

文章编号: 1000-8152(2005)01-0110-04

基于混合神经网络的非线性预测函数控制

周洪煜¹, 张 坚², 游立科¹, 张 峰³

(1.重庆大学 动力工程学院, 重庆 400044; 2. 上海大学 机电工程与自动化学院, 上海 200072;
3. 西安大唐电信有限公司, 陕西 西安 710075)

摘要: 针对基本预测函数控制只能用于线性对象的控制这一不足, 提出了基于混合神经网络的非线性预测函数控制。混合神经网络由 BP 网络和线性神经网络串连组成, 采用混合神经网络对可用 Hammerstein 模型描述的非线性对象进行有效的辨识。其中, BP 网络反映了非线性静态增益, 线性神经网络反映了线性动态子系统。利用 BP 网络求出非线性静态增益的逆并与非线性对象串联, 抵消非线性对象中的非线性静态增益部分, 将非线性对象的控制问题转化为对线性对象的控制问题, 实现了对非线性对象的预测函数控制。当被控对象的特性发生变化时, 可对混合神经网络权值及时进行修正并调整控制器参数使控制系统始终保持良好的控制性能。仿真结果表明, 此控制系统具有良好的控制效果。

关键词: 混合神经网络; Hammerstein 模型; 预测函数控制; 非线性静态增益; 线性动态子系统

中图分类号: TP273 文献标识码: A

Nonlinear predictive function control based on hybrid neural network

ZHOU Hong-yu¹, ZHANG Jian², YOU Li-ke¹, ZHANG Feng³

(1. Power Engineering College, Chongqing University, Chongqing 400044, China;
2. School of Mechanical & Electronic Engineering and Automation, Shanghai University, Shanghai 200072, China;
3. Xi'an Datang telephone Corp., Ltd., Xi'an Shaanxi 710075, China)

Abstract: A basic predictive function control (PFC) is only applicable for linear plant control. To overcome the defect, a nonlinear self-adaptive PFC based on a hybrid neural network is presented. The hybrid neural network is composed of BP network and linear neural network. One can identify a nonlinear plant described with Hammerstein model effectively by the hybrid neural network. The BP network reflects the nonlinear static gain. The linear neural network reflects the linear dynamic subsystem. Then the inverse form of nonlinear static gain is solved and in series with the nonlinear plant to compensate the nonlinear static gain of nonlinear plant. Thus the nonlinear plant control is transformed into linear plant control and the PFC of nonlinear plant is realized. The control system can adjust the weights of hybrid neural network and the parameters of controller timely to keep good control performance when the character of controlled plant varies. Simulation results show that the control system has good control effect.

Key words: hybrid neural network; Hammerstein model; predictive function control; nonlinear static gain; linear dynamic subsystem

1 引言(Introduction)

预测函数控制具有计算量小、实时性高、控制性能优良的特点。但它是以被控对象的基函数的输出响应可以叠加为前提的, 因而只适用于线性动态系统的控制。实际工业过程常表现出不同程度的非线性, 当对象只存在弱非线性时, 可把弱非线性视为一种模型失配, 其影响可采用过程实际输出与模型输出之间的误差进行反馈校正或通过鲁棒性设计加以克服; 当对象具有强非线性时, 用常规的基于线性对

象模型的预测函数控制就很难得到满意的控制效果^[1]。

在实际中, 有广泛的一类非线性系统可以用 Hammerstein 模型来描述。如许多化工设备或过程中的染色工艺、pH 中和过程^[2]等。对于此类非线性对象, 文献[3]采用广义预测函数控制对染色工艺进行了控制, 文献[4]采用基于模型的预测控制来对化学反应堆中的温度进行控制。但是他们均具有计算量大, 实时性差的缺点。本文中提出了基于混合神经网

络的非线性预测函数控制,可有效降低控制过程中的计算量,提高控制系统的实时性。

2 非线性对象的混合神经网络辨识(Identification of the nonlinear plant by the hybrid neural network)

本文中采用混合神经网络辨识可用 Hammerstein 模型描述的非线性对象。网络结构如图 1 所示。混合神经网络由一个 SISO 的 BP 网络及一个线性神经网络串联组成。可采用反向传播 BP 算法同步训练该混合神经网络的权值和阈值。具体方法参见文献[4]。混合神经网络经过训练后就可反映非线性对象的输入输出关系。其中的 BP 网络反映了非线性对象的静态增益,线性神经网络反映了线性动态子系统。从而将非线性对象的非线性静态增益与线性动态子系统分别辨识得到。

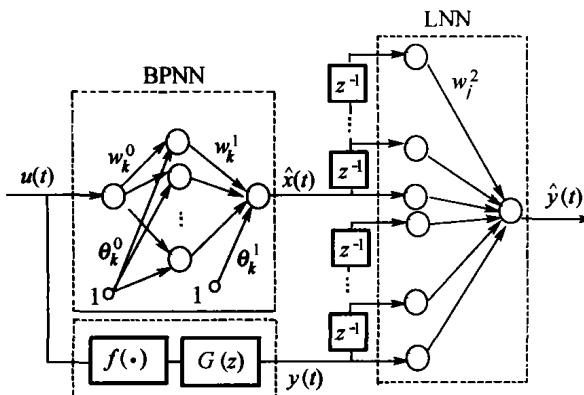


图 1 混合神经网络结构示意图

Fig. 1 Block diagram of hybrid network

3 基于混合神经网络的非线性预测函数控制(Nonlinear predictive function control based on hybrid neural networks)

对于可用 Hammerstein 模型来描述的非线性对象,采用第 2 节中所提出的混合神经网络将非线性静态增益与线性动态子系统分别辨识得到后^[4],可求出此非线性静态增益的逆并将其与非线性对象串联,抵消非线性对象中的非线性静态增益部分,把非线性对象的控制问题转化为对线性对象的控制问题,从而实现了非线性对象的预测函数控制。基于混合神经网络的非线性预测函数控制结构如图 2 所示。

PFC 仍属于模型预测控制的范畴,因此它仍具有模型预测控制的三大特征:预测模型、反馈校正、滚动优化^[5]。另外,为了适应被控对象模型变化较大的情况,本文所提出的基于混合神经网络的非线性预测函数控制还需要对预测模型及非线性静态增益

的逆进行在线校正。

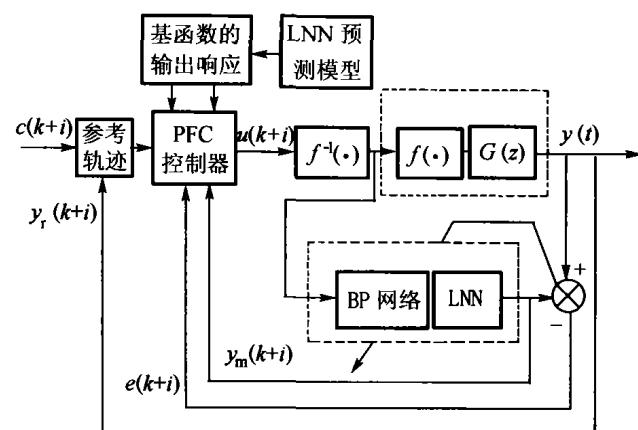


图 2 基于混合神经网络非线性预测函数控制框图

Fig. 2 Block diagram of nonlinear predictive function control based on hybrid network

3.1 预测模型(Predictive model)

预测模型用来预测过程的未来输出,PFC 对预测模型没有特殊的要求,它可以是任意结构。预测函数控制的模型输出预测值 $y_m(k+i)$ 由模型自由输出和模型函数输出两部分组成:

1) 模型在 $k+i$ 时刻的自由输出是指从 k 时刻起对模型不施加任何控制作用的情况下模型在 $k+i$ 时刻的预测输出值。

2) 模型函数输出

$$\omega(i) = \sum_{n=1}^N \mu_n g_n(i) \quad (1)$$

表示在 k 时刻起加入控制作用 $u(k+i)$ 后新增加的模型响应。

新加入的控制输入不是在时间上各自独立的量,而是基函数 $f_n(i)$ (表示第 n 个基函数在时刻 iT 时的值, T 为采样周期)的线性组合:

$$u(k+i) = \sum_{n=1}^N \mu_n f_n(i). \quad (2)$$

因此,其引起的输出变化是不同基函数的叠加,而非不同时间点控制效应的叠加。

本文中用混合神经网络中的线性神经网络作为预测模型求取模型自由输出和模型函数输出之和。

3.2 反馈校正(Feedback correction)

模型的预测输出与对象实际输出之间存在一定的偏差,叫预测误差。预测误差用来对模型的预测值进行校正。取未来的预测误差 $e(k+i)$ 为

$$e(k+i) = y(k) - y_m(k). \quad (3)$$

其中, $y_m(k)$ 是 k 时刻的模型输出。

在此基础上,可得到误差补偿后的预测输出:

$$y_p(k+i) = y_m(k+i) + e(k+i), i = 1, \dots, P. \quad (4)$$

3.3 滚动优化(Rolling optimizaiton)

1) 参考轨迹

预测函数控制的参考轨迹采用从现在时刻实际输出值出发的一阶指数形式:

$$\begin{aligned}y_r(k+i) &= \alpha^k y(k) + (1 - \alpha^k) c(k+i), \\y_r(k) &= y(k), i = 1, \dots, P.\end{aligned}\quad (5)$$

其中, $y_r(k+i)$ 为参考轨迹, $c(k+i)$ 为未来时刻的设定值, $\alpha = \exp(-T/\tau)$, T 为采样周期, τ 为参考轨迹的时间常数.

2) 性能指标

优化的目标是要寻找一组系数 $\mu_1, \mu_2, \dots, \mu_N$, 使整个优化时域内的预测输出尽可能接近参考轨迹确定的期望值 $y_r(k+i)$, ($i = 1, \dots, P$).

把 k 时刻的已知量记为:

$$\begin{aligned}Y &= y_r(k+i) - y_m(k+i) - e(k+i) + \omega(i) \\i &= 1, \dots, P.\end{aligned}\quad (6)$$

定义:

$$G = \begin{bmatrix} g_1(1) & \cdots & g_1(P) \\ \vdots & & \vdots \\ g_N(1) & \cdots & g_N(P) \end{bmatrix},$$

则性能指标可写为:

$$\min J(k) = (Y - G^T \mu)^T (Q(Y - G^T \mu)). \quad (7)$$

式中, $Q = \text{diag}\{q_1, \dots, q_p\}$, q_1, \dots, q_p 为非负加权系数, $\mu^T = [\mu_1, \dots, \mu_N]$, $g_i(j)$ 表示第 i 个基函数在 j 时刻的输出响应.

令 $\frac{dJ(k)}{d\mu} = 0$, 求得使性能指标最小的最优解为

$$\mu = (GQG^T)^{-1} GQY^T. \quad (8)$$

可将 $(GQG^T)^{-1} GQ$ 预先算出后存入计算机, 此时优化计算仅是矩阵向量的乘法运算.

解出 μ_n ($n = 1, \dots, N$) 后, 即可综合出 k 时刻应加入的函数输入 $u(k+i)$ ($i = 0, \dots, P-1$). 其中, $u(k)$ 除可作为新加入的控制作用付诸实施外, 其余的控制量可逐一送入预测模型的输入端, 用以预测对象在未来时刻的输出.

3.4 在线校正(Online correction)

当系统的动态特性发生较大变化时, 对基本的预测函数控制而言, 由于预测模型不变, 所以预测模型的输出将与对象的实际输出有较大的偏差, 此时, 控制系统的性能将变坏. 控制系统中采用混合神经网络后, 则可以利用此偏差作为混合神经网络训练信号, 对网络的权值进行修正, 从而使网络可以准确

反映非线性对象变化后的非线性静态增益 $f(\cdot)$ 与线性动态特性. 从而可以得到准确的实时的非线性静态增益的逆 $f^{-1}(\cdot)$ 和线性预测模型, 并据此对控制器参数进行修正, 使控制系统始终保持优良的性能.

3.5 非线性预测函数控制算法(Nonlinear predictive function control algorithm)

1) 利用对象的实际输入输出数据对混合神经网络离线进行训练, 分别辨识得到反映对象非线性静态增益 $f(\cdot)$ 的 BP 网络与反映对象线性动态特性的线性神经网络. 然后利用 BP 网络的输入输出数据作为另一 BP 网络的输出输入数据对其进行训练得到非线性静态增益的逆 $f^{-1}(\cdot)$. 将新 BP 网络与非线性对象串联, 并复制线性神经网络用于求基函数的输出响应.

2) 算法初始化: 选择加权系数矩阵 Q 、预测优化时域长度 P 、基函数数目 N 及种类和误差允许值 T_o , 并设控制量的初始值 $u(0), u(1), \dots, u(P-1)$ 为 0, 时刻 k 为 0, 对象的输出 $y(0)$ 及模型输出预测值 $y_m(0)$ 为 0.

3) 利用对象的实时输入输出数据对混合神经网络进行训练, 并利用训练后的网络更新反映 $f^{-1}(\cdot)$ 的 BP 网络与反映动态子系统的线性神经网络. 然后利用线性神经网络求出各基函数的输出响应 $g_n(i)$ ($i = 1, \dots, P$), 得到 G , 求出 $(GQG^T)^{-1} GQ$.

4) 将 $u(k)$ 付诸实施, 并将 $u(k), u(k+1), \dots, u(k+P-1)$ 逐一送入线性神经网络预测模型, 得到模型预测值 $y_m(k+1), y_m(k+2), \dots, y_m(k+P)$.

5) 计算预测误差 $e(k+i) = y(k) - y_m(k)$, $y(k)$ 为对象在 k 时刻的实际输出. 在此基础上, 根据式(4) 可得到误差补偿后的预测输出 $y_p(k+i)$ ($i = 1, \dots, P$).

6) 读入对象在 $k+1, k+2, \dots, k+P$ 时刻的设定值, 根据式(5) 计算得到参考轨迹 $y_r(k+i)$ ($i = 1, 2, \dots, P$).

7) 利用式(8) 计算得到 μ_n ($n = 1, \dots, N$), 即可综合出 k 时刻应加入的函数输入 $u(k+i)$ ($i = 0, \dots, P-1$).

8) 令 $k = k+1$, 若 $e(k+i-1) > T_o$, 则转入 3) 执行, 否则转入 4) 执行.

4 仿真研究(Simulation research)

采用 pH 中和滴定过程作为计算机仿真的对象,在采样区间 0~45 s, 45~90 s 内被控对象的模型^[2]分别为

1) 非线性静态增益

$x(k) = f(u(k)) = u(k) - 1.207u^2(k) + 1.15u^3(k)$,
线性动态子系统

$$G(z) = \frac{y(k)}{x(k)} = \frac{0.0185z^{-2} + 0.173z^{-3} + 0.00248z^{-4}}{1 - 1.558z^{-1} + 0.597z^{-2}}.$$

2) 非线性静态增益

$x(k) = f(u(k)) = 2.1u(k) + 0.95u^3(k)$,
线性动态子系统

$$G(z) = \frac{y(k)}{x(k)} = \frac{0.021z^{-2} + 0.0152z^{-3}}{1.2 + 1.871z^{-1}}.$$

对上述被控对象采用基于混合神经网络的非线性预测函数控制后,结果如图 3 所示。由图可见,非线性预测函数控制响应速度快,并可根据设定值曲线预知设定值的变化而提前响应,且过程的输出超调小、控制量的变化平稳。当被控非线性对象的特性发生变化时,可对控制器参数进行及时调整,从而使控制系统始终保持良好的控制性能。

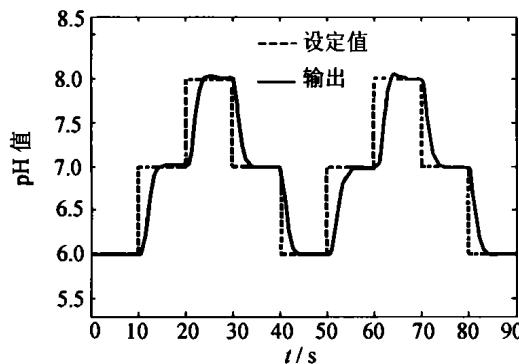


图 3 基于混合神经网络的非线性预测函数控制结果

Fig.3 Results of nonlinear predictive function control based on bybrid neural netowrk

5 结论(Conclusion)

本文中提出了基于混合神经网络的非线性自适应预测函数控制,适用于可用 Hammerstein 模型描述的非线性对象。该算法的特点是只需进行线性寻优及求解一个 P 次代数方程而不需要进行非线性优化,过程的预测输出应用线性神经网络直接计算得到。而且在非线性对象的特性变化较大时可通过在线修正混合神经网络的权值使之准确地反映非线性对象实时的非线性静态增益及线性动态特性。既保

持了基本预测函数控制计算量小的优点,又能够满足时变的非线性对象在各种工况下对控制品质的要求,具有较强的实用性,值得推广。

根据本文中提出的控制算法及相关文献很容易推广到多输入、多输出的非线性被控对象及可用 Wiener 模型描述的非线性被控对象。

参考文献(References):

- [1] 张泉灵,王树青.基于 ARMAX 模型自适应预测函数控制[J].信息与控制:2000,29(5):431~436.
(ZHANG Quanling, WANG Shuqing. Self-adaptive predictive function control based on ARMAX model [J]. *Information and Control*, 2000,29(5):431~436.)
- [2] 顾钟文,邹志云,罗文巍.一类非线性系统的预测控制算法[C]//中国自动化学会首届过程控制科学报告会论文集.杭州:浙江大学出版社,1987:186~194.
(GU Zhongwen, ZOU Zhiyun, LUO Wenwei. One kind of predictive control algorithm of nonlinear system [C]// *Proc of the First Symposium of Chinese Association of Automation on Process Control*. Hangzhou: Zhejiang University Press, 1987:186~194.)
- [3] ZHANG Jianxin, CHEN Benyong, ZHONG Tingxiu. Nonlinear generalized predictive control to a thermal process for batch dyeing [C]// *The Fifth International Symposium on Instrumentation and Control Technology*. Washington, America: The International Society for Optical Engineering, 2003:611~615.
- [4] M'SAHLI F, ABDENNOUR R B, KSOURI M. Nonlinear model-based predictive control using a generalised Hammerstein model and its application to a semi-batch reactor[J]. *Int J of Advanced Manufacturing Technology*, 2002, 20(11):844~852.
- [4] LI Shihua, LI Qi, LI Jie. Identification of Hammerstein model using hybid neural networks [J]. *Journal of Southeast University*, 2001, 17(1):26~30.
- [5] 王树青.先进控制技术及应用[M].北京:化学工业出版社,2001:109~129.
(WANG Shuqing. *Advanced Control Technology and Application* [M]. Beijing: Chemical Industry Press, 2001:109~129.)

作者简介:

周洪煜 (1954—)男,1984 年毕业于重庆大学获硕士学位,现任重庆大学动力工程学院副教授,研究方向为:智能控制及其应用;

张 坚 (1976—)男,上海大学机电工程与自动化学院博士研究生。研究方向为神经网络,先进控制技术,E-mail: zhangjian168@yeah.net;

游立科 (1980—)男,重庆大学动力工程学院硕士研究生。研究方向为:智能控制及其应用;

张 峰 (1978—)男,2000 年毕业于重庆邮电学院,获学士学位,现任西安大唐电信有限公司工程师,研究方向为:智能软件工程。