruments in Chemical Industry* (化工自动化及仪表), 2004, **31** (6): 32-35

[5] Palma F Di, Magni L. A multi-model structure for model predictive control. *Annual Reviews in Control*, 2004, **28**: 47-52

[6] Li Ning (李柠), Li Shaoyuan (李少远), Xi Yugeng (席裕庚). Multiple model predictive control for MIMO systems. *Acta Automatica Sinica* (自动化学报), 2003, **29** (4): 517-523

[7] Piche S, Sayyar-Rodsari B, Johnson D, Gerules M. Nonlinear model predictive control using neural networks. *IEEE Control Systems Magazine*, 2000, **20** (3): 53-62

[8] Luo Xionglin, Zou Xin, Du Dianlin. Varying model based adaptive predictive control of highly nonlinear chemical process//Proceeding of 2005 International Conference on Control and Automation. Budapest, Hungary, 2005: 537-540

[9] Shi Yujing (石宇静), Chai Tianyou (柴天佑). Neural networks and multiple models based nonlinear adaptive generalized predictive control. *Acta Automatica Sinica* (自动化学报), 2007, **33** (5): 540-545

[10] Ljung L. System Identification: Theory for the User. 2nd ed. Beijing: Tsinghua University Press, 2002

[11] Moon S M, Clark R L, Cole D G. The recursive generalized predictive feedback control: theory and experiments. *Journal of Sound and Vibration*, 2005, **279**: 171-199

[12] Hu Q, Rangaiah G P. Adaptive internal model control of nonlinear processes. *Chemical Engineering Science*, 1999, **54**: 1205-1220

[13] Chow C M, Kuznetsov A G, Clark D W. Application of generalised predictive control to the paper machine benchmark. *Control Engineering Practice*, 1995, **3** (10): 1483-1486