

自适应神经元非模型多变量优化补偿控制*

黄道平 朱学峰 胥布工

(华南理工大学自动控制工程系·广州, 510641)

摘要: 根据解耦补偿和优化控制的思想, 本文提出了一种完全不依赖于对象模型的自适应神经元多变量优化补偿器模型, 给出了神经元权系数的在线学习方法, 分析了其工作机理. 进一步给出了在某多侧线精馏塔和连续搅拌釜式反应器(CSTR)上的仿真结果.

关键词: 自适应神经元优化补偿; 多变量系统; 神经网络; 非模型控制

1 引言

解耦控制和最优控制都是解决多输入多输出系统控制的有效方法. 在这之前人们已建立了比较完整的解耦控制理论和最优控制方法. 但它们都需要精确的数学模型为基础. 要建立实际对象的准确数学模型在大部分情况下是困难的, 有时甚至是不可能的, 这就使得基于数学模型的解耦控制和最优控制的应用都受到极大的限制.

人工神经网络近年来在控制界获得了广泛的应用, 并取得了许多可喜的成果. 其中神经元非模型控制是神经控制研究中的一大热点, 文献[1, 2]等提出了一种结构简单、学习速度快、适用于控制的神经元非模型控制算法, 但其仅用于单变量系统. 文献[2]虽讨论了结合解耦补偿器的多变量神经元非模型控制, 但其中的解耦补偿器设计仍需要依赖对象的数学模型(即使是较简单的静态模型), 未能实现真正的非模型多变量(解耦)控制.

本文融合最优控制和解耦控制的思想, 提出了与传统的解耦控制方法不尽相同的一种完全不依赖于对象模型的自适应神经元优化补偿方法, 给出了神经元优化补偿器模型结构和参数的在线学习策略. 进一步的仿真表明了此方法的简单、实用和有效性.

2 神经元非模型控制

图 1 显示了非模型神经元控制系统^[1, 2]. 其中, 神经元学习策略主要有以下几种:

1) 无监督 Hebb 学习规则

$$\Delta w_i(t) = h s(t) x_i(t). \quad (1)$$

其中 h 是学习速率, $\Delta w_i(t)$ 是神经元第 i 个权重增量, $s(t)$ 是元输出, $x_i(t)$ 是元的第 i 个输入.

2) 有监督的 Delta 学习规则

$$\Delta w_i(t) = h z(t) x_i(t). \quad (2)$$

其中 $z(t)$ 是教师信号, 其它变量名同(1)式所述.

3) 有监督的 Hebb 学习规则

将无监督的 Hebb 学习和有监督的 Delta 学习结合起来, 可组成有监督的 Hebb 学习规则, 即

$$\Delta w_i(t) = h z(t) s(t) x_i(t). \quad (3)$$




图 1 神经元控制系统

* 华南理工大学自然科学基金资助项目(E1-108-193).

本文于 1997 年 3 月 19 日收到. 1998 年 1 月 16 日收到修改稿.

在图 1 中,转换器的输入量为反映受控对象及控制指标等状态量,如设定值 $r(t)$ 、输出测量值 $y(t)$ 等. 经过转换,变成神经元学习控制所需要的状态.

参考上述的几种学习规则,为保证学习的收敛性,规范化后得到此文所采用的神经元控制学习算法如下:

$$u(t) = k \sum_{i=1}^n w'_i(t) x_i(t), \quad (4)$$

$$w'_i(t) = w_i(t) / \sum_{i=1}^n |w_i(t)|, \quad (5)$$

$$w_i(t+1) = w_i(t) + h(r(t) - y(t))x_i(t), \quad i = 1, 2, \dots, n. \quad (6)$$

式中 k, h 是待取定的常数. 本文采用的神经元输入状态 $x_i(t)$ 为 ($n = 4$):

$$\begin{cases} x_1(t) = r(t), & x_2(t) = r(t) - y(t), \\ x_3(t) = x_2(t) - x_2(t-1), & x_4(t) = x_4(t-1) + \lambda x_2(t). \end{cases} \quad (7)$$

这里特别地加入了对系统误差有积分作用的 $x_4(t)$ 这个状态量,这是保证系统稳态无余差所必需的. 这是因为,虽然在 $w_i(t)$ 的学习中对误差 $(r(t) - y(t))$ 有“积分”作用(见式(6)),但式(5)的归一化限制了 $w'_i(t)$ 的范围. 所以 $w_i(t)$ 权系数的调整学习,只能在小范围内消除余差,而在大范围内它是无能为力的. 式(7)中的 λ 是可选系数,一般选小些为宜.

3 多变量系统的自适应神经元非模型优化补偿控制

多变量系统的控制设计是自动控制领域中的一大难题. 本文根据上述介绍的神经元自学习策略、多变量系统的解耦控制理论和优化控制方法,设计出如图 2 虚线框所示的神经网络自适应非模型优化补偿器,再结合神经元自适应控制器,构成图 2 所示自适应神经元非模型多变量优化补偿控制系统(为绘图方便,仅以三输入三输出系统为例绘图).




图 2 自适应神经元非模型多变量优化补偿控制系统

在图 2 中,自适应神经控制元和自适应神经优化补偿元的学习算法如下:

1) 神经元控制器算法:

$$\begin{cases} v_i(t) = k_i \sum_{j=1}^{m_i} w_{ij}(t) x_{ij}(t) / \sum_{j=1}^{m_i} |w_{ij}(t)|, \\ w_{ij}(t+1) = w_{ij}(t) + h_i(r_i(t) - y_i(t))x_{ij}(t), \end{cases} \quad i = 1, 2, \dots, n, j = 1, 2, \dots, m_i. \quad (8)$$

其中 h_i 是学习速率. 输入状态的选择为 ($m_i = 4$):

$$\begin{cases} x_{i1}(t) = r_i(t), & x_{i2}(t) = r_i(t) - y_i(t), \\ x_{i3}(t) = x_{i2}(t) - x_{i2}(t-1), & x_{i4}(t) = x_{i4}(t-1) + \lambda x_{i2}(t). \end{cases} \quad (9)$$

$w_{ij}(t)$ 的初始值可选为 0 ~ 1 之间的随机数.

2) 神经优化补偿器算法:

$$\begin{cases} u_i(t) = \sum_{j=1}^n b_{ij}(t)v_j(t), \\ b_{ij}(t+1) = b_{ij}(t) + d_{ij}(t)(r_i(t) - y_i(t))v_j(t), \end{cases} \quad i = 1, 2, \dots, n, j = 1, 2, \dots, n. \quad (10)$$

$b_{ij}(t)$ 初始值的选取为

$$\begin{cases} b_{ij}(0) = 1, & (i = j), \\ b_{ij}(0) = 0, & (i \neq j). \end{cases} \quad (11)$$

在式(10)中的 $d_{ij}(t)$ 是学习速率,为了保证算法的收敛, $d_{ij}(t)$ 采用如下式所示的变学习速率:

$$d_{ij}(t) = \begin{cases} d_1 \exp(-0.2(|b_{ij}(t)| - 1)), & i = j, \\ d_2 \exp(-0.2|b_{ij}(t)|), & i \neq j. \end{cases} \quad (12)$$

其中 d_1, d_2 是二个初始学习速率(常数).

4 自适应神经元非模型优化补偿器的机理分析

根据公式(10)和图 2 的关系,可以获得如下关于优化补偿器的关系式:

$$\begin{bmatrix} u_1(t) \\ u_2(t) \\ \vdots \\ u_n(t) \end{bmatrix} = \begin{bmatrix} b_{11}(t) & b_{12}(t) & \cdots & b_{1n}(t) \\ b_{21}(t) & b_{22}(t) & \cdots & b_{2n}(t) \\ \vdots & \vdots & \ddots & \vdots \\ b_{n1}(t) & b_{n2}(t) & \cdots & b_{nn}(t) \end{bmatrix} \begin{bmatrix} v_1(t) \\ v_2(t) \\ \vdots \\ v_n(t) \end{bmatrix}. \quad (13)$$

设 n 输入、 n 输出的多变量受控对象可由下式描述:

$$\begin{bmatrix} y_1(t) \\ y_2(t) \\ \vdots \\ y_n(t) \end{bmatrix} = \begin{bmatrix} g_{p11}(z^{-1}) & g_{p12}(z^{-1}) & \cdots & g_{p1n}(z^{-1}) \\ g_{p21}(z^{-1}) & g_{p22}(z^{-1}) & \cdots & g_{p2n}(z^{-1}) \\ \vdots & \vdots & \ddots & \vdots \\ g_{pn1}(z^{-1}) & g_{pn2}(z^{-1}) & \cdots & g_{pnn}(z^{-1}) \end{bmatrix} \begin{bmatrix} u_1(t) \\ u_2(t) \\ \vdots \\ u_n(t) \end{bmatrix}. \quad (14)$$

其中 $g_{pij}(z^{-1})$ 是实际对象相应通道的 z 传递函数,并设 k_{pij} 是 $g_{pij}(z^{-1})$ 的静态增益($i, j = 1, 2, \dots, n$).

为了说明优化补偿器算法式(10)的工作机理,建立各个系统输出的局部优化目标函数如下:

$$J_i = \frac{1}{2}(r_i(t) - y_i(t))^2, \quad i = 1, 2, \dots, n. \quad (15)$$

从式(14)的多变量对象输入输出关系式和式(13)的补偿器关系式可以看出,目标函数 J_i 是补偿器权系数 $b_{ij}(t)$ 的函数.通过 $b_{ij}(t)$ 的自学习、调整,可以使目标函数 J_i 达到最小.为此,可以采用梯度法进行搜索.

从式(15)、(14)、(13)可求得:

$$\begin{aligned} \frac{\partial J_i}{\partial b_{ij}(t)} &= -(r_i(t) - y_i(t)) \frac{dy_i(t)}{db_{ij}(t)} \\ &= -(r_i(t) - y_i(t)) \frac{dy_i(t)}{du_i(t)} \cdot \frac{du_i(t)}{db_{ij}(t)}, \quad i = 1, 2, \dots, n, j = 1, 2, \dots, n. \end{aligned} \quad (16)$$

令

$$\frac{dy_i(t)}{du_i(t)} \approx k_{pii}. \quad (k_{pii} \text{ 为对象相应通道的静态增益}) \quad (17)$$

而

$$\frac{du_i(t)}{db_{ij}(t)} = v_j(t). \quad (18)$$

将式(17)、(18)代入式(16),得:

$$\frac{\partial J_i}{\partial b_{ij}(t)} = - (r_i(t) - y_i(t)) k_{pii} v_j(t). \quad (19)$$

根据梯度优化方法即可得 $b_{ij}(t)$ 的学习调整公式如下:

$$\begin{aligned} b_{ij}(t+1) &= b_{ij}(t) - \lambda_{ij} \frac{\partial J_i}{\partial b_{ij}(t)} \\ &= b_{ij}(t) + \lambda_{ij} k_{pii} (r_i(t) - y_i(t)) v_j(t). \end{aligned} \quad (20)$$

其中 λ_{ij} 是优化步长. 因为 k_{pii} 是常数, 可令 $d_{ij}(t) = \lambda_{ij} k_{pii}$, 再把 $d_{ij}(t)$ 看成是新的、可调整的优化步长, 则式(20)可写成:

$$b_{ij}(t+1) = b_{ij}(t) + d_{ij}(t) (r_i(t) - y_i(t)) v_j(t). \quad (21)$$

至此, 可以看出, 式(21)即是神经优化补偿器式(10)中的系数自学习公式.

从上述分析可知, 神经网络补偿器各权系数自学习的结果, 将使多变量系统的各输出值趋向于一种局部最优. 且这是一种不依赖于对象模型、仅根据一些过程信息不断学习和调整的过程, 故将该补偿器称之为自适应神经元非模型多变量优化补偿器.

5 仿真研究

5.1 多侧线精馏塔的自适应神经元非模型优化补偿控制仿真

某多侧线精馏塔近似的线性化数学模型如下^[3]:

$$\begin{bmatrix} y_1(s) \\ y_2(s) \\ y_3(s) \end{bmatrix} = \begin{bmatrix} \frac{0.7}{1+9s} & 0 & 0 \\ \frac{2}{1+8s} & \frac{0.4}{1+6s} & 0 \\ \frac{2.3}{1+10s} & \frac{2.3}{1+8s} & \frac{2.1}{1+7s} \end{bmatrix} \begin{bmatrix} u_1(s) \\ u_2(s) \\ u_3(s) \end{bmatrix}. \quad (22)$$

其中 y_1, y_2, y_3 是塔顶和两个侧线的重组分浓度, 为被控量. 而 u_1, u_2, u_3 是塔顶和两个侧线的相应采出量, 作为控制变量. 显然, 这是严重关联的多变量对象. 仿真控制系统框图如图 2 所示, 仿真实验结果如图 3(b) 所示. 图 3(b) 表明, 随着神经优化补偿器的不断学习, 起动一段时间后系统控制效果即获得明显改善. 虽然没能完全消除各通道之间的关联, 但改善了多变量系统的动态性能, 使各被控量基本上独立运行, 且都获得良好的控制效果. 为了比较, 图 3(a) 给出了式(22)对象在没有神经优化补偿器情况下 (相当于在图 2 中令 $b_{ij} \equiv 1 (i=j), b_{ij} \equiv 0 (i \neq j)$ 的过渡过程曲线. 显然此时多变量系统难以正常运行.




图 3(a) 无优化补偿器的多侧线精馏塔系统过渡过程




图 3(b) 自适应非模型神经优化补偿多侧线精馏塔系统过渡过程

5.2 连续搅拌釜式反应器(CSTR)的自适应神经元非模型优化补偿控制仿真

连续搅拌釜式反应器(CSTR)的反应过程可由一个非线性微分方程组来描述^[4]:

$$\begin{cases} \dot{c}_A = \frac{q}{v}(c_{Af} - c_A) - k_0 c_A \exp(-\frac{E}{RT}), \\ \dot{T} = \frac{q}{v}(T_f - T) + \frac{(-\Delta H)k_0 c_A \exp(-\frac{E}{RT})}{\rho c_p} + \frac{\rho_c c_{pc} q_c}{\rho c_p v} \left[1 - \exp(-\frac{hA}{q_c \rho_c c_{pc}}) \right] (T_{cf} - T), \end{cases} \quad (23)$$

一单级不可逆放热反应 $A \rightarrow B$ 在反应器中进行. c_A 是生成物 A 的浓度, T 是反应器温度, q_c 是冷却剂流量, q 是进料流量. 在这, c_A 和 T 作为被控量, q_c 和 q 作为控制输入. 控制之目的是通过操纵 q_c 和 q 来控制 c_A 和 T 值. 这是一个二输入二输出、严重关联和严重非线性的复杂系统. 仿真控制系统框图形如图 2. 仿真结果如图 4(b)所示. 图 4(a)则是无优化补偿环节的过渡过程曲线. 对比图 4(a)和图 4(b)可以看出, 加入自适应神经优化补偿环节, 提高了系统的稳定性, 改善了整个多变量系统的动态性能, 且使各输出量都能较好地跟随并稳定在其给定值上.




图 4(a) CSTR 无优化补偿器控制曲线




图 4(b) CSTR 自适应非模型神经优化补偿控制曲线

6 结束语

本文提出的完全不依赖于对象模型的自适应神经优化补偿控制方法, 不仅适用于线性多变量系统, 同样对非线性多变量系统亦能获得较好的控制效果, 同时还能改善整个控制系统的动态性能. 由于自适应神经补偿器具有在线学习的功能, 故此它能克服对象参数慢时变对控制系统的影响. 此算法简单、运算量小、且完全不依赖于对象的模型, 工程实现容易. 故此, 这是一种很有研究价值和应用价值的非线性多变量控制算法.

参 考 文 献

- 1 王顺显, 舒迪前. 智能控制系统及其应用. 北京: 机械工业出版社, 1995
- 2 王宁. 神经网络控制理论及应用研究. 华中理工大学博士学位论文, 武汉, 1992
- 3 W. H. 雷著, 邵惠鹤, 俞金寿译. 高级过程控制. 北京: 轻加工出版社, 1987
- 4 Henson, M. S. and Seborg, D. E.. Input-output linearization of general nonlinear processes. AIChEJ, 1990, 36(11): 1755-1757

Adaptive Neural Non-Model Optimal Compensating Control for MIMO System

HUANG Daoping, ZHU Xuefeng and XU Bugong

(Department of Automatic Control Engineering, South China University of Technology • Guangzhou, 510641, PRC)

Abstract: Based on the principle of the decoupling compensating and optimal control, an adaptive neural optimal compensator independent on object model and the on-line learning method of neuron weights are presented. The principle of the compensator is analysed. Further, the simulation results in a distillation column with multi-outputs and in a CSTR are shown.

Key words: adaptive neural optimal compensating; MIMO system; neural networks; non-model control

本文作者简介

黄道平 1961年生,现为华南理工大学副教授,分别于1982年、1986年和1998年在华南理工大学获得学士、硕士和博士学位。1995至1996年在比利时根特大学(University of Gent)作访问学者。目前主要研究方向为多变量非线性过程控制,预测控制,智能控制和人工神经网络。

朱学峰 1940年生,现为华南理工大学教授,博士生导师,分别于1962年和1965年在华南化工学院和华南工学院获得学士和硕士学位。1980年至1982年和1992年至1993年分别在美国Lehigh大学和University of California Santa Barbara当访问学者和教授。主要研究方向:工业过程的建模、仿真、控制和优化。

胥布工 1956年生。1972年3月至1978年9月在某大型石化企业工作。1978年10月至1982年7月在华南理工大学化工自动化及仪表专业学习,获工学学士学位。1982年8月至今在华南理工大学自动控制工程系任教,历任助教、讲师、现为副教授,系主任。期间,分别于1989年和1993年获工学硕士和工学博士学位。1993年11月至1995年3月在英国Strathclyde大学电子与电气工程系作博士后访问研究。主要研究兴趣为时滞系统和不确定系统的分析与综合,大系统理论及其在工业过程中的应用。