

文章编号: 1000-8152(2001)02-0298-03

## 基于多层局部回归神经网络的多变量非线性系统预测控制

刘贺平 张兰玲 孙一康

(北京科技大学自动化系·北京, 100083)

**摘要:** 以罐式搅拌反应器为例, 针对复杂多变量系统的强耦合性、非线性、时变性等问题, 研究了多变量非线性系统的预测控制及改善控制性能的方法. 采用多层局部回归神经网络离线建立预测模型, 以偏差补偿和模型修正相结合的方式对预测模型进行误差补偿, 经在线校正用于预测控制. 通过对性能指标中的偏差项负指数加权, 进一步改善预测控制性能. 仿真结果表明了控制算法的有效性.

**关键词:** 多变量非线性系统; 多层局部回归神经网络; 预测控制; 模型修正

**文献标识码:** A

## Predictive Control of Multivariable Nonlinear System Based on Multilayer Local Recurrent Neural Networks

LIU Heping, ZHANG Lanling and SUN Yikang

(Department of Automation, Beijing University of Science and Technology·Beijing, 100083, P. R. China)

**Abstract:** Taking the stirred tank reactor for example, the predictive control of MIMO nonlinear system based on multilayer local recurrent neural networks is presented. Aiming at the difficulties in modeling the complex MIMO nonlinear system, the multilayer local recurrent neural network is used to build the predictive model of the process off-line. In feedback correction, considering the requirements of the accuracy and practicability, error compensation and model correction are adopted to correct the predictive model online for the predictive control. We draw the conclusion that negative exponential weighting of future tracking errors can improve the control performance of the control systems. The results of simulation show the effectiveness of the control algorithm.

**Key words:** multivariable nonlinear system; multilayer local recurrent neural networks; predictive control; model correction

### 1 引言(Introduction)

多输入-多输出复杂非线性系统的建模和预测控制一直是个难以解决的问题. 随着对神经网络的深入研究及其在系统建模方面的成功应用, 非线性系统的预测控制也取得了进展. 基于神经网络的一步预测控制<sup>[1]</sup>、多步预测控制<sup>[2]</sup>以及神经网络预测控制系统的稳定性<sup>[3]</sup>等问题也相继得到了研究.

本文研究用多层局部回归神经网络建立过程预测模型, 实现对多输入-多输出非线性系统的预测控制. 基于神经网络的预测模型, 推导出系统的预测控制算法. 在控制中采用离线建模和在线补偿, 修正的策略以增强控制系统的鲁棒性. 最后对罐式搅拌反应器进行了预测控制的仿真试验.

### 2 基于局部回归神经网络的预测控制算法 (Algorithm of the predictive control based on

### multilayer local recurrent neural network)

基于神经网络的预测控制与经典的预测控制类似, 同样具有预测模型、滚动优化、反馈校正三个基本特征, 但很重要的区别在于由神经网络预测模型取代了经典的数学预测模型, 因此可以适用于一般非线性系统.

在非线性系统建模中, 前馈神经网络是应用得最多的一种网络形式, 理论和算法方面取得了很多成果. 而前馈网络本质上是静态网络, 不能从根本上解决动态建模问题, 因此动态神经网络的应用受到了重视<sup>[4]</sup>. 为了兼顾动态特性和计算简化的要求, 我们采用了多层局部回归神经网络建立被控对象的预测模型. 这种网络在前馈网络的基础上, 在同层节点之间增加了自回归及交叉反馈连接, 既具有前馈网络的非线性映射能力, 又具有很强的动态特性, 且

结构和算法也不很复杂,因而非常适合于动态系统的建模<sup>[5]</sup>.局部回归网络的结构如图1所示.




图1 多层局部回归神经网络结构图

Fig. 1 Multilayer recurrent neural network

设  $Y_l = [y_l^1, y_l^2, \dots, y_l^{m_l}]^T$  为神经网络第  $l$  层的输出向量 ( $m_l$  为第  $l$  层的神经元数),  $X_l = [x_l^1, x_l^2, \dots, x_l^{r_l}]^T$  为第  $l$  层的综合输入向量, 则网络隐含层神经元的状态和输出方程为:

$$X_l(k) = W_{l-1,l} Y_{l-1}(k) + W_{l,l} Y_l(k-1) + b_l, \quad (1)$$

$$Y_l(k) = \phi(X_l(k)), \quad (2)$$

式中,  $W_{l-1,l}$  为神经网络  $l-1$  层到  $l$  层的连接权向量,  $W_{l,l}$  为  $l$  层的自回归连接权向量,  $b_l$  为  $l$  层神经元的阈值向量,  $\phi(\cdot)$  为神经元的输出函数, 这里取为  $\tanh$  函数. 为得到由网络参数和信息提供预测控制的算法, 对以下性能指标进行优化.

$$J = \frac{1}{2} \sum_{j=1}^{N_1} \alpha(j) [\bar{Y}_L(k+j) - Y_d(k+j)]^T [\bar{Y}_L(k+j) - Y_d(k+j)] + \frac{1}{2} \sum_{p=1}^{N_2} \beta(p) [\Delta U(k+p)]^T [\Delta U(k+p)], \quad (3)$$

其中,  $N_1, N_2$  分别为预测时域和控制优化时域,  $\alpha(j), \beta(j)$  分别为跟踪误差及控制加权因子,  $Y_d = [Y_d^1, Y_d^2, \dots, Y_d^r]^T, \bar{Y}_L = [\bar{Y}_L^1, \bar{Y}_L^2, \dots, \bar{Y}_L^r]^T$  分别为参考输入向量和神经网络的修正输出向量,  $\Delta U = [\Delta u_1, \Delta u_2, \dots, \Delta u_r]^T$  为控制增量向量.  $\bar{Y}_L$  定义如下:

$$\bar{Y}_L(k+j) = Y_L(k+j) + e(k), \quad j = 1, 2, \dots, N_1, \quad (4)$$

式中,  $Y_L$  为神经网络的预测输出向量,  $e$  为模型偏差补偿向量, 其定义将在后面的反馈校正中给出. 另外定义:

$$\begin{cases} \Delta U(k+p) = U(k+p) - U(k+p-1), \\ \quad \quad \quad 0 \leq p \leq N_2, \\ \Delta U(k+p) = 0, \quad \forall p > N_2. \end{cases} \quad (5)$$

对(3)式求关于  $U(k+i) (i = 0, \dots, N_2)$  的偏导数, 并引入复合量关系可得

$$\begin{aligned} \frac{\partial J}{\partial U(k+i)} = & \frac{1}{2} \cdot \sum_{p=0}^{N_2} \{ \beta(j) \cdot \frac{\partial \Delta U^T(k+p)}{\partial U(k+i)} \cdot \frac{\partial [\Delta U^T(k+p) \Delta U(k+p)]}{\partial \Delta U(k+p)} \} + \\ & \frac{1}{2} \cdot \sum_{j=i+1}^{N_1} \{ \alpha(j) \cdot \frac{\partial Y_L^T(k+j)}{\partial U(k+i)} \cdot \frac{\partial \{ [\bar{Y}_L(k+j) - Y_d(k+j)]^T [\cdot] \}}{\partial Y_L(k+j)} \}. \end{aligned} \quad (6)$$

将(4)、(5)式代入(6)式, 得:

$$\frac{\partial J}{\partial U(k+i)} = \Delta J_\Sigma(i) + \beta(i) \Delta U(k+i) - \beta(k+i+1) \Delta U(k+i+1), \quad (7)$$

式中

$$\Delta J_\Sigma(i) = \sum_{j=i+1}^{N_1} \{ \alpha(j) \frac{\partial Y_L^T(k+j)}{\partial U(k+i)} [Y_L(k+j) - e(k) - Y_d(k+j)] \}. \quad (8)$$

(8)式中的导数项可由(1)、(2)式得:

$$\begin{aligned} \frac{\partial Y_L^T(k+j)}{\partial U(k+i)} &= \left[ \frac{\partial Y_L(k+j)}{\partial U^T(k+i)} \right]^T = \\ & \left[ \frac{\partial Y_L(k+j)}{\partial X_L^T(k+j)} \cdot \frac{\partial X_L(k+j)}{\partial U^T(k+i)} \right]^T = \\ & \frac{\partial X_L^T(k+j)}{\partial U(k+i)} \cdot \text{diag}[\phi'(x_l^1(k+j)), \dots, \phi'(x_l^{r_l}(k+j))]^T. \end{aligned} \quad (9)$$

再由状态方程(1)可求得

$$\frac{\partial X_L^T(k+j)}{\partial U(k+i)} = \begin{cases} \frac{\partial Y_{l-1}^T(k+j)}{\partial U(k+i)} \cdot W_{l-1,l}, & (l \text{ 为输出层}) \\ \frac{\partial Y_l^T(k+j-1)}{\partial U(k+i)} \cdot W_{l,l} + \frac{\partial Y_{l-1}^T(k+j)}{\partial U(k+i)} \cdot W_{l-1,l}. \end{cases} \quad (10)$$

再利用一步预测神经网络模型递推  $Y_L(k+j)$  时, 所需的控制信号可采用

$$\hat{U}(k+j) = U(k) + \sum_{i=1}^j \Delta U(k+i),$$

其中  $\Delta U(k+i)$  由上一步优化结果提供. 预测  $Y_L(k+j)$  所需要的  $Y, U$  的历史信息在前面的迭代过程中, 通过网络的反馈结构, 已经蕴含、记忆在网络之中, 不必全部加在网络的输入端, 这是本文采用的动态网络的特点.

控制信号的调整量为

$$\Delta U(k+i) = -\eta \frac{\partial J}{\partial U(k+i)}, \quad (11)$$

将(7)式代入(11)式可解出

$$\begin{cases} \Delta U(k+i) = \frac{\eta}{1+\eta\beta(i)} [\beta(i+1) \cdot \\ \Delta U(k+i+1) - \Delta J_{\Sigma}(i)], \\ i = N_2, N_2 - 1, \dots, 0. \end{cases} \quad (12)$$

通过对(11)式的  $\eta$  采用自适应变步长梯度下降法修正  $\Delta U(k+i)$  可提高控制性能。 $U(k+i)$  的初始值可取绝对值较小的随机数。

反馈校正采用了模型修正与误差补偿相结合的形式,即:在控制的每一步,都实时检测被控对象实际输出与神经网络输出之间的误差,若此误差大于预先设定的允许误差,则修正神经网络预测模型,否则,利用该误差对神经网络预测输出进行误差补偿,以使网络预测更加准确。模型误差补偿方式有多种,本文采用如下形式:

$$e(k) = \rho \cdot e(k-1) + (1-\rho) \cdot e_L(k), \quad (13)$$

其中  $\rho$  为  $[0,1)$  的常数,  $e_L(k)$  为  $k$  时刻系统实际输出与网络输出的误差向量,即

$$e_L(k) = Y(k) - Y_L(k). \quad (14)$$





图2 预测控制仿真曲线

Fig. 2 Simulation result of predictive control

## 4 结论(Conclusion)

本文提出采用多层局部回归网络建立被控对象的预测模型,依据这种预测模型推导了滚动式多步优化的预测控制律。在反馈校正中,考虑到修正神经网络预测模型费时的特点,提出了模型修正与偏差补偿相结合的反馈校正策略,显著地提高了算法的实时性,可以有效地克服不确定性因素的影响。另外,通过对性能指标中的偏差项进行负指数加权,改善了系统的动态响应过程品质。仿真结果表明了本文提供的预测控制算法的有效性。

## 参考文献(References)

- [1] Li J, Xu X and Xi Y. A neural networks based predictive control [A]. Int. Conf. Industrial Electronics Control and Instrumentation [C], Kobe, Japan, 1991, 1405-1410
- [2] Yoon T W and Clarke D W. Adaptive predictive control of the benchmark plant [J]. Automatica, 1994, 30(4): 621-628
- [3] Eaton J W, Ravolings J B and Ungar L H. Stability of neural-net based model predictive control [A]. Proc. American Control Conf.

## 3 仿真结果(Simulation result)

罐式搅拌反应器是一个非线性系统,它的输入为进料量  $F_1$  和冷却率  $Q$  (可通过改变冷却套中冷却液的流量来调整),输出为流出物浓度  $C_A$  和反应器温度  $T$ 。每个输出都与各个输入之间有较强的耦合性。

模型辨识用的学习数据取自文献[6]提供的模型,采样周期取为 1.5min。学习算法按文献[5]步骤进行。多层局部回归网络的结构选为 4 层,各层的节点数分别是 4, 8, 6, 2, 迭代 12000 步后,网络输出获得令人满意的效果。

基于神经网络预测模型对反应器进行预测控制时,取控制时域  $N_2 = 2$ , 预测时域  $N_1 = 5$ 。  $T, C_A$  的初值分别为  $T_S = 546.7$  K,  $C_{AS} = 393.3$  mol/m<sup>3</sup>, 相应的  $Q, F_1$  的初值为  $Q_S = 1.055 \times 10^8$  J/h,  $F_{1S} = 1.133$  m<sup>3</sup>/h。

先将(3)式中的  $\alpha(j), \beta(j)$  设成与  $j$  无关的常数,经调节后,当  $\alpha(j) = 2.5, \beta(j) = 0.01$  时,控制效果比较好。其次,修正  $\alpha(j)$ , 将其设为  $j$  的负指数形式,即  $\alpha(j) = a^{b-j}$ , 经调节后,当  $\alpha(j) = 4^{(2-j)}, \beta(j) = 0.01$  时,与前者相比,可加速系统的动态响应过程,减少超调。仿真结果如图 2 所示。

[C], 1994, 2481-2485

- [4] Paris A G and Atiya A F. Application of the recurrent multilayer perceptron in modeling complex process dynamics [J]. IEEE Trans. Neural networks, 1994, 5(2): 255-266
- [5] Zhang Lanling, Liu Heping and Sun Yikang. A multilayer local recurrent neural network based predicting model for complex production process [J]. Pattern Recognition and Artificial Intelligence, 1998, 11(1): 75-81 (in Chinese)
- [6] Stephanopoulos G. Chemical Process Control—An Introduction to Theory and Practice [M]. Englewood Cliffs, New Jersey: Prentice-Hall Inc., 1984

## 本文作者简介

刘贺平 1951年生,1992年获名古屋工业大学博士学位,1995年完成北京科技大学博士后研究工作,现任北京科技大学教授,博士生导师。目前主要研究方向为:复杂系统的建模,自适应控制,预测控制,智能控制等。

张兰玲 女,1970年生,博士,工程师。现从事信息科学理论及计算机应用方面的研究。

孙一康 1932年生,博士生导师,国家教委科技组自动控制组成员。目前主要从事轧钢自动化理论研究和技术改造工作。