

文章编号: 1000-8152(2002)04-05-0639

基于多模型的非线性系统自适应最小方差控制*

孙 维¹, 李晓理², 王 伟³

(1. 东北大学 信息学院, 沈阳 110006; 2. 清华大学 自动化系, 北京 100084; 3. 大连理工大学 信息与控制研究中心, 大连 116024)

摘要: 对于一类典型的离散时间非线性系统, 提出了一种基于多模型的自适应最小方差控制方法. 通过在平衡点附近建立线性模型, 用径向基函数神经网络来补偿建模误差和未建模动态, 形成了非线性系统的多模型表示. 采用了具有积分性质的切换指标函数作为切换法则和最小方差的控制方法构成了多模型自适应控制器. 仿真实验的结果表明了这种方法的有效性.

关键词: 非线性系统; 多模型; 最小方差控制; 径向基函数神经网络; 自适应控制

中图分类号: TP273.2; TP271

文献标识码: A

Multiple model based adaptive minimum variance control of nonlinear system

SUN Wei¹, LI Xiao-li², WANG Wei³

(1. College of Information Science and Engineering, Northeastern University, Shenyang 110006, China;

2. Department of Automation, Tsinghua University, Beijing 100084, China;

3. Research Center of Information and Control, Dalian University of Technology, Dalian 116024, China)

Abstract: A multiple model based adaptive minimum variance control is provided for a nonlinear discrete time system that is subject to multiple operating regimes. The RBFNN, i. e. radial basis function neural network, is used to approximate the nonlinear unmodeled error of the local linear model at different equilibrium operating point. And the nonlinear system is modeled by the multiple linear models and neural network at different equilibrium operating point. A switching function with integral property and minimum variance algorithm are used to set up the multiple model adaptive controller. From the result of simulation, it can be seen that the controller proposed in this paper can give a better control performance for nonlinear system.

Key words: nonlinear system; multi-model; minimum variance control; RBFNN; adaptive control

1 引言(Introduction)

多模型自适应控制(MMAC)是对于具有强非线性和参数跳变的系统进行控制的一种有效的方法. 在 70 年代初期, 就提出了 MMAC 的概念^[1], 它利用多个卡尔曼滤波模型来改善系统的状态估计和控制问题. 90 年代以来, 由 Middleton, Goodwin, Narendra 等人基于线性连续时间系统, 相继给出了基于指标切换函数的多模型自适应控制^[2,3], 并证明了算法的闭环稳定性. 有关非线性系统的多模型自适应控制方法正在研究和探索中. 文[4]对一类非线性离散时间系统建立多个局部线性化模型, 提出了解决一类非线性系统控制问题的多模型预测控制方法.

近来神经网络作为强有力的非线性建模工具已大量应用于非线性被控对象, 它与多模型方法的

结合, 对非线性系统的控制已得到一些令人满意的结果. 文[5]将线性模型与 RBF 神经网络模型相结合, 解决了一类非线性被控对象的控制问题; 文[6]将多线性模型与 BP 神经网络相结合, 构成多模型自适应控制器, 由于神经网络的存在, 减少了线性模型的数量, 提高了计算速度.

本文对一类典型的离散时间非线性系统, 提出了一种多模型与自适应最小方差控制(MVAC)相结合的非线性控制方法. 它是在对非线性被控对象建立多个局部线性模型的基础上, 用径向基函数神经网络(RBFNN)来补偿线性模型建模误差和未建模动态, 并采用具有积分性质的指标函数作为切换法则构成多模型自适应控制器. 仿真实验的结果表明, 和用简单的线性模型作为局部模型相比, 本文提出的这种方法使系统的动、静态特性和控制品质

* 基金项目: 国家杰出青年科学基金(69825106)和教育部高等学校骨干教师资助计划资助.

收稿日期: 2000-07-05; 收修改稿日期: 2001-05-09.

都得到了改善,有效的控制了局部模型的数量,能够保证模型间的稳定切换.在参数时变的情况下,也能得到良好的控制效果.且由于采用了具有递推最小二乘性质的 RBF 神经网络,加速了自适应算法在辨识过程中参数的收敛速度.

2 问题描述(Problem description)

考虑如下单输入单输出离散时间非线性系统

$$\begin{cases} x(k+1) = f(x(k), u(k)), \\ y(k+1) = g(x(k), u(k)). \end{cases} \quad (1)$$

其中, $y(k)$ 为系统输出, $f(\cdot)$ 和 $g(\cdot)$ 为状态变量 $x(k) \in \mathbb{R}^N$ 和系统输入 $u(k)$ 的非线性函数,且 $f(\cdot)$ 和 $g(\cdot)$ 连续且一阶可微.假设系统(1)具有 N 个已知的状态平衡点 (x_i, y_i, u_i) , $i = 1, 2, \dots, N$, 将系统(1)在各平衡点附近线性化展开,可得到 N 个不同的线性模型

$$\begin{cases} x_i(k+1) = \frac{\partial f}{\partial x} \Big|_{(x_i, u_i)} (x_i(k) - x_i) + \\ \quad \frac{\partial f}{\partial u} \Big|_{(x_i, u_i)} (u_i(k) - u_i) + x_i, \\ y_i(k+1) = \frac{\partial g}{\partial x} \Big|_{(x_i, u_i)} (x_i(k) - x_i) + \\ \quad \frac{\partial g}{\partial u} \Big|_{(x_i, u_i)} (u_i(k) - u_i) + y_i. \end{cases} \quad (2)$$

即为系统的线性化多模型表示.但是在系统非线性强、关联严重的情况下,这种局部范围内的线性化模型和实际的非线性系统之间存在着匹配误差 e_m : 其一来自于模型线性化时的建模误差,即 $f(\cdot)$ 和 $g(\cdot)$ 泰勒展开时省略的高阶导数项;其二是由于系统运行可能进入未建模区域而引起的未建模动态误差.这种模型与实际对象间误差的存在,使得系统的动、静态特性,控制品质,鲁棒性,甚至稳定性都难以得到保证.

由于 RBFNN 具有可以以任意精度逼近非线性函数的特性,本文用 RBFNN 来逼近局部线性化模型的非线性误差 e_m . 假设在给定的有界闭区域 D 内,构造 RBFNN,使网络输出 \hat{e}_m 在任意给定 $\epsilon \geq 0$ 时,存在有效的权值向量 w ,使得 $|e_m - \hat{e}_m| \leq \epsilon$,在 D 区域内成立.则在平衡点附近得到如下的局部模型 $M_i (i = 1, 2, \dots, N)$

$$\begin{cases} x_i(k+1) = \frac{\partial f}{\partial x} \Big|_{(x_i, u_i)} (x_i(k) - x_i) + \frac{\partial f}{\partial u} \Big|_{(x_i, u_i)} (u_i(k) - u_i) + \\ \quad x_i + NN(w_x, x_i(k), u_i(k)), \\ y_i(k+1) = \frac{\partial g}{\partial x} \Big|_{(x_i, u_i)} (x_i(k) - x_i) + \frac{\partial g}{\partial u} \Big|_{(x_i, u_i)} (u_i(k) - u_i) + \\ \quad y_i + NN(w_y, x_i(k), u_i(k)). \end{cases} \quad (3)$$

其中, $NN(w, x(k), u(k))$ 为 RBFNN 的输出向量, $x(k), u(k)$ 为 RBFNN 的输入向量, w 为权值向量.神经网络所具有的非线性逼近性和适应性,使得用 RBFNN 来逼近模型误差后,不仅有效地补偿了模型的误差项,并且减少了局部模型个数,消除了模型切换时的震荡,提高了系统的抗干扰能力,改善了系统的鲁棒性与动态响应特性,使动态响应快,动态偏差小.

3 控制方案设计(Design of control law)

3.1 自适应最小方差控制器(Adaptive minimum variance controller)

本文考虑设计控制器保证被控对象的输出渐进跟踪设定值.由于被控对象的非线性特性,采取基于多模型的控制器设计方法,其控制方案为:使被控对象的输出从一个设定值跟踪到另一个设定值,逐渐的接近最终的跟踪目标.被控对象的多模型表示将足够覆盖其跟踪区域.这样被控对象的控制器将在基于不同的平衡点处的局部模型控制器内切换.文中采用自适应最小方差控制算法构成多模型自适应控制器.假设系统的参考输出为 $y^*(k) (|y^*(k)| < \infty)$, 并设切换指标函数为

$$J(k+1) = \frac{1}{2} [y(k+1) - y^*(k+1)]^2. \quad (4)$$

通过极小化切换指标函数(4),可得到如下的最小方差控制律^[7]

$$\begin{aligned} \frac{\partial g}{\partial u} \Big|_{(x_i, u_i)} u_i(k) = \\ y_i^*(k+1) - \frac{\partial g}{\partial x} \Big|_{(x_i, u_i)} (x_i(k) - x_i) + \\ \frac{\partial g}{\partial u} \Big|_{(x_i, u_i)} u_i - y_i - NN(w_y, x_i(k), u_i(k)). \end{aligned} \quad (5)$$

当系统工作在不同的区域时,多模型的自适应最小方差控制将在不同局部模型的控制器间切换.

3.2 RBFNN 的训练算法 (Training algorithm of RBFNN)

由于线性模型存在未建模动态,往往会使控制精度不高,输出出现波动,为得到更好的控制效果,提高控制精度,采用图 1 具有最小二乘性质 RBFNN 来逼近线性模型未建模误差,这里使用高斯函数作为 RBFNN 的基函数.

$$z_i(t) = K(|\mathbf{x}(t) - \mathbf{s}_i|) = \exp\left[-\frac{\sum_{j=1}^N (x_j(t) - s_{i,j})^2}{2\alpha_i^2}\right], 1 \leq i \leq L,$$

$$\begin{aligned} y_j(t) &= \sum_{i=1}^L w_{j,i}(t) z_i(t) + \theta_j(t) = \\ &= \sum_{i=0}^L w_{j,i}(t) z_i(t) = \\ &= \mathbf{z}^T(t) \mathbf{w}_j(t), 1 \leq j \leq M, \end{aligned}$$

$$w_{j,0}(t) = \theta_j(t), z_0(t) = 1,$$

$$\mathbf{w}_j(t) = [w_{j,0}(t), \dots, w_{j,L}(t)]^T,$$

$$\mathbf{z}(t) = [z_0(t), \dots, z_L(t)]^T.$$

如图 1 所示, RBFNN 由三部分组成:输入层单元、隐层单元和输出层单元,隐层单元的径向基函数为高斯函数. RBFNN 的输入向量为 \mathbf{x} , 输出向量为 \mathbf{y} , 隐层单元的输出向量为 \mathbf{z} ; 隐层第 i 个单元的中心向量为 \mathbf{s}_i , 中心向量的控制参数向量为 α_i ; 输出层第 i 个单元与隐层单元的权值向量为 \mathbf{w}_i , 采用文[5]中给出的最小二乘递推算法在线学习权值 \mathbf{w}_i .

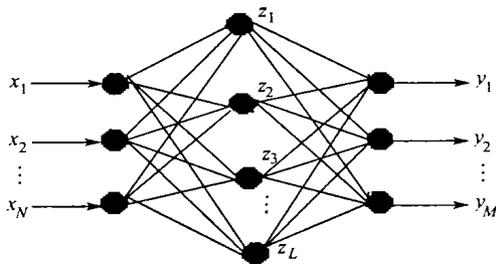


图 1 径向基函数神经网络

Fig. 1 The radial based function neural network

4 模型切换策略 (Switching function)

本文基于多模型的自适应控制器是通过在 N 个局部控制器之间切换来实现的. 在每个采样时刻, 根据切换指标函数判断哪一个模型为距离被控对象最近的模型, 当系统参数发生变化时, 根据指标切换函数输出, 使被控对象控制器自动切换到基于距离真实模型最近的局部模型而设计的控制器工作. 这是一种典型的硬切换策略.

为了确定每一时刻描述被控对象动态特性的最

佳局部模型, 设计如下具有积分性质的指标切换函数

$$J_i(k) = \sum_{j=1}^k \alpha(j)^{(k-j)} |y_i(k) - y^*(k)|. \quad (6)$$

其中, $y_i(k) (i = 1, 2, \dots, N)$ 为第 i 个模型的输出, $y^*(k)$ 为系统的理想输出, $0 < \alpha(j) < 1$ 为加权因子. 计算 $r(k) = \arg \min_{1 \leq i \leq N} J_i(k)$, $r(k)$ 即为 k 时刻所采用的局部模型. 由于采用了这种带有积分项的切换指标函数, 不仅切换方法简单, 而且易于实现.

每一时刻当切换函数决定了采用哪一个局部线性模型后, RBFNN 就与该线性模型相结合, 逼近此时真实系统的模型, 以进一步提高模型精度, 而其他局部模型均以线性化模型表示, 以此来计算这一时刻各局部模型的误差, 作为切换函数的输入项, 决定下一时刻所采用的局部模型. 由于采用了 RBFNN 来逼近当前所采用的线性模型的误差, 使得模型切换趋于稳定, 提高了模型切换的精度, 有效的解决了模型切换时的抖动问题. 从下面的仿真例子中可以得到验证, 尽管本文采用的是一种硬切换策略, 也能实现输出量的光滑平稳过渡. 此外, 这种方法只涉及到一个神经网络的学习和训练, 与每一个局部线性模型都附加一个 RBFNN 的方法相比较, 在输出的动态特性相同的前提下, 本文所提出的方法计算量小, 反应速度快.

5 仿真实例 (Simulation)

以连续搅拌的釜式反应器 (CSTR) 作为对象, CSTR 反应过程可由离散时间状态方程和输出方程来描述 (采样周期 $T = 0.2s$) [8]

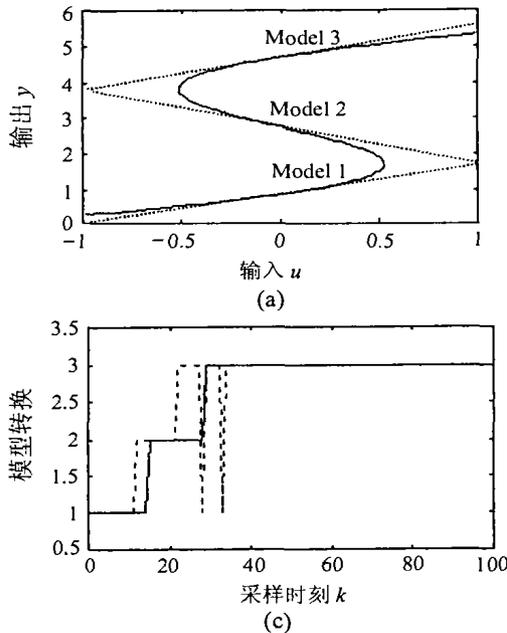
$$\begin{cases} x_1(k+1) = 0.8x_1(k) + 0.2D_a(1 - x_1(k)) \exp(x_2(k)/(1 + x_2(k)/\gamma)), \\ x_2(k+1) = 0.8x_2(k) + 0.2BD_a(1 - x_1(k)) \exp(x_2(k)/(1 + x_2(k)/\gamma)) + 0.2\beta(u(k) - x_2(k)). \end{cases}$$

其中, $y(k) = x_2(k)$, 状态变量 $x_1(k)$ 为生成物的浓度, $x_2(k)$ 为反应器的温度, 输入量 $u(k)$ 为反应器冷却装置的温度. 在一定的反应条件下, 取常量参数 $D_a = 0.072$, $\gamma = 20$, $B = 8$, $\beta = 0.3$. 由此可以看出, CSTR 系统是关联严重、非线性强的控制对象.

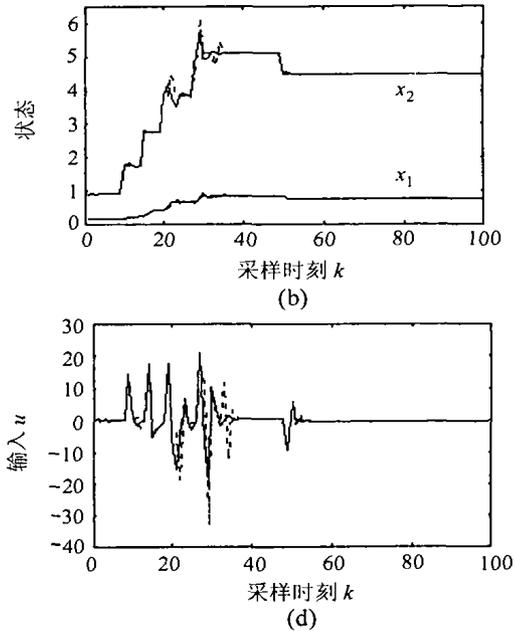
设仿真时间 $t = 100Ts$. 当 $t < 10T$ 时, $y^* = 0.8660$; 当 $10T \leq t < 15T$ 时, $y^* = 1.7518$; 当 $15T \leq t < 20T$ 时, $y^* = 2.7518$; 当 $20T \leq t < 28T$ 时, $y^* = 3.8518$; 当 $28T \leq t < 50T$ 时, $y^* = 5.1000$; 当 $50T \leq t < 100T$ 时, $y^* = 4.5000$. 用本文所提出的多模型自适应最小方差控制进行如下的仿真分析.

5.1 模型数相等时的仿真 (Simulation having the same number of local models)

$u = 0$ 时, 在系统的 3 个平衡点附近建立 3 个局部线性模型. 图 2 为模型数相等条件下, 本文所提出的方法与不加 RBFNN 逼近模型误差的最小方差



MMAC 的仿真结果. 图 2a 中, ——为 CSTR 系统真实的平衡点曲线,为局部线性模型的平衡点曲线. 图 2b 为最小方差控制下两种算法的状态输出比较. 图 2d 为最小方差控制下两种算法控制量的比较. 如图 2c 为控制过程中模型间的切换情况.



— 本文方法 ··· 不加 RBFNN 方法

图 2 模型数相等条件下的仿真结果

Fig. 2 Simulation with equal models

从仿真结果可以看出, 在所采用的线性模型个数相同的条件下, 当参考输出 y^* 发生大的跳变 $t = 20T, t = 28T$ 时, 本文所提出的方法的输出量和控制量都比不加 RBFNN 时产生的超调小, 不仅加快了动态响应速度, 同时也减少了模型间的切换.

5.2 参数时变时的仿真 (Simulation having time-varying parameters)

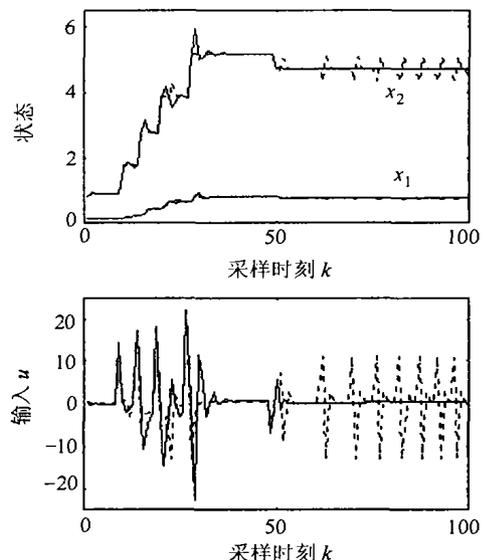
如图 3 所示, 在所采用的局部模型相同(同 5.1 所选取的 3 个模型)的条件下, 系统参数 β 随时间均匀由 0.28 变化为 0.34 时, 系统的状态输出与控制量的响应曲线. 从图 3 可以看出, 在 $50T \leq t < 100T$ 时, 没有在局部模型中加入 RBFNN 的算法使得模型间的切换频繁, 造成控制量的抖动较大; 而本文提出的方法的结果表明输出量平稳, 控制量没有跳变.

当其他系统参数(如 D_a, γ) 随时间发生变化时, 本文所提出的控制算法也能得到良好的控制效果.

6 结束语 (Conclusion)

本文通过在非线性系统的多个平衡点附近建立线性模型, 并用径向基函数神经网络逼近线性模型与非线性系统之间的模型误差, 建立了非线性系统的多模型表示. 应用最小方差的控制算法, 以及一种

具有积分性质的指标切换函数, 对实际工业中具有严重非线性的被控对象进行控制. 它有效的减少了局部模型个数, 降低了模型切换时的震荡, 提高了系统的鲁棒性与动态响应特性.



— 本文方法 ··· 不加 RBFNN 方法

图 3 参数时变时的仿真结果

Fig. 3 Simulation with time-varying parameters

参考文献(References)

- [1] Lainiotis D G. Optimal adaptive estimation structure and parameter adaptation [J]. IEEE Trans. Automat. Control, 1971, 13(2): 127 - 140
- [2] Middleton R H, Goodwin G C, Hilland D J, et al. Design issue in adaptive control [J]. IEEE Trans. Automat. Control, 1988, 40(1): 50 - 58
- [3] Narendra K S, Balakrishnan J. Adaptive control using multiple models [J]. IEEE Trans. Automat. Control, 1997, 42(2): 171 - 187
- [4] Xi Yugeng, Wang Fang. Multiple model based predictive control for nonlinear system [J]. Acta Automatica Sinica, 1996, 22(4): 456 - 460
- [5] Li Xiaoli, Wang Wei. Minimum variance based multi-model adaptive control [A]. Proc. of IFAC'99 [C], Beijing, 325 - 329
- [6] Al-Akhras M A, Aly G M, Green R J. Neural network learning approach of intelligent multi-model controller [J]. IEE Proc.-Control Theory and Application, 1996, 143(4): 395 - 400
- [7] Goodwin G C, Sin K S. Adaptive filtering, prediction and control [M]. Englewood Cliffs: Prentice Hall, 1984
- [8] Banerjee A, Arkun Y, Ogunnaike B, et al. Estimation of nonlinear system using linear multiple models [J]. AIChE Journal, 1997, 43(5): 1204 - 1226

本文作者简介

孙 维 1975 年生. 1997 年毕业于东北大学自动化专业. 1997 年 9 月在东北大学信息学院进行硕博连读学习. 现为博士研究生, 主要研究方向为多模型自适应控制, 计算机集成制造. Email: sunweibb@263.net

李晓理 1971 年生. 1994 年毕业于大连理工大学自动控制专业. 1997 年 3 月于大连理工大学获自动控制理论与应用专业硕士学位. 2000 年 3 月于东北大学获控制理论与控制工程专业博士学位. 目前为清华大学自动化系博士后. 主要研究方向为多模型自适应控制, 广义预测控制, 非线性系统辨识等.

王 伟 见本刊 2002 年第 2 期第 893 页.

(上接第 638 页)

4、用途

- 1) 发展高等教育、特别是研究生教育事业, 培养高层次科技人才;
- 2) 推进科技工作人员之间的学术交流, 促进学科建设和科研工作;
- 3) 建设国家基础知识设施和国家创新体系.

5、检索系统

- 1) 提供 CNKI 知识仓库分类导航与学科专业导航两套导航检索系统;
- 2) 提供关键词、中文题名、副题名、中文摘要、作者姓名、导师、全文、引文等基本检索功能;
- 3) 提供初级检索与高级检索两套检索界面, 支持二次检索、多种逻辑组合检索等专业检索功能;
- 4) 提供中文简体、中文繁体 and 英文检索三种检索界面, 支持中英文对照和中文简繁对照检索;
- 5) 提供论文全文的在线浏览、全文下载、保存、打印等功能, 提供摘录功能.

6、使用方式

- 1、网上包库服务(WEB 方式): 读者直接登录 CNKI 数据库交换服务中心网站(全国共有 10 个)进行检索;
- 2、镜像站点方式: 将 CDMD 数据库系统安装到用户单位的内部网络服务器上, 读者在内部网上进行检索;
- 3、全文光盘方式: 将 CDMD 全文光盘(DVD 格式)安装在本单位的计算机或局域网上使用.

7、更新周期

CNKI 数据库交换服务中心网站数据每日更新, 镜像站点通过互联网或卫星每日更新, 光盘每半年出版一期.

8、软件环境

用户端: Window 95/98/ME/2000/NT/XP 服务器端: Window 2000/NT/XP

愿 CDMD 成为您科研和教学的好帮手. 希望社会各界共同关心中国知识基础设施工程(简称 CNKI 工程), 对我们的产品和服务提出宝贵的意见和建议.

全国免费咨询热线: 8008100946

地址: 北京清华大学毕业大厦 1300 室

通信地址: 北京清华大学 84-48 信箱 邮编: 100084

联系人: 张莉 联系电话: 010-62791829/30/31 E-mail: qklw@cnki.net

详情请访问: CNKI 电信全国中心 <http://www.cnki.net/> CNKI 教育全国中心 <http://www.edu.cnki.net/>