

非线性动态系统神经模糊建模与内模/PID 双重控制系统设计

刘士荣¹, 林卫星¹, 俞金寿², 杨先一³

(1. 宁波大学 电气工程与自动化研究所, 浙江 宁波 315211; 2. 华东理工大学 自动化研究所, 上海 200237;
3. 圭尔夫大学 工程系, 圭尔夫, 安大略 N1G 2W1, 加拿大)

摘要: 非线性动态系统的内模控制要求建立精确的对象正模型和逆模型, 这对于大多数实际对象是难以做到. 提出了一类神经模糊模型的非线性动态系统建模方法, 并在此基础上研究了基于神经模糊模型的非线性系统的内模控制设计. 基于输入输出数据辨识的对象正模型和逆模型存在着模型失配问题, 导致神经模糊内模控制范围变窄和控制鲁棒性降低, 为了改善系统的性能, 提出了神经模糊内模控制与 PID 控制结合的双重控制策略. 对 CSTR 的反应物浓度控制研究表明, 双重控制策略能有效地拓宽系统可控范围, 改善系统性能. 仿真结果证明该控制策略简单而有效.

关键词: 神经模糊系统; 内模控制; PID 控制; 化学反应器

中图分类号: TP15, TP273 **文献标识码:** A

Neurofuzzy modeling for nonlinear dynamic systems and double control system design with internal model control and PID control

LIU Shi-rong¹, LIN Wei-xing¹, YU Jin-shou², Simon X. YANG³

(1. Research Institute of Electrical Engineering and Automation, Ningbo University, Ningbo Zhejiang 315211, China;
2. Research Institute of Automation, East China University of Science and Technology, Shanghai 200237, China;
3. School of Engineering, University of Guelph, Guelph, Ontario N1G 2W1, Canada)

Abstract: In the internal model control design for nonlinear systems, the precise forward and inverse models of plant are required, but it is impossible in the majority of practical plants. A modeling technique based on a class of neurofuzzy models for nonlinear dynamic systems is proposed. The internal model control design based on neurofuzzy modeling is studied. Because there is the model mismatch problem between the identified forward and inverse models of the plant based on the input-output data of plant, it will make the system controllable range narrowed and the system robustness lessened in the control system based on neurofuzzy modeling. To improve the performance of the control system, the double control strategy with neurofuzzy modeling based internal model control and PID control is proposed. By the concentration control of the reacted mass in a continuous stirred tank reactor (CSTR), the double control strategy is able to effectively extend the system controllable range and improve the performance of the system. The simulation results show that the proposed control strategy is simple and effective.

Key words: neurofuzzy systems; internal model control; PID control; chemical reactor

1 引言 (Introduction)

由于复杂非线性系统建模和控制的需要, 神经网络和模糊逻辑系统已经受到工程和学术界的广泛重视. 借鉴线性控制系统设计的思想, 已发展了一些基于神经网络和模糊逻辑系统的非线性系统控制的设计方法, 如模型参考自适应控制、直接自适应控制、内模控制、逆控制、学习控制和预测控制等. 尽管神经网络与模糊逻辑系统有本质的区别, 然而它们对函数的逼近能力都具有相似性, 而两者的结合也

为发挥各自优势提供了更好的途径. Gupta 和 Rao 对模糊系统和神经网络在知识获取、不确定性描述、推理能力、自适应性和自然语言表达等方面作了比较后指出: 神经网络与模糊系统融合后将构成功能更强大的神经模糊系统 (neurofuzzy systems)^[1]. 自 20 世纪 90 年代初以来, 神经模糊系统在过程模型辨识、故障诊断、软测量及系统控制等方面都已有较多成功的应用.

Carcia 和 Morari 在 1982 年提出的内模控制 (IMC),

由于它具有设计简单、跟踪调节性能好、鲁棒性强以及能消除不可预测干扰影响等优点,已经成为工业过程控制系统的一类有效控制结构^[2].但是常规IMC控制结构和设计方法仅是局限于线性对象或对象非线性特性不明显的运行区域.1986年Economou等人在IMC分析和设计中引入了非线性算子理论,将IMC推广到非线性系统^[3].IMC应用于非线性动态系统控制的主要困难是要求建立精确的非线性对象的正模型和逆模型.一些工业过程即使建立了非线性动力学模型也难以求得逆模型的解析形式,在满足可逆性的条件下,通常采用迭代或牛顿法来求取模型的数值逆.为了克服IMC在工程应用中的困难,人们主要利用受控对象的输入输出数据建立对象模型和逆模型.已有的研究建议运用模糊模型、神经网络来建立受控对象模型和逆模型,实现复杂非线性对象的内模控制^[4-9].

本文研究了一类神经模糊模型在非线性动态系统建模中的应用,通过化学反应器(CSTR)的建模和逆系统建模证明了神经模糊建模技术的有效性.还研究了基于神经模糊模型的非线性系统内模控制设计,通过CSTR反应物浓度的PID控制和内模控制的比较研究,证明了神经模糊内模控制具有一定的控制范围和较好的控制效果.由于基于输入输出数据辨识的对象模型和逆模型存在未建模动态和模型失配等缺陷,将会导致内模控制的可控制范围变窄和控制鲁棒性不足等问题.为此,我们提出了神经模糊内模控制与PID控制结合的内模/PID双重控制策略.仿真实验表明,采用双重控制策略有效地拓宽了CSTR的可控制范围,进一步提高了系统的动态静态控制性能,其控制效果优于文献^[7,8]的CSTR内模控制.

2 神经模糊模型(Neurofuzzy model)

内模控制系统的设计,首先是建立对象正模型和逆模型.当前,在基于数据和知识的复杂系统建模中,神经模糊模型的非线性系统建模能力已经在各种应用中得到了验证.考虑 $\mathbf{x} = (x_1, x_2, \dots, x_p)^T$ 为 p 维输入变量, y 为单输出变量,具有 M 条规则的Takagi-Sugeno模糊模型(T-S模型)的一般形式为

$$R^l: \text{IF } x_1 \text{ is } F_1^l \text{ and } x_2 \text{ is } F_2^l \text{ and } \dots \text{ and } x_p \text{ is } F_p^l \\ \text{THEN } y \text{ is } f^l(\mathbf{x}), \quad l = 1, 2, \dots, M, \quad (1)$$

其中 F_k^l 是输入模糊子集, $f^l(\cdot)$ 是输入变量的函数,一阶T-S模型的 $f^l(\cdot)$ 是输入变量的线性组合,

$$f^l(\mathbf{x}) = a_0^l + a_1^l x_1 + \dots + a_p^l x_p. \quad (2)$$

当 $f^l(\cdot)$ 是常数型时,T-S模型就退化为后件是输出论域的一个实数的Mamdani模糊模型.若在前件推理采用乘积推理、高斯型(或三角形)隶属函数和重心去模糊化,模糊模型清晰化输出的一般形式为

$$y = f(\mathbf{x}) = \frac{\sum_{l=1}^M f^l(\mathbf{x}) [\prod_{k=1}^p \mu_{F_k^l}(x_k)]}{\sum_{l=1}^M [\prod_{k=1}^p \mu_{F_k^l}(x_k)]}, \quad (3)$$

式中 $\mu_{F_k^l}$ 是第 l 条规则的前件中第 k 个输入变量模糊子集的隶属函数.若令

$$p_l(\mathbf{x}) = \frac{\prod_{k=1}^p \mu_{F_k^l}(x_k)}{\sum_{l=1}^M [\prod_{k=1}^p \mu_{F_k^l}(x_k)]}, \quad \sum_{l=1}^M p_l(\mathbf{x}) = 1, \quad (4)$$

则式(3)可写为

$$y = f(\mathbf{x}) = \sum_{l=1}^M p_l(\mathbf{x}) f^l(\mathbf{x}). \quad (5)$$

在此, $p_l(\mathbf{x})$ 就是每条模糊规则的前件推理结果,而且是归一化的.

多层前馈型神经网络,例如MLP,RBF,CAMC和B样条函数神经网络都可以认为是一类只有单隐层的基函数神经网络.具有 n 个隐节点的一般输出形式为

$$y = f(\mathbf{x}) = \sum_{i=1}^n \phi_i(\mathbf{x}) w_i. \quad (6)$$

式中, $w_i (i = 1, 2, \dots, n)$ 是输出层的连接权, $\phi_i(\mathbf{x}) (i = 1, 2, \dots, n)$ 是基函数,其对于不同网络所取的基函数形式也随之变化.

在T-S模型与广义基函数神经网络等价的基础上,可以定义一类广义基函数神经模糊网络,简称为GBFNFN(general basis function neurofuzzy networks).比较式(5)和(6),若令 $n = M$,取 $\phi_i(\mathbf{x})$ 是归一化的模糊基函数,并且将 w_i 用 $f^i(\cdot)$ 代替,即可定义GBFNFN的输出为

$$y = f(\mathbf{x}) = \sum_{i=1}^M \phi_i(\mathbf{x}) f^i(\mathbf{x}). \quad (7)$$

进一步可考虑式(7)中的 $\phi_i(\mathbf{x})$ 取非归一化的形式.这样GBFNFN的输入到输出之间的每一条通路对应于一条模糊规则.若在输入空间采用模糊划分,则每一个模糊划分就对应于输入到输出的一条通路(或规则).式(7)描述的神经模糊模型的辨识与优化的任务归结如下:

1) 当输入输出变量确定的条件下,确定神经模

糊规则数 M , 其等价于在 GBFNFN 中确定网络的输入端到输出端之间的通道数, 它对应于输入空间模糊划分数;

2) 确定隐节点的输出形式, 归一化输出或非归一化输出;

3) 确定 GBFNFN 的基函数 $\phi_i(x) (i = 1, 2, \dots, M)$ 的形式, 宜选择对称径向基类函数;

4) 确定后件函数 $f^i(x) (i = 1, 2, \dots, M)$ 形式, 后件函数可以是线性函数、非线性函数、线性差分方程、线性微分方程或线性状态空间描述形式;

5) 前件参数辨识, 例如当基函数为高斯型, 待辨识参数是输入空间的聚类中心值和聚类半径值;

6) 后件函数 $f^i(x) (i = 1, 2, \dots, M)$ 的参数辨识。

上述 1)~4) 是神经模糊模型的结构辨识问题, 而 5), 6) 是参数辨识问题。要从上述六个方面的最优性角度来确定模型是非常困难。在实际建模中, 总是融合了模型设计者对问题认识和建模经验。在 GBFNFN 中, 一般先确定基函数(隶属函数)的形式、后件函数的形式、隐节点是否采用归一化等。GBFNFN 的结构辨识与优化问题归结为基函数隐节点的简化, 回溯到输入空间就是最优模糊划分或最优聚类数的确定。GBFNFN 的前件参数和后件函数的参数辨识不同于传统的模型参数估计问题, 由于 GBFNFN 的前件参数是聚类中心和聚类半径, 其取值与输入空间的模糊划分有关, 这样使得前件参数辨识与结构辨识交织在一起, 所以 GBFNFN 辨识与优化是结构与参数辨识的迭代优化过程。

动态系统建模既要有满意的模型精度、泛化能力, 又要有一定的模型鲁棒性。这个原则对于神经模糊建模同样适用。研究表明, 最精简的神经模糊模型结构具有三方面的作用: 1) 防止模型的过拟合; 2) 简单的模型便于解释和理解; 3) 对于因参数摄动、工作点漂移和时滞变化等引起的变化具有一定的鲁棒性。关于模糊模型的构造仍缺乏一般的方法, 特别在复杂动态系统模糊建模中, “规则爆炸”或“维数灾难”已成为制约模糊模型应用的主要瓶颈之一。神经模糊模型本质是一类模糊系统的神经网络描述及其实现, 所以模糊模型的“规则爆炸”、“维数灾难”对于神经模糊模型依然存在, 为此神经模糊模型的关键是模型的结构辨识。文献[10]给出了一阶 T-S 模型的结构和参数迭代优化算法, 文献[11]给出了一种

启发式模糊聚类学习方法, 这些方法可以平行地推广到神经模糊模型优化。

3 非线性动态系统神经模糊建模 (Neuro-fuzzy modeling for nonlinear dynamic systems)

非线性离散时间动态系统建模需要采用串联-并联型和并联型两种非线性模型结构。在串联-并联型模型结构中, 用对象当前和过去的输入输出信号来建模, 其表达式为

$$y_m(k+1) = f(y_p(k), y_p(k-1), \dots, y_p(k-n_y+1), u(k), u(k-1), \dots, u(k-m_u+1)). \quad (8)$$

其中 $y_m(k+1)$ 是在 $k+1$ 时刻的模型输出, $y_p(k), \dots, y_p(k-n_y+1)$ 和 $u(k), \dots, u(k-m_u+1)$ 分别为对象的输入输出, m_u 和 n_y 分别是对象输入输出的阶次, $f(\cdot)$ 为输入与输出之间的非线性映射。在并行结构中, 用非线性模型的输出来代替对象的输出, 则有

$$y_m(k+1) = f(y_m(k), y_m(k-1), \dots, y_m(k-n_y+1), u(k), u(k-1), \dots, u(k-m_u+1)). \quad (9)$$

运用 GBFNFN 建模时, 在模型训练阶段采用串联-并联模型结构, 经过充分训练后达到模型设计要求, 这时可用模型的输出来替代对象的输出构成并联型模型。基于 GBFNFN 模型, 由式(7)可得

$$y_m(k) = \sum_{i=1}^M \phi_i(y_p(k-1), \dots, y_p(k-n_y), u(k-1), \dots, u(k-m_u)) f^i(\cdot). \quad (10)$$

其中

$$f^i(\cdot) = a_0^i + a_1^i y_p(k-1) + \dots + a_{n_y}^i y_p(k-n_y) + b_1^i u(k-1) + \dots + b_{m_u}^i u(k-m_u),$$

$\phi_i(\cdot)$ 可以采用归一化或非归一化形式。以下讨论 GBFNFN 在简单不可逆放热反应的连续搅拌型化学反应器 CSTR (continuous stirred tank reactor) 的对象正模型和逆模型建模中的应用。

3.1 CSTR 的神经模糊建模 (Neurofuzzy modeling for CSTR)

CSTR 是化工过程的重要单元, 具有很强的非线性特性, 是化工系统中一类典型的非线性对象。CSTR 的输入输出动力学方程为

$$\frac{dC_a}{dt} = \frac{Q}{V} (C_{af} - C_a) - k_0 C_a \exp\left(-\frac{E}{RT}\right), \quad (11)$$

$$\frac{dT}{dt} = \frac{Q}{V}(T_f - T) + \frac{(-\Delta H)k_0 C_a}{\rho C_p} \exp\left(\frac{E}{RT}\right) + \frac{\rho_c C_{pc}}{\rho C_p V} Q_c \left[1 - \exp\left(\frac{-hA}{Q_c \rho_c C_{pc}}\right) \right] (T_{cf} - T). \quad (12)$$

在式(11)和(12)中, C_a 是反应器内生成物 A 的浓度; T 是反应器温度, Q 是进出料流量(一般假设反应器的进、出料相等); C_{af} 是进料浓度; T_f 是进料温度; Q_c 是冷却剂流量; T_{cf} 是冷却剂进口温度; T_c 是冷却剂出口温度. 通过调节冷却剂流量 Q_c 的大小, 可控制反应器内温度 T , 进而控制反应物的浓度 C_a . 根据工艺要求, 确定 C_a 和 T 是过程输出, Q_c 为控制变量, 可视 T_c , Q 和 C_{af} 为外部扰动变量. 表 1 给出了 CSTR 的参数和操作条件, 表中 Q_{c0} , T_0 和 C_{a0} 分别为 CSTR 的一个稳态工作点对应的稳态值.

表 1 CSTR 参数与操作条件

Table 1 Operation conditions and parameters of CSTR

$Q = 100 \text{ L/min}$	$E/R = 9.95 \times 10^3 \text{ K}$
$C_{af} = 1.0 \text{ mol/L}$	$-\Delta H = 2 \times 10^5 \text{ cal/mol}$
$T_f = 350 \text{ K}$	$\rho \rho_c = 1000 \text{ g/L}$
$T_{cf} = 350 \text{ K}$	$C_p C_{pc} = 1 \text{ cal/(gK)}$
$V = 100 \text{ L}$	$Q_{c0} = 103.41 \text{ L/min}$
$hA = 7 \times 10^5 \text{ cal/min K}$	$T_0 = 440.2 \text{ K}$
$k_0 = 7.2 \times 10^{10} \text{ 1/min}$	$C_{a0} = 0.0836 \text{ mol/L}$

图 1 和图 2 分别是当冷却剂流量在稳态工作点 $Q_{c0} = 103.41 \text{ L/min}$ 变化 +14% 和 -35% 时, CSTR 的开环响应, CSTR 的响应呈现非常强的非线性. 当冷却剂流量变化分别接近 +14% 和 -35% 时, CSTR 的开环响应出现不稳定, 为此, 必须将 Q_c 控制在上述变化之内.

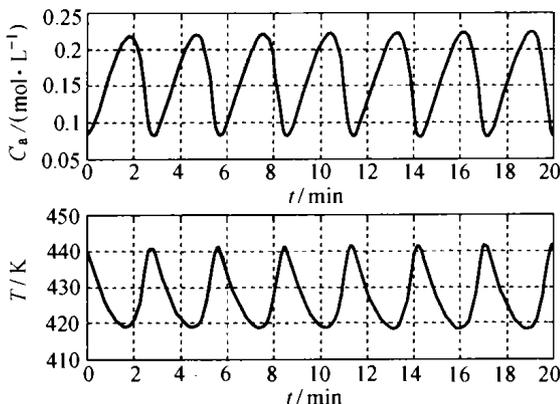


图 1 CSTR 开环响应(冷却剂流量变化 +14%)
Fig. 1 Open responses of CSTR with +14% change in Q_{c0}

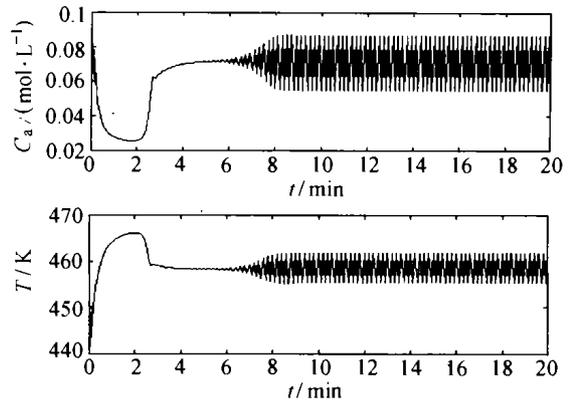


图 2 CSTR 开环响应(冷却剂流量变化 -35%)
Fig. 2 Open responses of CSTR with -35% change in Q_{c0}

对于非线性系统的辨识, 还没有关于持续激励的理论根据. 一些文献建议: 1) 若能了解系统稳定工作的大致频响范围, 可用不同频率的正弦信号的组合作为输入激励; 2) 若能了解系统稳定工作的输入信号幅值的大致范围, 在稳态工作点叠加一个具有固定的脉宽、适当强度的随机信号作为系统辨识的激励信号. 在此, 采用了第 2 种激励信号产生方案, 取固定的脉宽 10 min, 激励强度为 2.5 的随机信号叠加到 Q_{c0} 上, 激励信号的幅值控制在系统稳定范围内. 仿真计算采用 4 阶龙格-库塔法, 采样周期为 0.1 min, 时间长度为 1000 min, 将时间区间 800 ~ 1000 min 的共 2001 对输入输出数据作为模型训练数据.

合理地选择模型的输入变量及其输入差分项十分重要. 将矩阵 SVD-QR 方法用于输入数据矩阵的分析, 可以确定数据矩阵中重要的、不重要的、甚至是冗余的数据列, 这样可以确定模型输入中对应的重要输入、不重要输入和冗余输入变量. 设初始输入向量为 $[C_a(k) \ C_a(k-1) \ T(k) \ T(k-1) \ Q_c(k)]^T$, 对其相应的数据矩阵进行 SVD-QR 分析, C_a 的串联-并联型模型为

$$\hat{C}_a(k+1) = \text{NF}_{C_a}(C_a(k), T(k-1), Q_c(k)). \quad (13)$$

运用基于输入空间模糊聚类的神经模糊模型迭代优化方法, C_a 模型经过 4 次迭代可得最精简结构模型. 优化过程依次为 20 → 25 → 19 → 14 → 13, 初始模型的规则数为 20, 最终的模型规则数 $M = 13$. 后件参数估计采用单次或迭代的稳态 Kalman 滤波. 在此, 将神经模糊模型简称为 NF 模型. 图 3 是具有 13 条规则的 NF 模型输出和过程输出.

同理, 反应器温度的串联-并联型神经模糊模型

$$\hat{T}(k+1) = \text{NF}_T(C_a(k), T(k), T(k-1), Q_c(k)).$$

$$(14)$$

根据反应器温度 NF 模型确定的输入,模型迭代优化过程为 20→28→20→15→8→12→11,经过 6 次迭代可得最终的模型规则数 $M = 11$. 图 4 是反应器温度 NF 模型输出和过程输出.

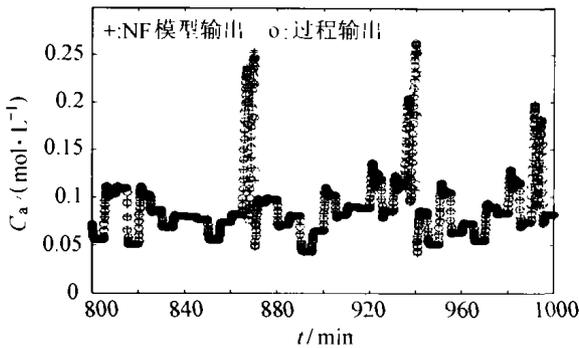


图 3 反应物浓度的 NF 模型训练

Fig. 3 Model training for reacted mass concentration

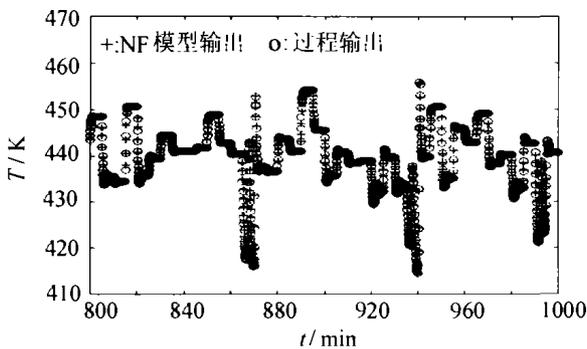


图 4 反应器温度的 NF 模型训练

Fig. 4 Model training for reacted temperature

3.2 CSTR 的神经模糊逆模型 (Neurofuzzy modeling of inverse model for CSTR)

设 SISO 离散非线性系统 $\Sigma: u(k) \rightarrow y(k)$, 由如下差分方程表示

$$\begin{aligned} y(k+1) &= f(y(k), y(k-1), \dots, y(k-n_y+1), \\ &\quad u(k), u(k-1), \dots, u(k-m_u+1)), \end{aligned} \quad (15)$$

初始条件

$$\begin{aligned} y_0 &= [y(0), y(-1), \dots, y(-n_y+1)], \\ u_0 &= [u(0), u(-1), \dots, u(-m_u+1)]. \end{aligned}$$

若令 $y(k+1) = \varphi_k$, 可得系统 Σ 的 n -阶延迟逆系统 $\Pi_n: \varphi_k \rightarrow u(k)$ 的方程

$$\begin{aligned} u(k) &= g(\varphi_k, y(k), \dots, y(k-n_y+1), \\ &\quad u(k-1), \dots, u(k-m_u+1)). \end{aligned} \quad (16)$$

逆模型在训练时采用串联-并联结构,当用于逆模控制器时采用并联结构.

根据逆系统的方程(16),由已建立的 CSTR 的反应物浓度 C_a 和反应器温度 T 的神经模糊模型,可以写出对应的逆系统.由于 CSTR 的浓度和温度是

互相制约的,于是 C_a 的神经模糊逆模型可表示为

$$\hat{Q}_c(k) = \text{NF}_{Q_c}(C_a(k+1), C_a(k), T(k-1)), \quad (17)$$

式中的 $C_a(k+1)$ 是期望输出的一步预测值.用建立正模型的同样数据,设初始规则数为 38,模型迭代优化过程为 38→23→32→30,最后获得聚类数为 30 的 NF 逆模型,具体辨识结果见文献[12].

4 神经模糊内模控制 (Neurofuzzy internal model control)

基本的线性内模控制结构框图如图 5 所示,传递函数中省略了复变量.图中各传递函数分别定义如下: G_p 为被控对象; G_m 为对象模型; G_c 为内模控制器; G_f 为反馈滤波器; G_r 为参考输入滤波器.内模控制设计方法的关键是在控制结构中包含了对象模型.当模型 G_m 和对象 G_p 失配时,在反馈信息中,除了原来的扰动量之外,还包含模型失配的信息,从而有利于控制系统的抗干扰,增强系统的鲁棒性.滤波器 G_f 和 G_r 的设计要考虑系统的抗干扰和鲁棒性,需要综合平衡.在不考虑滤波器 G_f 和 G_r 时,基本内模控制有以下特点: $G_p = G_m$, 这时系统相当于开环,系统稳定性完全由对象和控制器的稳定性所决定;若 G_p 稳定且 G_m 精确,模型的逆 G_m^{-1} 存在并且可实现,令控制器 $G_c = G_m^{-1}$, 则在任何时刻则有 $y_p(k) = y_r(k)$, 这表明对于任何扰动输入都能消除,实现了对参考输入的无偏差跟踪.

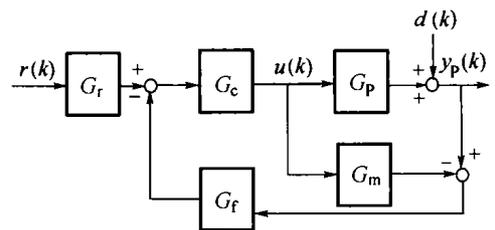


图 5 基本内模控制结构

Fig. 5 Structure of conventional internal model control

Economou 等人在线性 IMC 分析和设计中引入了非线性算子理论,将 IMC 推广到非线性系统. IMC 的以上特性也适用于非线性系统,这时对象模型是非线性的,若假设对象的逆存在,控制器是非线性对象模型的逆.在非线性的内模控制系统设计中,关键是要获得精确的对象模型和逆模型,但这是极其困难的.

4.1 基本神经模糊内模控制系统设计 (Design of conventional neurofuzzy internal model control)

基本神经内模控制系统设计是首先用神经模糊建模技术建立对象正模型和逆模型,然后将并联型

模型替代线性内模控制结构中的 G_m 和 G_c , 这就构成了基本神经模糊内模控制系统. 神经模糊内模控制系统 (neurofuzzy internal model control, NF-IMC) 的结构, 如图 6 所示. 在图中, 对象神经模糊模型和逆模型中都包含了对 $y_m(k)$ 和 $u(k)$ 的时间延迟线 (time-delay-line), 其分别实现对象模型 $f(s)$ 和逆模型 $g(\cdot)$. 为简单起见, 通常将输入滤波器和反馈滤波器选为参数相同的一阶滤波器.

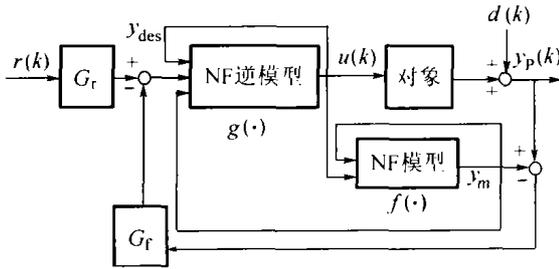


图 6 基本神经模糊内模控制结构

Fig. 6 Structure of conventional neurofuzzy internal

4.2 神经模糊内模控制在 CSTR 中的应用 (Neuro-fuzzy internal model control application to CSTR)

为了比较 CSTR 的 NF-IMC 和 PID 控制的效果, 作者分别研究了反应物浓度从 $C_{a0} = 0.0836$ 阶跃变化到 $C_{asp} = 0.12$ 和 $C_{asp} = 0.15$ 时, PID 控制的系统闭环响应. PID 控制器参数选择为: $C_{asp} > C_{a0}$, $K_p = 2 \times 10^3$, $K_i = 0.03 \times 10^3$, $K_d = 1.5 \times 10^3$, 分离积分误差限为 10%. 从仿真结果可知, 随着反应物浓度设定值的提高, 输出响应越来越不稳定. 当 $C_{asp} = 0.15$ 时, 系统响应就已经进入不稳定 (见图 7).

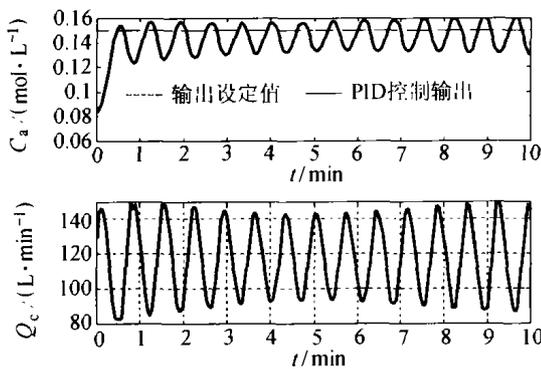


图 7 CSTR PID 控制响应曲线

Fig. 7 Response of CSTR under PID control

采用以上讨论的 CSTR 的神经模糊正模型和逆模型, 构成基本非线性内模控制系统, 这时输入与反馈的一阶滤波器的滤波系数 $\gamma = 0.55$. 图 8 和图 9 分别给出设定值从 $C_{a0} = 0.0836$ 阶跃变化到 $C_{asp} = 0.12$ 和 $C_{asp} = 0.15$ 时, CSTR 的 NF-IMC 的闭环响应. 当设定值变化到 $C_{asp} = 0.12$ 时, $C_a(t)$ 在 2 min

内无超调、平稳地上升到设定值, 稳态误差为 0; 当设定值从 $C_{a0} = 0.0836$ 变化到 $C_{asp} = 0.15$, NF-IMC 使得 $C_a(t)$ 略有超调, 大约在 5 min 内进入稳态, 这时稳态误差 $e_{ss} = 1.7\%$. 由此可见, NF-IMC 控制策略的动静态响应都明显地优于常规 PID 控制.

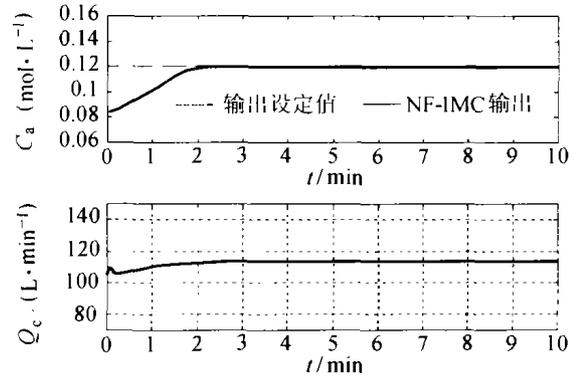


图 8 CSTR NF 内模控制响应曲线

Fig. 8 Response of CSTR under NF-IMC control

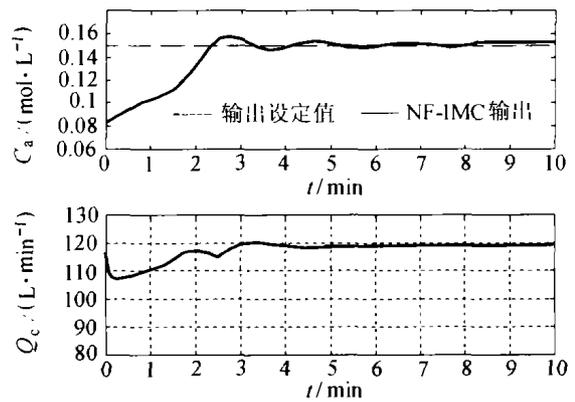


图 9 CSTR NF 内模控制响应曲线

Fig. 9 Response of CSTR under NF-IMC control

4.3 神经模糊内模控制的缺陷 (Defect of neuro-fuzzy internal model control)

在 CSTR 实验研究中发现, 当设定值从 $C_{a0} = 0.0836$ 变化到 $C_{asp} = 0.07$ 时, 尽管 NF-IMC 使得 $C_a(t)$ 单调下降, 但稳态误差 $e_{ss} = 24.3\%$. 若设定值进一步减小, 系统闭环响应就会出现持续等幅振荡. 实验表明, NF 内模控制在设定值 $C_{asp} < C_{a0}$ 时, 内模控制性能下降甚至导致控制失效. 这时, 可以观测到模型输出与对象输出相等. 内模控制结构实际是运行在直接逆模控制状态. 使系统闭环响应性能降低的原因是内模控制器失效, 这时因逆模型存在较大的建模误差而造成模型失配, 直接逆模控制不能获得理论上的“伪线性系统”^[12]. 若要实现 CSTR 的较大范围有效控制, 只有进一步提高逆模型的精

度,但这在模型结构的复杂性和训练耗时等方面需付出较大的代价。

5 神经模糊内模/PID 双重控制 (Double control strategy with NF-IMC and PID control)

为了克服模型失配问题,一些文献提出将模型自适应与内模控制结合的自校正内模控制策略,但这是以降低实时性、增加计算开销为代价的,而且模型自适应与内模控制的配合是一个新问题.作者从改造 NF-IMC 的结构着手,引入简单的 PID 反馈控制,提出了如图 10 所示的内模/PID 双重控制结构(简称 NF-IMC-PID 控制).NF-IMC-PID 控制克服了 NF-IMC 因模型不精确带来的控制性能下降等问题,同时也进一步提高了控制的鲁棒性。

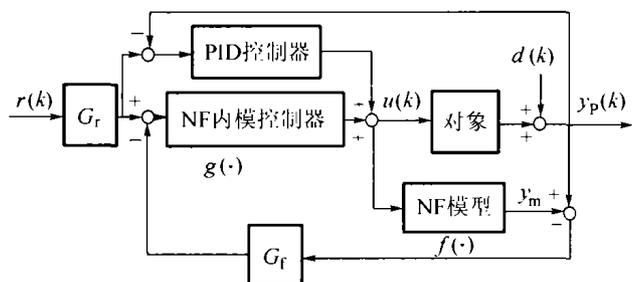


图 10 神经模糊内模/PID 双重控制结构
Fig. 10 Structure of NF-IMC-PID control system

将内模/PID 双重控制结构用于 CSTR 控制,而且注意到当 $C_{asp} < C_{a0}$ 时,常规 PID 控制效果明显优于其他的控制策略.本例仍采用 NF-IMC 的正模型、逆模型和滤波器参数,双重控制的 PID 控制器参数分别为: $C_{asp} \leq C_{a0}; K_P = 1.2 \times 10^3; K_i = 0.1 \times 10^3; K_d = 0.75 \times 10^3$; 积分分离的误差限为 25%; $C_{asp} > C_{a0}; K_P = 0.9 \times 10^3; K_i = 0.05 \times 10^3; K_d = 0.0$; 积分分离的误差限为 10%. 图 11 和图 12 分别给出了采用 NF-IMC-PID 控制后,设定值从 $C_{a0} = 0.0836$ 阶跃变化到 $C_{asp} = 0.15$ 和 $C_{asp} = 0.06$ 时, CSTR 的闭环响应.在上述设定值范围内,神经模糊内模/PID 双重控制使得 CSTR 的输出(反应物浓度)响应的动静态性能有非常明显的改善.如图 11 所示,系统响应略有超调,约在 2 min 内过渡过程结束,稳态误差为零.但 NF-IMC 控制则过渡过程时间需要 5 min 左右,而且稳态误差为 1.7%。

通过对神经模糊内模控制和神经模糊内模/PID 双重控制机理的比较,可知,由于基于辨识的对象正模型与逆模型都会存在模型不精确问题,若对象正模型与对象较匹配,而逆模型与对象不匹配, NF-

IMC 缺乏这种逆模失配信息的反馈,相当于处于直接逆模控制,但不能获得直接逆模控制在理论上的“伪线性系统”特性,因而使得系统控制性能下降.值得注意的是,在系统的一些局部工作区域这种“伪线性”性质是存在的,所以 NF-IMC 仍具有较好的控制效果.采用 NF-IMC-PID 控制结构,增加了逆模失配信息反馈的调节通道,扩大了系统控制范围,提高了系统的动静态性能,而且可以较大幅度地降低对逆模型的要求,这是非常有意义的。

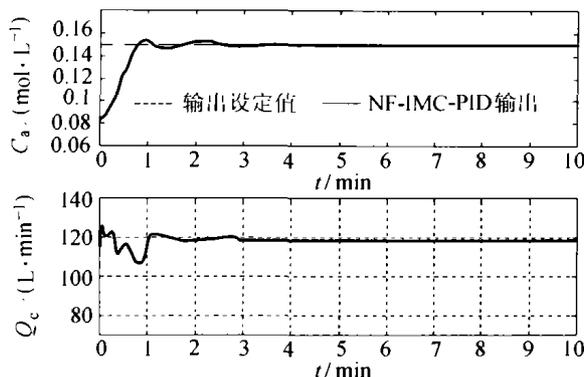


图 11 CSTR NF 内模/PID 双重控制响应曲线
Fig. 11 Response of CSTR under NF-IMC-PID control

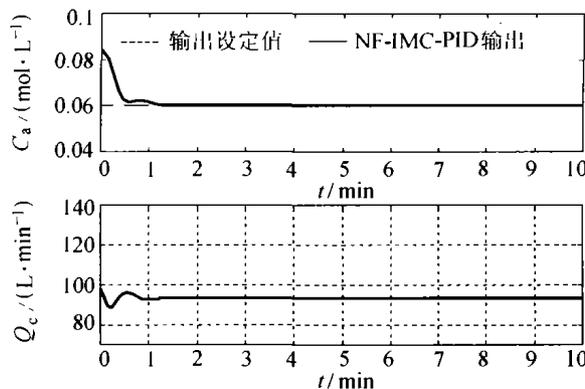


图 12 CSTR NF 内模/PID 双重控制响应曲线
Fig. 12 Response of CSTR under NF-IMC-PID control

6 结论 (Conclusions)

神经模糊模型迭代辨识与优化方法非常适合于非线性动态系统的建模,对 CSTR 的正模型和逆模型的建模表明,这种神经模糊建模技术具有较广的适应性和较高的实用价值.神经模糊内模控制(NF-IMC)的性能主要取决于对象正、逆模型的建模精度.由于辨识模型的不精确,导致 NF-IMC 的控制范围和控制性能都有一定的局限性.通过对 CSTR 的 NF-IMC 的控制效果分析,本文提出的 NF-IMC-PID 双重控制结构,使得内模控制与 PID 反馈控制各自的优势得到发挥,保证了闭环系统的鲁棒性,改善了系统控制范围和动静态性能.研究结果表明,对于非

线性内模控制不必一味地追求模型的精确性,完全依赖一种控制模式,如果将一些经典的、简单的控制模式与内模控制结合,可得到事半功倍的效果,这种控制系统设计思想也可供模糊控制、神经网络控制等系统参考。

参考文献(References):

- [1] GUPTA M M, RAO D H. On the principles of fuzzy neural networks [J]. *Fuzzy Sets and Systems*, 1994, 61(1): 1 - 18.
- [2] CARCIA C E, MORARI M. Internal model control. I. A unifying review and some new results [J]. *Ind Eng Chem Pro Des Dev*, 1982, 21(2): 308 - 323.
- [3] ECONOMOU C G, MORARI M, PALSSON B O. Internal model control: Extension to nonlinear systems [J]. *Ind Eng Chem Pro Des Dev*, 1986, 25(2): 403 - 411.
- [4] HUNT K J, SBARBARO D, ZBIKOWSKI R, et al. Neural networks for control systems: A survey [J]. *Automatica*, 1992, 28(6): 1083 - 1112.
- [5] HUNT K J, IRWIN G W, WARWICK K, et al. *Neural Network Engineering in Dynamic Control Systems* [M]. London: Springer-Verlag, 1995.
- [6] HUNT K J, SBARBARO D. Neural networks for nonlinear internal model control [J]. *IEE Proceeding, Part D*, 1991, 138(5): 431 - 438.
- [7] LIGHTBODY G, IRWIN G W. Nonlinear control structures based on embedded neural system models [J]. *IEEE Trans on Neural Networks*, 1997, 8(3): 553 - 567.
- [8] AOYAMA A, DOYLE III F J, VENKATASUBRAMNIAN V. Control-affine fuzzy neural network approach for nonlinear process control [J]. *J of Process Control*, 1995, 5(6): 375 - 386.
- [9] NAHAS E P, HENSON M A, SEBORG D E. Nonlinear internal model control strategy for neural networks [J]. *Computers & Chemical Engineering*, 1992, 16(12): 1039 - 1057.
- [10] 刘士荣, 俞金寿. 一类模糊模型的结构优化问题研究[J]. 计算机学报, 2001, 24(2): 164 - 172.
(LIU Shirong, YU Jinshou. Model construction optimization for a class of Fuzzy models [J]. *Chinese J of Computers*, 2001, 24(2): 164 - 172.)
- [11] 刘士荣, 余建军, 林卫星, 等. 启发式模糊聚类学习在函数逼近和非线性系统建模中的应用[J]. 模式识别与人工智能, 2003, 16(2): 230 - 235.
(LIU shirong, YU Jianjun, LIN Weixing, et al. Heuristic fuzzy cluster learning and its applications to function approximation and nonlinear system modeling [J]. *Pattern Recognition and Artificial Intelligence*, 2003, 16(2): 230 - 235.)
- [12] 刘士荣, 俞金寿. 神经模糊逆模/PID复合控制在CSTR中的应用[J]. 控制理论与应用, 2001, 18(5): 769 - 773.
(LIU Shirong, YU Jinshou. Composite control combining neuro-fuzzy inverse control with PID control and its application in a continuous stirred tank reactor [J]. *Control Theory & Applications*, 2001, 18(5): 769 - 773.)

作者简介:

刘士荣 (1952 —), 男, 博士, 教授, 研究领域包括复杂系统建模、控制与优化、智能机器人、智能系统与信息融合等, E-mail: liusr@mail.nbptt.zj.cn; shliu@uoguelph.ca;

林卫星 (1957 —), 男, 副教授, 研究领域包括系统辨识与建模、计算机控制等, E-mail: linzj@nbip.net;

俞金寿 (1939 —), 男, 教授, 博士生导师, 研究领域包括复杂系统模型化与控制、先进控制及人工智能在石油化工过程中的应用等, E-mail: jshyu@vip.sina.com;

杨先一 (1965 —), 男, 博士, 加拿大 Guelph 大学副教授, 先进机器人与智能系统实验室 (Advanced Robotics and intelligent Systems Lab) 主任, 主要研究领域包括机器人、智能系统、控制系统、信息融合、神经计算和生物信息学等, E-mail: syang@uoguelph.ca.