

文章编号: 1000-8152(2008)04-0677-06

非线性系统的自组织多模型自适应逆控制

高大远^{1,2}, 沈 辉², 胡德文²

(1. 海军潜艇学院 航海观通系, 山东 青岛 266071; 2. 国防科技大学 机电工程与自动化学院, 湖南 长沙 410073)

摘要: 针对离散时间非线性系统, 在分析基于自组织映射神经网络的多模型控制方法的基础上, 提出了一种自组织多模型直接逆控制方法, 并分析了控制误差的有界性. 进一步, 借鉴参数空间多模型方法的切换-自适应策略, 在固定模型的基础上增加一个参数可调节的自适应逆模型, 提高了稳态控制性能. 仿真实例表明, 对于变化较快的信号, 自组织多模型直接逆控制器和自组织多模型自适应逆控制器都能进行有界跟踪, 对于稳态信号, 自组织多模型自适应逆控制器还能进行渐近跟踪.

关键词: 多模型控制; 自组织映射; 神经网络; 逆控制; 自适应控制

中图分类号: TP183 **文献标识码:** A

Multiple models adaptive inverse control based on self-organizing map for nonlinear system

GAO Da-yuan^{1,2}, SHEN Hui², HU De-wen²

(1. Department of Navigation and Communication, Navy Submarine Academy, Qingdao Shandong 266071, China;
2. College of Mechatronics and Automation, National University of Defense Technology, Changsha Hunan 410073, China)

Abstract: An inverse control method is proposed based on multiple models using self-organizing map neural network. The boundedness of the controlled output error is proven. Furthermore, the idea of multiple-model adaptive control in parameter space is introduced. One more adaptive inverse model is added to the fixed multiple models to improve the performance of the control system. The simulation example illustrates the proposed method.

Key words: multiple models; self-organizing map; neural network; inverse control; adaptive control

1 引言(Introduction)

近年来, 多模型控制方法得到迅速发展, 其基本思想是利用多个模型对动态特性变化较大的系统进行控制, 多个控制器覆盖了可能出现的多个动态特性. 其中最突出的工作由Yale大学的Narendra教授领导的研究小组开展. 为改善自适应控制器的过渡过程响应性能, 提出了一套基于多模型切换的自适应控制策略^[1], 经过不断演化, 最终形成了一种具有“ $N + 2$ ”个模型的切换-自适应控制结构^[2]. 此方法的特点是在参数空间建立多个(N 个)固定的线性模型以覆盖可能的参数分布情况, 并且有一个可重新初始化的自适应模型和一个自由自适应模型. 当系统参数发生跳变, 根据性能指标, 系统切换到最合适的模型, 同时可重新初始化的自适应模型也切换到此模型并重新开始自适应, 而自由自适应模型只进行参数自适应而不做任何切换. 这样, 切换策略

保证系统的过渡过程性能, 而自适应策略保证系统的稳态性能. 目前, 这一控制方法已扩展到随机系统^[3,4]和非线性系统控制. 在国内, 王伟教授领导的研究小组在这方面的工作取得了丰富的成果^[5,6].

但是对于一般的非线性系统而言, 这种多模型控制器的效果并不理想. 因为对于非线性系统而言, 即使参数不发生变化, 线性系统也难以对它进行逼近. 并且, 对于同样的性能指标, 一个非线性模型也可能对应于多种不同的线性参数模型. 因此, 对于较复杂的非线性系统而言, 还只能采取与其它方法(如神经网络)相结合的方式控制^[7].

对于非线性系统而言, 采用多个模型在状态空间进行分而治之的控制策略, 则要直接的多. Matinetz等采用自组织映射(self-organizing map, SOM)神经网络划分工作空间, 在机器人手眼协调控制过程中用多个局部线性模型逼近机械手的逆运

收稿日期: 2006-08-26; 收修改稿日期: 2007-06-18.

基金项目: 国家自然科学基金重点资助项目(60234030); 国家杰出青年科学基金资助项目(60225015); 高等学校优秀青年教师教学科研奖励计划项目.

动学^[8],得到了较好的控制精度.王正志等改进他们的方法,加快了SOM收敛的速度^[9].Principe等用多模型对混沌时间序列进行局部动态建模,并用来对时间序列进行预测^[10],研究表明,用基于SOM的多模型方法所得到的预测精度高于采用多层前向神经网络进行全局建模所得到的预测精度.在进一步的工作中,他们还将此方法用于跨音速风洞的预测控制^[11]以及无人驾驶飞机的建模与控制器设计^[12],取得了较好的结果.

虽然基于SOM的自组织多模型控制方法已有较多应用,但是其性能并没有得到深入分析.本文研究自组织多模型逆控制方法.首先给出一般的自组织多模型逆控制方法,并分析其优缺点;然后提出一种自组织多模型直接逆控制方法,并分析此方法控制误差的有界性;在此基础上,借鉴关于时变线性系统的切换-自适应控制策略,通过增加一个参数可调节的自适应逆模型,提高控制系统的稳态性能.最后通过仿真例子对方法进行说明.

2 自组织多模型逆控制方法(Multiple models inverse control based on SOM)

2.1 自组织映射神经网络(Self-organizing map neural network)

SOM神经网络由芬兰学者T. Kohonen教授提出^[13],它模拟生物神经系统的自组织形成过程,通过竞争和侧抑制机制调节各个神经元,使得网络能够正确的划分输入空间并反映出输入信号之间的相互关系以及分布特征,还能够正确的映射出输入空间内在的拓扑关系和结构.

一个基本的SOM神经网络有 n 个输入节点,对应于 n 维输入数据,神经元节点个数为 N ,这些神经元节点相互之间连接,构成了规则的网格,常用的是四边形或六边形,也可以是其他形状.对每一个神经元节点 j ,各有一个参考向量 $\omega_j = [\omega_{j1}, \omega_{j2}, \dots, \omega_{jn}]^T$ 与之对应,表示此节点在输入空间中的位置.SOM的学习是一个无监督的自组织学习过程,可以实现从高维空间到低维空间的拓扑保持特征映射,并且网络节点的分布密度反映所映射区域的样本数据分布密度大小.它已经在语音和图像识别、数据可视化、非线性系统控制等许多领域得到成功应用.

2.2 一般的自组织多模型逆控制方法(General multiple models inverse control based on SOM)

考虑一个SISO非线性系统:

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

$$\begin{aligned} \psi_y(k) &\triangleq [y(k), y(k-1), \dots, y(k-n_y+1)]^T \in \\ &D_y \subset \mathbb{R}^{n_y}, \end{aligned}$$

$$\begin{aligned} \psi_u(k) &\triangleq [u(k), u(k-1), \dots, u(k-n_u+1)]^T \in \\ &D_u \subset \mathbb{R}^{n_u}, \end{aligned}$$

$$\psi(k) = [\psi_y(k), \psi_u(k)]^T \in D_\psi = D_y \times D_u,$$

则系统写为

$$y(k+d) = f(\psi_y(k), \psi_u(k)) = f(\psi(k)).$$

问题是设计 $u(k)$ 使得 $y(k)$ 跟踪期望输出 $y_d(k)$.

一般的自组织多模型控制方法结构图如图1所示^[13].

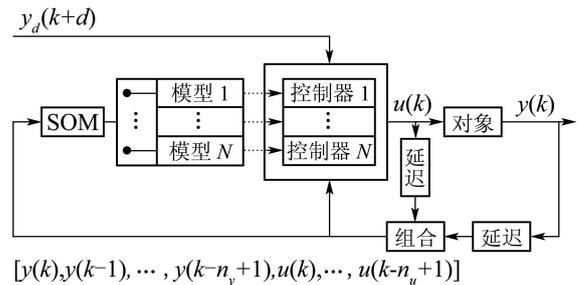


图1 自组织多模型逆控制结构

Fig. 1 Multiple models inverse control based on SOM

先利用 D_ψ 中的样本数据 $\psi(k)$ 对SOM进行训练,所得神经网络利用其神经元节点分布将 D_ψ 划分为多个局部区域 D_{ψ_i} , $i = 1, 2, \dots, N$.对应于每个神经元节点,构造一个模型(一般是线性模型),这相当于在每一个局部区域内建立局部模型.其结构为

$$\begin{aligned} M_i : y(k+d) &= \sum_{j=0}^{n_y-1} a_j^i y(k-j) + \sum_{j=0}^{n_u-1} b_j^i u(k-j), \\ \psi(k) &\in D_{\psi_i}, \end{aligned} \quad (2)$$

其中的参数可以通过最小二乘方法得到.根据局部模型(2),构造逆控制器 IC_i :

$$\begin{aligned} u(k) &= \frac{1}{b_0^i} [y_d(k+d) - \sum_{j=0}^{n_y-1} a_j^i y(k-j) - \\ &\sum_{j=1}^{n_u-1} b_j^i u(k-j)], \end{aligned} \quad (3)$$

则SOM连同局部模型和逆控制器,构成了系统的自组织多模型逆控制器.假设在 k 时刻,已知 $k+d$ 时刻的期望值 $y_d(k+d)$,控制过程如下.首先,根据当前的系统状态 $\psi(k)$,由SOM的输出(获胜神经元节点)选择局部模型 M_i ,然后根据此模型,由相应的逆控制器 IC_i ,就可以根据式(3)计算期望的控制输出 $u(k)$.

在此控制结构中,使用SOM的作用有两个,在建立局部模型时,SOM根据其神经元节点分布自动的划分出局部区域;在控制过程中,SOM根据其对应

前系统状态的响应输出(获胜节点)对控制器进行切换. 如果增加神经元节点的数目, 其划分的局部区域越细, 从而用线性模型逼近非线性对象的误差就越小, 控制精度也可以达到更高的水平.

此控制方法的问题在于, 在选择局部模型的时候, 需要 ψ_y 和 ψ_u 的信息, 而此时 $u(k)$ 是未知的, 因此无法直接利用 ψ_u 进行选择. 另一个问题是, 在式(3)中, 如果 b_0^i 过小, 会使得控制输出对误差敏感. 这两个问题在其他神经网络逆控制方法中也存在. 文献[12]采用如图1的控制结构, 但是, 其训练SOM和选择局部模型时只利用 $\psi_y(k)$ 作为神经网络的输入, 这样一种方法实际上是假设局部模型的参数只与 $\psi_y(k)$ 有关, 因此它只适用于类似于

$$y(k+d) = f(\psi_y(k)) + \sum_{i=0}^{n_u-1} g_i(\psi_y(k))u(k-i) \quad (4)$$

的一类仿射结构的非线性系统, 对于一般的系统而言, 采用这种方法会出现较大的误差.

3 自组织多模型直接逆控制方法(Multiple models direct inverse control based on SOM)

前面所述的方法实际上是一种间接的逆控制方法, 逆控制器根据局部模型设计, 因此, 控制器的性能与局部模型的逼近精度直接相关, 而且受到系数 b_0^i 的影响. 为了避免这些问题, 考虑如图2所示的自组织多模型直接逆控制结构.

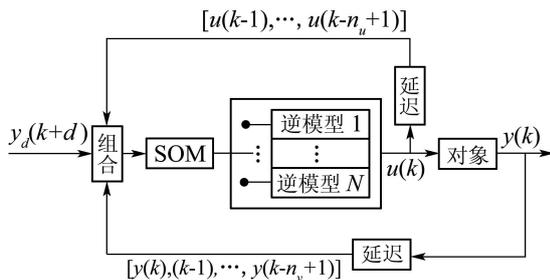


图 2 自组织多模型逆控制结构

Fig. 2 Multiple models direct inverse control based on SOM

在这种结构中, SOM的输入为

$$\psi'(k) \triangleq [y_d(k+d), y(k), \dots, y(k-n_y+1), u(k-1), \dots, u(k-n_u+1)]^T. \quad (5)$$

对应于每一个神经元, 构造局部逆模型 IM_i :

$$u(k) = a_{pd}^i y_d(k+d) + \sum_{j=0}^{n_y-1} a_j^i y(k-j) + \sum_{j=1}^{n_u-1} b_j^i u(k-j) + d^i. \quad (6)$$

其中参数可以由相应局部区域内的样本数据用最小二乘法辨识得到. 局部逆模型构造完毕后, 就可以直接用来对原系统进行控制. 假设在 k 时刻, 已知 $k+d$ 时刻的输出期望值 $y_d(k+d)$, 则由此值和当

前已知的输入输出信息构成SOM的输入式(5), 根据获胜节点选择局部逆控制器 IM_i , 式(6)作用于这些输入即得到控制器输出.

从这个过程可以看到, 局部控制器实际上是用逆模型来充当的, 这样做的好处是用于选择获胜节点的信息都是当前已知的, 并未使用未知的 $u(k)$, 使得控制器不仅能使用于如式(4)的仿射结构系统, 还能适用于如式(1)的一般非线性系统. 下面说明, 对于一般的非线性系统, 这个方法可以得到一个有界的跟踪误差.

对于非线性系统(1), 假设 $f(\cdot)$ 在紧集 D_ψ 上连续, 且对 $u(k)$ 满足Lipschitz条件, 即对

$$\begin{aligned} \psi_1(k) &= [\psi_y(k), u_1(k), u(k-1), \dots, u(k-n_u+1)]^T, \\ \psi_2(k) &= [\psi_y(k), u_2(k), u(k-1), \dots, u(k-n_u+1)]^T, \end{aligned}$$

有

$$\|f(\psi_1(k)) - f(\psi_2(k))\| \leq L \|u_1(k) - u_2(k)\|. \quad (7)$$

其中 $L > 0$, 且对于 $y_d(k+d)$ 存在 $u_d(k)$ 使得

$$\begin{aligned} y_d(k+d) &= f(y(k), \dots, y(k-n_y+1), \\ &u_d(k), \dots, u(k-n_u+1)) \end{aligned}$$

成立. 假设经过训练的SOM神经网络已将工作空间 D'_ψ 划分成多个局部区域 D'_{ψ_i} . 这里需要注意的是, 在此方法中, 工作空间 D'_ψ 和其中的局部区域 D'_{ψ_i} 是指 $[y(k+d), y(k), \dots, y(k-n_y+1), u(k-1), \dots, u(k-n_u+1)]$ 在其中分布的空间, 而不是 D_ψ . 在每一个局部区域内, 逆模型对原系统的逆动力学逼近有界, 即在区域 D'_{ψ_i} 内有

$$\|u_s(k) - u_d(k)\| \leq u_b^i. \quad (8)$$

其中 $u_s(k)$ 由式(6)计算, 即

$$u_s(k) = a_{pd}^i y_d(k+d) + \sum_{j=0}^{n_y-1} a_j^i y(k-j) + \sum_{j=1}^{n_u-1} b_j^i u(k-j) + d^i,$$

则在 $u_s(k)$ 作用下, 系统输出为

$$\begin{aligned} y(k+d) &= f(y(k), \dots, u_s(k), \dots, u(k-n_u+1)) = \\ &y_d(k+d) + [f(\dots, u_s(k), \dots) - \\ &f(\dots, u_d(k), \dots)]. \end{aligned}$$

而由式(7)和式(8), 有

$$\|y(k+d) - y_d(k+d)\| \leq L b_u^i.$$

从而在工作空间 D'_ψ 内, 有

$$\|y(k+d) - y_d(k+d)\| \leq L b_u.$$

其中 $b_u = \max_{i=1, \dots, N} \{b_u^i\}$ 为在所有局部区域内逼近误差的最大值, 因此在工作空间 D'_ψ 内, 系统的跟踪误差有界.

如果增加神经元节点的数目, 细化局部区域的划分, 则每一个局部区域上的逼近误差界 b_u^i 变小, 从而总的控制误差界也可以变小.

在上面的方法中, 有几个方面值得注意:

1) 逆控制器是直接由原系统的逆模型得到, 这样, 只要神经网络选择恰当, 就可以直接保证系统输出与期望输出误差的界, 而不像前节那样需要由原系统的逼近模型来决定并且还受到系数的影响.

2) 如果将SOM与局部逆模型看成一个整体, 则它们的功能可以由一个前向神经网络来取代, 这也是神经网络逆控制的一般结构, 但是, 文献[14]指出, 对于那些相对度没有适当定义的系统或者零动态不稳定的系统, 采用传统的连续前向神经网络逆控制器并不能得到有效的控制. 而采用本节的方法则不存在这样的问题, 因为, 由此得到的逆控制器是不连续(而是分段连续)的, 并不受到这一条件的约束.

3) 与式(2)不同, 在每一个局部逆模型中都带有一个常数项, 采用这种一般形式的线性逆模型是为了更好的逼近原系统. 因为原系统并不是在每一个局部区域内都有平衡点, 因此不能按照在平衡点附近展开那样的形式建立局部模型, 而是要采用更加一般的线性模型.

4 自组织多模型自适应逆控制方法(Multiple models adaptive inverse control based on SOM)

前一节中, 给出了自组织多模型直接逆控制器的结构和方法, 对于非线性系统来说, 它能保证系统跟踪误差的有界性, 一般来说, 模型越多, 误差越小, 但是不能完全消除. 对于动态信号来说, 笔者希望保证误差的有界性, 而对于稳态信号来说, 笔者希望系统的误差是渐近稳定的. 这一点, 由于上面的方法只有局部控制器的切换而无控制器的调节, 因此无法保证系统对稳态信号的渐近跟踪.

这里借鉴针对线性时变系统的多模型切换-自适应控制策略^[2], 提出一种带切换和自适应的多模型自适应逆控制方法. 其结构如图3所示.

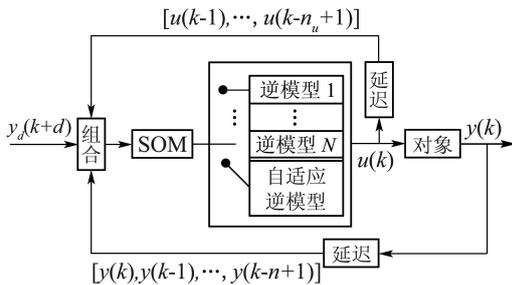


图3 自组织多模型自适应逆控制结构
Fig. 3 Multiple models adaptive inverse control based on SOM

与图2相比, 图3的控制结构在它的基础上增加了一个可调节的自适应逆模型 IM_{N+1} . 在每一次通过SOM选定局部逆控制器 IM_i 后, 如果新选定的逆控制器与前一步不一致, 则采用新选定的局部逆控制器进行控制, 同时, IM_{N+1} 的参数也切换到新的控制器; 如果新选定的逆控制器与前一步一致, 则采用 IM_{N+1} 进行控制, 并且 IM_{N+1} 的参数根据控制误差进行调节, 直到新的神经元被选中. 也就是说, 如果系统的状态一直在某一个局部区域内, 则采用 IM_{N+1} 进行控制, 并且其参数根据输出跟踪误差调节; 如果状态进入新的局部区域, 则切换到新的控制器. 参数的调节方法可以是任何合适的方法, 下面给出一种常用的自适应调节方法^[15]. 与式(6)类似, 令 IM_{N+1} 的结构为

$$u_{ad}(k) = \gamma_{pd}y_d(k+d) + \sum_{i=1}^{n_y-1} \gamma_i y(k-i) + \sum_{i=1}^{n_u-1} \eta_i u(k-i) + d_a \triangleq [\gamma^T, \eta^T, d_a] \begin{bmatrix} \psi'_y(k) \\ \psi'_u(k) \\ 1 \end{bmatrix} \triangleq \theta^T \begin{bmatrix} \psi'(k) \\ 1 \end{bmatrix},$$

则参数 θ 的调节应使得控制误差减小, 令

$$J(k) = [y(k+d) - y_d(k+d)]^2 \triangleq e(k)^2,$$

则应有

$$\theta(k+1) = \theta(k) - \alpha \frac{\partial J(k)}{\partial \theta},$$

其中 $\alpha > 0$ 是学习速率. 而

$$\frac{\partial J(k)}{\partial \theta(k)} = 2e(k) \frac{\partial y(k+d)}{\partial \theta(k)} = 2e(k) \frac{\partial y(k+d)}{\partial u_{ad}(k)} \cdot \frac{\partial u_{ad}(k)}{\partial \theta(k)}.$$

由于假设系统对 $u(k)$ 是 Lipschitz 的, 因此导数有界, 令

$$\frac{\partial y(k+d)}{\partial u_{ad}(k)} = b \leq L,$$

并且有

$$\frac{\partial u_{ad}(k)}{\partial \theta(k)} = \begin{bmatrix} \psi'(k) \\ 1 \end{bmatrix},$$

因此可得

$$\theta(k+1) = \theta(k) - 2\alpha b e(k) \begin{bmatrix} \psi'(k) \\ 1 \end{bmatrix}.$$

考虑到学习速率 α 的作用, b 的具体值并不是笔者所关心的, 可以将 αb 用 α 代替, 所以

$$\theta(k+1) = \theta(k) - 2\alpha e(k) \begin{bmatrix} \psi'(k) \\ 1 \end{bmatrix}.$$

这种控制结构的好处在于, 当非线性系统变化较快时, 状态快速的在不同的局部区域之间变化, 相应的切换不同的逆控制器, 以保证系统对快速变化信号跟踪误差的有界性, 当状态在某一个区域停留较长时间时, 可以认为此时系统动态特性变化较小, 采用自适应控制器以使跟踪误差逐渐减小. 与参数空间中的方法相比, 由于此方法直接对系统的状态空间而不是参数空间进行划分, 因此能够更好的对非线性系统进行控制.

5 仿真实例(Simulation example)

考虑一个常用的非线性系统例子:

$$y(k+1) = \frac{y(k)}{1+y^2(k)} + u^3(k),$$

分别利用第2节到第4节所描述和提出的方法(分别称为方法1,2,3)进行控制.

首先, 建立SOM神经网络. 以 $[-2, 2]$ 区间内的随机信号为输入, 得到系统输出, 并构成训练样本. 为了进行比较, 3种方法均采用具有25个神经元节点的SOM.

对于方法1, 以 $y(k)$ 为输入训练SOM, 得到一维神经网络, 局部线性模型为 $y(k+1) = a_j y(k) + b_j u(k)$, $j = 1, 2, \dots, 25$, 根据模型所设计的逆控制器为 $u = \frac{1}{b_j} [y_d(k+1) - a_j y(k)]$.

对于方法2, 以 $[y(k+1), y(k)]$ 为输入训练一个 5×5 的二维SOM, 得到神经网络如图4所示, 局部逆控制器为 $u(k) = a_j y_d(k+1) + b_j y(k+1) + d_j$.

对于方法3, 在方法2的基础上增加一个参数可调节的逆控制器 $u_a(k) = a_a y(k+1) + b_a y(k) + d_a$, 其参数调节的学习速率为 $\alpha = 0.01$.

用两种测试信号, 一种由正弦信号叠加得到

$$y_d(k) = 2 \sin\left(\frac{2\pi k}{25}\right) + 3 \cos\left(\frac{2\pi k}{15}\right).$$

另一个是分段常数信号. 分别测试控制器对快速变化信号以及稳态信号的控制精度. 仿真结果如图5和图6所示.

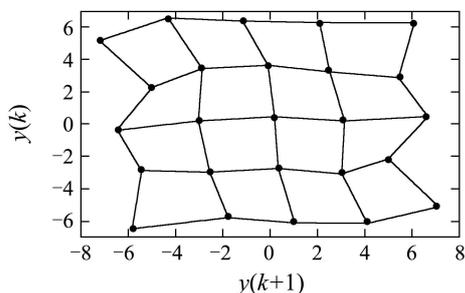
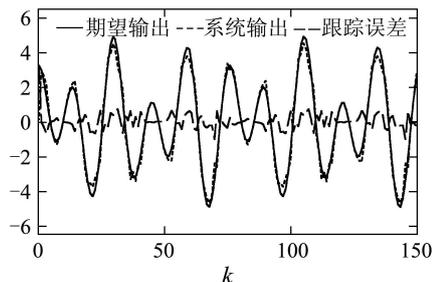
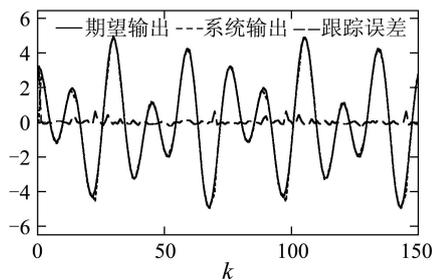


图4 二维SOM神经元分布图

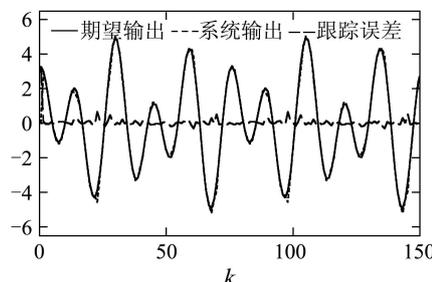
Fig. 4 The nodes distribution of 2-dimensional SOM



(a) 一般自组织多模型方法



(b) 自组织多模型直接逆方法

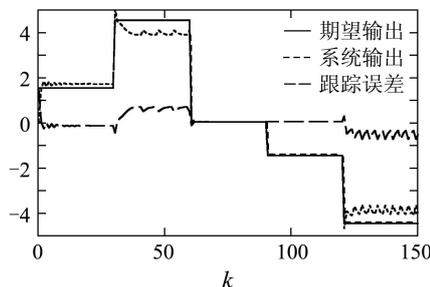


(c) 自组织多模型自适应逆方法

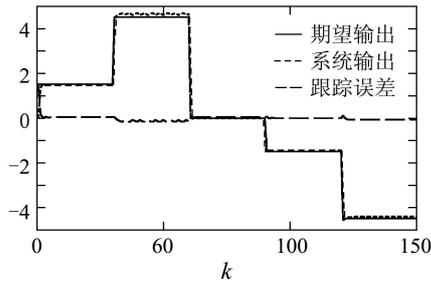
图5 对正弦信号的跟踪曲线

Fig. 5 Output response for the sinusoidal signal

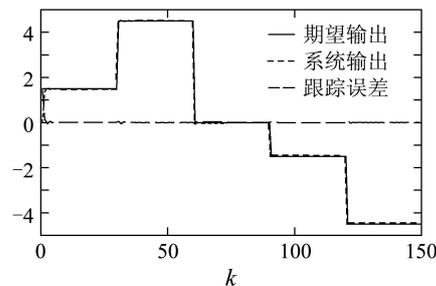
从仿真结果可以看出, 由于采用了更加合理的控制器结构, 方法2和3的控制效果明显好于方法1的效果. 对于正弦信号, 每一个方法都能保证系统输出误差有界, 方法1的误差较大, 而方法2和3对此信号的跟踪效果相当. 对于分段常数信号, 方法1存在较大的稳态误差和振荡, 方法2的效果明显改善, 但还是存在稳态误差, 而方法3由于采用了自适应控制器, 使得每次发生切换后稳态误差很快趋近于零.



(a) 一般自组织多模型方法



(b) 自组织多模型直接逆方法



(c) 自组织多模型自适应逆方法

图6 对分段常数信号的跟踪曲线

Fig. 6 Output response for the piecewise constant signal

6 结论(Conclusions)

基于参数空间建模的多模型切换-自适应控制方法对时变线性系统的控制有很好的结果,而基于SOM神经网络的自组织多模型控制方法对非线性系统的控制更加直接.本文针对传统自组织多模型控制方法对误差敏感、模型选择困难等问题,提出了一种自组织多模型直接逆控制器结构,并证明了其控制误差的有界性.进一步,借鉴参数空间中多模型控制方法的切换-自适应策略,将二者的优点结合起来,改进了自组织多模型逆控制器的效果.

参考文献(References):

- [1] NARENDRA K S, BALAKRISHNAN J. Improving transient response of adaptive control system using multiple models and switching[J]. *IEEE Transactions on Automatic Control*, 1994, 39(9): 1861 – 1866.
- [2] NARENDRA K S, BALAKRISHNAN J. Adaptive control using multiple models[J]. *IEEE Transactions on Automatic Control*, 1997, 42(2): 171 – 187.
- [3] NARENDRA K S, CHEN X. Adaptive control of discrete-time system using multiple models[J]. *IEEE Transactions on Automatic Control*, 2000, 45(9): 1669 – 1686.

- [4] NARENDRA K S, DRIOLLET O A. Stochastic adaptive control using multiple estimation models[C] // *Proceedings of the American Control Conference*. Arlington: IEEE Press, 2001: 1539 – 1544.
- [5] 李晓理, 王伟. 输入受限系统的多模型自适应控制[J]. *控制理论与应用*, 2000, 17(6): 889 – 893.
(LI Xiaoli, WANG Wei. Multiple models adaptive control of input constrained system [J]. *Control Theory & Applications*, 2000, 17(6): 889 – 893.)
- [6] 李晓理, 张维存, 王伟. 基于有界扰动分区的多模型自适应控制[J]. *控制理论与应用*, 2006, 23(2): 283 – 286.
(LI Xiaoli, ZHANG Weicun, WANG Wei. Multiple models adaptive control based on the divided scope of bounded disturbance[J]. *Control Theory & Application*, 2006, 23(2): 283 – 286.)
- [7] CHEN L J, NARENDRA K S. Intelligent control using neural networks and multiple models[C] // *Proceedings of the 41st IEEE Conference on Decision and Control*. Las Vegas: IEEE Press, 2002: 1357 – 1362.
- [8] MATINETZ T M, RITTER H J, SCHULTEN K J. Three-dimensional neural net for learning visumotor coordination of a robot arm[J]. *IEEE Transactions on Neural Networks*, 1990, 1(1): 131 – 136.
- [9] 王正志, 周宗潭. M.R.S.自组织三维神经网络的改进及其在机器人控制中的应用[J]. *自动化学报*, 1992, 18(1): 9 – 14.
(WANG Zhengzhi, ZHOU Zongtan. Improvement of the M.R.S. three dimensional self-organizing map neural network and its application in robot control[J]. *Acta Automatica Sinica*, 1992, 18(1): 9 – 14.)
- [10] PRINCIPE J C, WANG L D. Non-linear time series modeling with self-organizing feature maps[C] // *IEEE Workshop on Neural Network for Signal Processing*. Piscataway, NJ: IEEE Service Center, 1995: 11 – 20.
- [11] MOTTER M A, PRINCIPE J C. Predictive multiple model switching control with the self-organizing map[J]. *International Journal of Robust and Nonlinear Control*, 2002, 17(12): 1029 – 1051.
- [12] CHO J, PRINCIPE J C, ERDOGMUS D, et al. Modeling and inverse controller design for an unmanned aerial vehicle based on the self-organizing map[J]. *IEEE Transactions on Neural Networks*, 2006, 17(2): 445 – 460.
- [13] KOHONEN T. *Self-Organizing Maps*[M]. 2nd ed. Berlin: Springer-Verlag, 1997.
- [14] CABRERA J B D, NARENDRA K S. Issues in the Application of neural networks for tracking based on inverse control[J]. *IEEE Transactions on Automatic Control*, 1999, 44(11): 2007 – 2027.
- [15] ÅSTRÖM K J, WITTENMARK B. *Adaptive Control*[M]. 2nd ed. Beijing: Science Press, 2003.

作者简介:

高大远 (1978—), 男, 博士, 讲师, 主要研究方向为非线性控制、神经网络控制、惯性导航技术, E-mail: dygao@nudt.edu.cn或dygao@263.net;

沈辉 (1975—), 男, 博士, 副教授, 研究方向为机器人控制、神经网络控制与辨识等;

胡德文 (1963—), 男, 教授, 博士生导师, 从事系统辨识、神经网络、脑功能成像分析等研究, E-mail: dwu@nudt.edu.cn.