

一类非线性不确定系统的最小方差神经控制*

牛玉刚 杨成梧 赵建丛
(南京理工大学动力学院 210094)

摘要 针对一类非线性不确定系统,提出一种新的基于神经网络动态补偿的最小方差控制方法(MVNNC)。这种控制系统将传统的最小方差控制技术与神经网络优良的非线性逼近能力相结合,从而能有效地消除不确定性引起的控制误差。仿真实验表明,这种最小方差神经控制系统具有较强的鲁棒性和良好的动态性能。

关键词 神经网络,不确定性,最小方差控制,补偿

分类号 TP 273

Minimum Variance Neural Control for a Class of Nonlinear System with Uncertainties

Niu Yugang, Yang Chengwu, Zhao Jiancong
(Nanjing University of Science & Technology)

Abstract A new neural network-based minimum variance control technique (MVNNC) was proposed for a special class of nonlinear uncertain systems. This control scheme integrates classical linear minimum variance control technique and the excellent learning ability of neural network. It can eliminate system control error caused by nonlinear uncertainties. Simulation results show that this control scheme has a strong robustness with respect to system uncertainties and a good dynamic performance.

Key words neural network, uncertainties, minimum variance control, compensation

1 引言

最小方差控制是用于控制随机扰动对系统输出影响最小的一种有效方法,在工业过程控制中具有重要的应用价值。文献[1,2]提出的基于神经网络的非线性最小方差控制方案,为克服非线性系统的建模困难,实现非线性最小方差控制提供了一种新方法。

本文进一步将传统的最小方差控制技术与神经网络的非线性逼近能力相结合,提出一种基于神经网络补偿的最小方差控制方法。被控对象为部分已知的非线性不确定性系统,其中已知的线性标称模型用于设计一个传统最小方差控制器,而基于神经网络辨识模型的神经补偿器则用于对最小方差控制进行补偿,从而可以有效地消除系统不确定性的影响,提

高最小方差控制的鲁棒性。这种新的最小方差神经控制的显著特点是充分利用了被控对象的先验知识,因此可以大大改善闭环系统的控制性能。

2 问题描述

2.1 一般最小方差控制

不失一般性,考虑如下 SISO 非线性系统

$$y(k) = f(y(k-1), \dots, y(k-n), u(k-d), \dots, u(k-d-m)) + \omega(k) \quad (2.1)$$

其中, u 和 y 为输入和输出, $\{\omega(k)\}$ 为白噪声, $f(x)$ 为未知非线性光滑函数。在实际应用中,设计者通常对系统动态特性有个粗略估计,利用这些先验知识可将 $f(x)$ 表示为

$$f(x) = f_0(x) + \delta f(x) \quad (2.2)$$

其中, $f_0(x)$ 为已知函数,表示 $f(x)$ 的某个基准估计,设 $f_0(x)$ 为 $y(k-1), \dots, y(k-n), u(k-d)$,

* 国防科技预研基金项目(99J16.6.1BQ0214)

..., $u(k-d-m)$ 的线性函数; $\delta_f(x)$ 为未知函数, 表示系统的非线性不确定性。

将式(2.2)代入(2.1), 整理得

$$A(q^{-1})y(k) = q^{-d}B(q^{-1})u(k) + \omega(k) + \delta_f(x) \quad (2.3)$$

其中

$$A(q^{-1}) = 1 + a_1q^{-1} + a_2q^{-2} + \dots + a_nq^{-n}$$

$$B(q^{-1}) = b_0 + b_1q^{-1} + b_2q^{-2} + \dots + b_nq^{-n}, \quad b_0 \neq 0$$

并假设 $B(q^{-1})$ 为 Hurwitz 多项式, q^{-1} 表示单位延迟算子, d 为时延。

当不存在不确定性(即 $\delta_f(x) = 0$) 时, 系统的标称模型为

$$A(q^{-1})y(k) = q^{-d}B(q^{-1})u(k) + \omega(k) \quad (2.4)$$

于是可得模型(2.4)在性能指标 $J_1 = E\{[y(k+d) - y^d(k+d)]^2\}$ 下的最小方差控制器为

$$u_0(k) = y^d(k+d) - \frac{E(q^{-1})}{B(q^{-1})D(q^{-1})}y(k) \quad (2.5)$$

其中 $D(q^{-1})$ 和 $E(q^{-1})$ 满足 Diophantine 方程

$$1 = D(q^{-1})A(q^{-1}) + q^{-d}E(q^{-1})$$

当系统存在非线性不确定性时, 由于非线性不确定性的影响, 控制器(2.5)不能保证系统(2.3)的输出满足性能指标 J_1 为最小, 即系统存在控制误差。因此, 为消除非线性不确定性的影响, 本文设计对象 P 的控制输入为控制器(2.5)加上一个补偿项 Δu , 即

$$u = u_0 + \Delta u \quad (2.6)$$

2.2 最小方差神经控制结构

本文提出的非线性不确定最小方差神经控制系统如图1所示。其中, 神经网络 NNI 用于辨识对象 P 的非线性不确定性, NNC 为基于辨识模型 NNI 的神经补偿控制器。

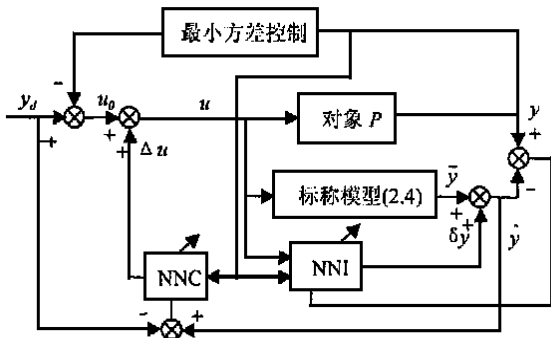


图1 最小方差神经控制系统

设对象 P 的实际输出为 $y(k)$, 标称模型(2.4)的输出为 $\bar{y}(k)$ 。由于系统存在非线性不确定性, $y(k)$ 与 $\bar{y}(k)$ 一般不一致, 本文将 NNI 与模型(2.4)并联起来实现对 P 的建模。

设 NNI 的输出为 $\delta y(k)$, 网络 NNI 和模型(2.4)的并联辨识模型输出为 $\hat{y}(k)$, 则

$$y(k) = \bar{y}(k) + \delta y(k) \quad (2.7)$$

对 NNI 进行训练, 使得 $\hat{y}(k)$ 任意逼近 $y(k)$ 。这样, 通过将被控对象 P 的先验模型(2.4)与神经网络建模相结合, 可以得到对象 P 更准确的模型。而通过将 NNC 的输出 Δu 作为控制器(2.5)的补偿信号, 可以消除非线性不确定性产生的控制误差。

3 训练算法

3.1 多层前馈神经网络结构

设 NNI 和 NNC 为三层前馈神经网络; 并设 $x_i(k)$ 为输入层第 i 个节点的输入, O_j^H 为隐层第 j 个节点的输出, $O(k)$ 为输出层节点的输出, 输入层第 i 个节点到隐层第 j 个节点的权重为 w_{ij} , 隐层第 j 个节点到输出层第 k 个节点的权重为 v_j , 隐层节点的激励函数 $f(x)$ 为双曲正切函数 $\tanh(x)$, 输出层节点的激励函数为线性函数。于是可得网络输入到输出的映射关系为

$$\begin{cases} \text{net}_j = \sum_i w_{ij}x_i(k) \\ O_j^H = f(\text{net}_j), O(k) = \sum_j v_j O_j^H \end{cases} \quad (3.1)$$

为明确起见, 以下分别用上角标 I 或 C 表示对应于 NNI 或 NNC 的量。

3.2 基于神经网络的辨识模型

设 NNI 的输入为

$$X^I(k) = \{x_1(k), \dots, x_i(k), \dots, x_{n+m+1}(k)\} = \{y(k), \dots, y(k-n+1), u(k-d+1), \dots, u(k-d-m+1)\}$$

输出为 $\delta y(k+1) = O^I(k+1)$ 。NNI 训练的目标是使并联辨识模型的输出值 $\hat{y}(k+1)$ 与系统实际输出值 $y(k+1)$ 的误差充分小, 因此定义网络 NNI 的训练指标函数为

$$J_2 = \frac{1}{2}e^2 = \frac{1}{2}(y(k+1) - \hat{y}(k+1))^2 \quad (3.2)$$

BP 算法在极小点附近存在收敛缓慢的缺陷。为了改善网络训练的收敛速率, 本文采用带死区函数

的 BP 算法^[3] 修正网络权重, 得到权重修正规则如下

$$v_j^l(k+1) = v_j^l(k) - \eta D(e_1) \frac{\partial J_2}{\partial v_j^l} = v_j^l(k) + \eta D(e_1) (y(k+1) - \hat{y}(k+1)) O_j^{H1} \quad (3.3)$$

$$w_{ij}^l(k+1) = w_{ij}^l(k) + \eta D(e_1) (y(k+1) - \hat{y}(k+1)) v_j^l(1 - O_j^{H1})(1 + O_j^{H1}) x_i^l(k) \quad (3.4)$$

其中, η 为学习速率, $D(e_1)$ 为对应于误差 e_1 的死区函数。

3.3 神经网络补偿器的设计

本文用 NNC 的输出 $\Delta u(k)$ 作为控制器(2.5)的补偿信号, 即对象 P 的控制输入为

$$u(k) = u^0(k) + \Delta u(k) \quad (3.5)$$

其中 NNC 的输入为

$$X^C(k) = \{x_i^C(k)\} = \{y(k-1), \dots, y(k-n)\}$$

网络 NNC 的训练目标, 是使模型(2.3)和控制器(3.5)组成的闭环系统的输出 $y(k+d)$ 与希望输出 $y_d(k+d)$ 间的误差方差最小。由 3.2 节知, 并联辨识模型的输出 \hat{y} 可以任意逼近系统实际输出 y , 因此本文选择 NNC 的训练指标函数为

$$J_3 = E\{[y(k+d) - y_d(k+d)]^2\} \quad (3.6)$$

其中

$$\hat{y}(k+d) = \bar{y}(k+d) + \delta y(k+d)$$

记 $e_2 = y(k+d) - y_d(k+d)$, 由式(2.4)得

$$\bar{y}(k+d) = D(q^{-1})\alpha(k+d) + B(q^{-1})D(q^{-1})u(k) + E(q^{-1})\bar{y}(k)$$

于是有

$$\frac{\partial \bar{y}(k+d)}{\partial u(k)} = B(q^{-1})D(q^{-1}) \quad (3.7)$$

网络 NNI 的输出为 $\delta y(k+d)$, 根据 NNI 的输入输出映射关系(3.1), 得到

$$\frac{\partial \delta y(k+d)}{\partial u(k)} = \sum_j v_j(1 + O_j^{H1})(1 - O_j^{H1})w_{lj}^1 \quad (3.8)$$

采用 3.2 节算法(死区函数为 $D(e_2)$), 由式(3.5), (3.7), (3.8) 得到 NNC 的权值调整规则如下

$$v_j^c(k+1) = v_j^c(k) - \eta_c D(e_2) [\hat{y}(k+d) - y_d(k+d)] \frac{\partial \bar{y}(k+d)}{\partial v_j^c} \quad (3.9)$$

$$w_{ij}^c(k+1) = w_{ij}^c(k) - \eta_c D(e_2) [\hat{y}(k+d) - y_d(k+d)] \frac{\partial \bar{y}(k+d)}{\partial w_{ij}^c} \quad (3.10)$$

其中

$$\frac{\partial \bar{y}(k+d)}{\partial v_j^c} = (B(q^{-1})D(q^{-1}) + \sum_j v_j^l(1 + O_j^{H1})(1 - O_j^{H1})w_{lj}^1) O_j^{HC}$$

$$\frac{\partial \hat{y}(k+d)}{\partial w_{ij}^c} = (B(q^{-1})D(q^{-1}) + \sum_j v_j^l(1 + O_j^{H1})(1 - O_j^{H1})w_{lj}^1) \times v_j^c(1 + O_j^{HC})(1 - O_j^{HC})x_i^c$$

记

$$\delta_1 = B(q^{-1})D(q^{-1}) + \sum_j v_j^c(1 + O_j^{HC})(1 - O_j^{HC})w_{lj}^c \quad (3.11)$$

$$\delta_2 = v_j^c(1 + O_j^{HC})(1 - O_j^{HC}) \quad (3.12)$$

于是得到 NNC 的学习算法为

$$v_j^c(k+1) = v_j^c(k) - \eta_c D(e_2) [y(k+d) - y_d(k+d)] \delta_1 O_j^{HC} \quad (3.13)$$

$$w_{ij}^c(k+1) = w_{ij}^c(k) - \eta_c D(e_2) [y(k+d) - y_d(k+d)] \delta_1 \delta_2 x_i^c \quad (3.14)$$

4 仿真实验

考虑一非线性不确定随机系统, 当忽略非线性或不不确定性时, 得到系统的标称模型为

$$(1 - 1.7q^{-1} + 0.7q^{-2})\bar{y}(k) = q^{-1}(1 + 0.5q^{-1})u(k) + (1 + 1.5q^{-1} + 0.9q^{-2})\alpha(k) \quad (4.1)$$

而系统的实际模型为

$$y(k) = \bar{y}(k) + \epsilon [1 - \exp(-\bar{y}(k))] \quad (4.2)$$

其中参数 ϵ 用于控制非线性程度。

首先按式(2.5)设计系统标称模型(4.1)的最小方差控制器为

$$u(k) = -0.5u(k-1) - 3.2y(k) - 0.2y(k-1) \quad (4.3)$$

由于(4.1)为最小相位系统, 因此由(4.3)构成的最小方差控制系统为闭环稳定系统。

对于系统(4.2), 用神经网络 NNI 和 NNC 分别辨识和补偿系统的非线性不确定性。其中, NNI 为 $4 \times 10 \times 1$ 型, NNC 为 $2 \times 10 \times 1$ 型, 网络初始权值都取 $(-0.1, 0.1)$ 中的随机数, 学习速率分别为 $\eta = 0.1, \eta_c = 0.05$, 死区函数的界 $d_0 = 0.001$ 。设 NNC 的输出信号为 Δu , 于是得到系统(4.2)的控制




图2 最小方差控制系统的响应曲线

输入为 $u = u_0 + \Delta u$, u_0 为标称模型(4.1)的控制器(4.3)。

本文对实际系统(4.2) ($\epsilon = 0.6$) 分别在最小方差控制和最小方差神经控制下,对方波信号(幅值为 ± 5 , 周期为100)的跟踪情况进行仿真,其结果如图2和图3所示。

由仿真结果可以看出,当系统存在非线性不确定性时,基于线性模型的最小方差控制的响应曲线振荡较大,控制效果不佳。而本文提出的最小方差神经控制通过神经网络的补偿作用,使得系统响应快,稳态误差小,具有较强的鲁棒性和良好的动态响应。

参考文献

- 1 Bittanti S, Piroddi L. GMV technique for nonlinear control with neural networks. IEE Proc D, 1994, 14(2): 57




图3 最小方差神经控制系统的响应曲线

- 2 Bittanti S, Piroddi L. Neural implementation of GMV control schemes based on affine input/output models. IEE Proc D, 1997, 14(6): 521 ~ 530
- 3 F C Chen, H K Khalil. Adaptive control of nonlinear systems using neural networks — A dead-zone approach. In: Proc of ACC. Boston, 1991. 667 ~ 672

作者简介

牛玉刚 男,1964年生。南京理工大学动力学院博士研究生。研究领域为复杂系统建模,自适应控制,神经网络控制。

杨成梧 男,1936年生。南京理工大学教授,博士生导师。研究领域为复杂系统,高速采样控制,信号处理等。

赵建丛 女,1966年生。河北农业大学讲师。研究领域为非线性系统辨识,神经网络理论等。

(上接第457页)

参考文献

- 1 Barmish B R. Stabilization of uncertain systems via linear control. IEEE Trans on Autom Contr, 1983, 28: 848 ~ 850
- 2 Schmitendorf W E. Design methodology for robust stabilizing controllers. J Guidance, 1987, 10: 250 ~ 254
- 3 Barmish B R. Necessary and sufficient condition for quadratic stabilizability of uncertain linear systems. J Optim Theory Appl, 1985, 46(2): 389 ~ 408
- 4 Wonham W M. Linear multivariable control: A geometric approach. Berlin: Springer-Verlag, 1979
- 5 Anderson B D, Clements D J. Algebraic characterization of fixed modes in decentralized control. Automatica, 1981, 17(5): 703 ~ 712

- 6 Geromel J C, Cruz J J. On the robustness of optimal regulators for nonlinear discrete-time systems. IEEE Trans on Autom Contr, 1987, 32(8): 703 ~ 710
- 7 Driss M, Mohammed A H, Francois P. Robustness and optimality of linear quadratic controller for uncertain systems. Automatica, 1996, 32(7): 1081 ~ 1083

作者简介

张颖伟 女,1969年生。东北大学自动控制理论及应用专业博士研究生。研究方向为相似组合大系统。

王剑 男,1957年生。1990年东北大学信息科学与工程学院获硕士学位,现为东北大学副教授。研究方向为相似组合大系统。

张嗣瀛 见本刊本期第422页。