

PID 神经网络混沌优化及其在机械臂轨迹跟踪控制中的应用

张秀玲^{1,2}, 李晓辉¹, 徐 腾¹, 赵 亮¹, 樊红敏¹, 臧佳音¹

(1. 燕山大学 河北省工业计算机控制工程重点实验室, 河北 秦皇岛 066004;

2. 国家冷轧板带装备及工艺工程技术研究中心, 河北 秦皇岛 066004)

摘 要:针对 BP 优化 PID 神经网络(BP-PDNN)易陷入局部极小的不足,提出了一种变尺度混沌优化 PID 神经网络设计方法,即 MSCOA-PIDNN,将其应用于机械臂轨迹跟踪控制中。利用混沌运动的遍历性优化网络权值,通过压缩优化变量取值区间提高搜索效率。采用 MSCOA-PIDNN 建立机械臂系统的预测模型,以多步预测性能指标为目标函数,优化 PID 神经网络控制器,从而实现机械臂系统轨迹跟踪的有效控制。仿真结果表明, MSCOA-PIDNN 在机械臂轨迹跟踪控制中性能优于 BP-PIDNN。

关键词:混沌优化;PID 神经网络;机械臂;轨迹跟踪;预测控制

中图分类号: TP273

文献标志码: A

文章编号: 1672-3767(2013)05-0084-06

Chaos Optimization of PID Neural Network and Its Application in the Trajectory Tracking Control of Manipulator

Zhang Xiuling^{1,2}, Li Xiaohui¹, Xu Teng¹, Zhao Liang¹, Fan Hongmin¹, Zang Jiayin¹

(1. Key Laboratory of Industrial Computer Control Engineering of Hebei Province, Yanshan University, Qinhuangdao, Hebei 066004, China; 2. National Engineering Research Center for Equipment and Technology of Cold Strip Rolling, Qinhuangdao, Hebei 066004, China)

Abstract: Aiming at the defects of PID neural network optimized by BP algorithm, a kind of PID neural network training method based on mutative scale chaos optimization algorithm (MSCOA) is proposed and applied in manipulator trajectory tracking control. The neural network weights can be optimized by making use of the ergodicity of chaos, and the search efficiency can be increased through narrowing solution space. Through establishing the predictive model of manipulator by utilizing MSCOA-PIDNN, and by using the multi-step predictive objective function to train the weights of PIDNN controller, manipulator trajectory tracking prediction control can be realized. The simulation results show that the performances of MSCOA-PIDNN are better than those of BP-PIDNN in manipulator trajectory tracking control.

Key words: chaos optimization; PID neural network; manipulator; trajectory tracking; predictive control

神经网络具有强大的学习能力和并行分布式结构,能够充分逼近任意复杂的非线性关系,并具有较强的鲁棒性和容错性,在控制领域得到广泛应用。PIDNN^[1](proportion integral derivative neural network)是一种新的动态神经网络,具有结构简单、规范等优点^[2-3]。采用 BP(back propagation)算法优化网络权值易陷入局部极小^[4],所以必须改进网络权值优化算法。混沌运动具有遍历性、随机性和规律性,能在自身的范围内不重复地遍历所有状态^[5-6]。利用变尺度混沌算法(MSCOA, mutative scale chaos optimization algo-

收稿日期: 2013-04-10

基金项目: 国家自然科学基金项目(50675186)

作者简介: 张秀玲(1968—),女,山东章丘人,教授,博士,主要从事神经网络智能控制研究。E-mail: zxllysu@ysu.edu.cn

rithm)优化,不依赖混沌状态的初值和目标函数的梯度信息,可实现全局优化^[7-8]。利用 MSCOA 优化 PIDNN 可有效解决 BP 算法收敛速度慢、易陷入局部极小等不足。

神经网络在机械臂轨迹跟踪控制中得到了广泛的应用,而目前对机械臂神经网络逆控制的研究相对较少^[9]。靳其兵等^[10]针对非线性系统,提出了多步预测性能指标下的神经网络逆动态控制方法,使整个系统具有预测控制的特点。把预测控制的思想 and 神经网络逆动态控制的思想结合起来,用多步预测性能指标函数去训练神经网络逆动态控制器的权值,具有逆动态控制和预测控制两者的优势^[10-12]。

本研究提出 MSCOA-PIDNN 并将其应用于机械臂轨迹跟踪控制中。MSCOA-PIDNN 不依赖于被控对象的精确数学模型,具有鲁棒性和容错性,且在一定程度上解决了神经网络预测控制中神经网络模型结构选取困难和学习算法计算量大、易陷入局部极小等问题。通过建立被控对象预测模型,利用多步预测性能指标函数优化神经网络逆控制器,对机械臂系统进行轨迹跟踪控制,达到了良好控制效果。

1 基于 MSCOA 的 PIDNN 优化设计

1.1 多输出 PIDNN 结构及工作原理

单 PIDNN 的基本形式为 $2 \times 3 \times 1$ 结构,如图 1 中虚框部分所示,包括输入层的 2 个神经元、隐层的 3 个神经元、输出层的 1 个神经元。多个单 PIDNN 子网交叉并联构成多输出 PIDNN (Multi-PIDNN, MPIDNN),结构如图 1 所示。

MPIDNN 的权值优化通常以使网络目标函数 J 最小为目的,而 J 可由网络输出经相应计算得到,所以首先需要了解 MPIDNN 的工作原理。MPIDNN 在采样时刻 k 的前向计算过程如下。

设输入层神经元的输入为 $net_{si}(k)$,则神经元输出为 $x_{si}(k) = net_{si}(k)$ 。 (1)
其中: s 为子网的序号 ($s = 1, 2, \dots, n$); i 为子网输入层序号 ($i = 1, 2$)。

隐含层各神经元的输入为 $net'_{sj}(k) = \sum_{i=1}^2 \omega_{sij}(k)x_{si}(k)$ 。 (2)

隐含层有 3 种神经元,比例元输出为 $x'_{s1}(k) = net'_{s1}(k)$; (3)

积分元的输出为 $x'_{s2}(k) = x'_{s2}(k-1) + net'_{s2}(k)$; (4)

微分元的输出为 $x'_{s3}(k) = net'_{s3}(k) - net'_{s3}(k-1)$ 。 (5)

其中: j 为子网中隐含层神经元序号 ($j = 1, 2, 3$); $x_{si}(k)$ 为各子网输入层神经元的输出值; ω_{sij} 为各子网输入层至隐含层的连接权重值;有上标“'”的变量表示隐含层变量。

由于 MPIDNN 是由多个单 PIDNN 子网交叉并联而成,输出层各神经元输入 net''_h 为隐含层全部神经元输出值的加权总和,且输出层各神经元为线性神经元,则输出为

$$y_h(k) = net''_h(k) = \sum_{s=1}^n \sum_{j=1}^3 \omega'_{sjh} x'_{sj}(k) \quad (6)$$

其中: h 为输出层神经元序号 ($h = 1, 2, \dots, n$); $x'_{sj}(k)$ 为隐含层各神经元输出值, ω'_{sjh} 为隐含层至输出层的连接权重值;有上标“''”的变量表示输出层变量。

1.2 MSCOA-PIDNN 优化算法的实现

基于 BP 算法的 PIDNN 收敛性与初始权值选取有密切关系,学习速率、训练次数等参数的选取对神经网络也有很大影响。由于混沌具有遍历性的特点,利用 MSCOA 优化 PIDNN 权值,不依赖混沌状态的初值和目标函数的梯度信息,可以有效克服 BP 算法优化网络权值时依赖初始值以及易陷入局部极小的




图 1 MPIDNN 拓扑结构图

Fig. 1 Topological structure of MPIDNN

缺陷,实现全局优化,并通过不断缩小最优权值的搜索空间和改变精细搜索的调节系数,提高搜索效率。

具有简单边界约束条件的最优化问题为:
 $G = \min f(W_i), i = 1, 2, \dots, n, W_i \in [a_i, b_i]$ 。其中, f 为待优化函数, W_i 为优化自变量, b_i 和 a_i 分别为优化变量的上限和下限。变尺度混沌优化算法采用 Logistic 映射产生混沌变量

$$X^{N+1} = 4X^N(1 - X^N) \quad (7)$$

其中: X 为混沌变量, N 为混沌变量迭代次数, Logistic 映射迭代初始值 $X^0 \in (0, 1)$ 且 X^0 不为 0.25, 0.5, 0.75。通过式(8)可以将混沌变量 X_i^N 变换到优化变量 W_i^N 取值区间

$$W_i^N = a_i + X_i^N(b_i - a_i) \quad (8)$$

然后,通过一定步数的搜索,选择满足条件的优化变量视为全局最优近似值,再以此近似值为中心缩小优化区间,继续搜索至满足搜索停止条件时,可得到全局最优解或近似最优解。MSCOA 优化 PIDNN 的具体步骤如图 2 所示。

2 机械臂轨迹跟踪控制系统设计

机械臂系统是一类高度非线性、强耦合的动力学系统,其离散输入输出方程可描述为^[13]

$$\theta(t+1) = f(\theta(t), \theta(t-1), \dots, \theta(t-n), \tau(t), \tau(t-1), \dots, \tau(t-m)) \quad (9)$$

其中:控制力矩矢量 $\tau(t) = [\tau_1(t) \ \tau_2(t) \ \dots \ \tau_p(t)]^T \in R^p$ 为系统输入向量,关节角位移矢量 $\theta(t) = [\theta_1(t) \ \theta_2(t) \ \dots \ \theta_q(t)]^T \in R^q$ 为系统输出向量; p, q 为系统输入和输出维数; m, n 为输入和输出的最大时延; f 为未知的输入输出非线性函数。

MSCOA-PIDNN 不依赖混沌状态的初值和目标函数的梯度信息,具有收敛速度快、全局优化等特点。将其应用于机械臂控制系统设计,可提高系统响应的速度和准确性。采用多步预测性能指标函数的机械臂神经网络逆控制系统如图 3 所示。

图 3 中,神经网络辨识器(NNI, neural network identifier)的网络训练与神经网络控制器(NNC, neural network controller)配合进行,所用神经网络皆为 PIDNN,最终实现机械臂轨迹跟踪。

2.1 机械臂神经网络预测模型(NNI)的建立

要实现预测控制,首先需要建立系统预测模型。利用神经网络建立系统的正向模型,只要用测得的过程输入输出数据对神经网络进行训练,就可以获得其输入输出特性与实际过程等价的神经网络模型^[14-15]。

式(9)的神经网络辨识模型为

$$\hat{\theta}(k+1) = NNI(\Theta(k), T(k), WI) \quad (10)$$

其中: $\Theta(k) = [\theta(k) \ \theta(k-1) \ \theta(k-2) \ \dots \ \theta(k-n)]$, $T(k) = [\tau(k) \ \tau(k-1) \ \dots \ \tau(k-m)]$, WI 为辨识神经网络权值, $\hat{\theta}(k+1)$ 为网络输出向量。利用 MSCOA,使网络性能指标函数 J_1 最小化:

$$J_1 = \frac{1}{2} [\theta(k+1) - \hat{\theta}(k+1)]^2 \quad (11)$$

则神经网络作为实际系统的近似模型,网络模型的输出可作为实际系统的输出估计。

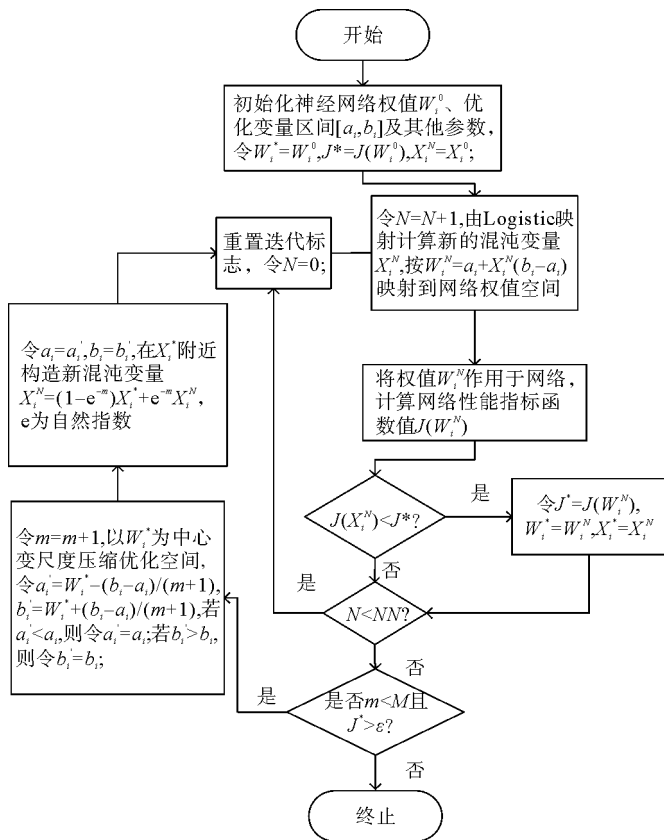


图 2 MSCOA 优化 PIDNN 流程图

Fig. 2 Flow diagram of PIDNN optimized by MSCOA

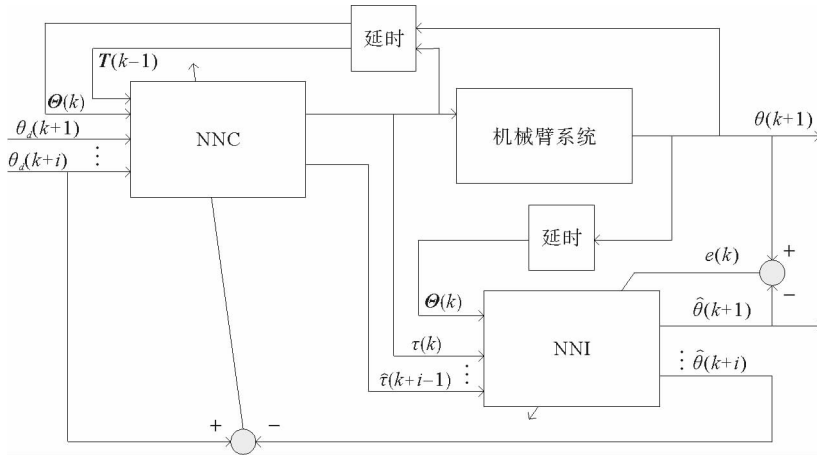


图3 机械臂神经网络预测逆控制系统框图

Fig. 3 The block diagram of manipulator trajectory tracking prediction inverse control system

2.2 机械臂神经网络预测逆控制器的设计

机械臂系统的逆模型可描述为

$$\tau(t) = g(\theta_d(t+1), \theta(t), \theta(t-1), \dots, \theta(t-n), \tau(t-1), \dots, \tau(t-m)). \quad (12)$$

其中, $\theta_d(t+1)$ 为系统的期望输出向量。

式(12)用 NNC 实现

$$\tau(k) = NNC(\theta_d(k+1), \Theta(k), T(k-1), WC). \quad (13)$$

其中, WC 为控制器权值。

利用 MSCOA, 使网络性能指标函数 J_2 最小化:

$$J_2 = \frac{1}{2} q_1 [\theta_d(k+1) - \theta(k+1)]^2 + \frac{1}{2} \sum_{i=2}^{N_p} q_i [\theta_d(k+i) - \hat{\theta}(k+i)]^2 + \frac{1}{2} \Delta \tau^2(k) + \frac{1}{2} \sum_{i=2}^{N_p} \lambda_i \Delta \hat{\tau}^2(k+i-1). \quad (14)$$

其中, N_p 为预测步长。

基于 MSCOA-PIDNN 的预测逆控制步骤如下:

- 1) 对用 MSCOA-PIDNN 建立的系统神经网络辨识器进行离线训练;
- 2) 将 $\theta_d(k+1), \Theta(k), T(k-1)$ 作用于神经网络控制器, 产生控制量 $\tau(k)$, 将 $\tau(k)$ 作用于被控对象得到 $\theta(k+1)$, 作用于 NNI 得到 $\hat{\theta}(k+1)$;
- 3) 将 $\theta_d(k+2), \hat{\theta}(k+1), \theta(k), \dots, \theta(k-n+1), T(k)$ 作用于 NNC 产生控制量 $\hat{\tau}(k+1)$, 将 $\hat{\tau}(k+1)$ 作用于 NNI 得到 $\hat{\theta}(k+2)$;
- 4) 将 $\theta_d(k+3), \hat{\theta}(k+2), \hat{\theta}(k+1), \theta(k), \dots, \theta(k-n+2), \hat{\tau}(k+1), \tau(k), \dots, \tau(k-m+2)$ 作用于 NNC 产生控制量 $\hat{\tau}(k+2)$, 将 $\hat{\tau}(k+2)$ 作用于 NNI 得到 $\hat{\theta}(k+3)$;
- 5) 依次类推, 可依次得到 $\hat{\tau}(k+3), \hat{\tau}(k+4), \dots, \hat{\tau}(k+N_p-1), \hat{\theta}(k+4), \hat{\theta}(k+5), \dots, \hat{\theta}(k+N_p)$;
- 6) 利用 MSCOA 优化 PIDNN 控制器权值, 极小化 NNC 目标函数 J_2 , 满足 $J_2 < \varepsilon_2$;
- 7) 利用 MSCOA 优化辨识网络权值, 极小化辨识器性能指标函数 J_1 , 满足 $J_1 < \varepsilon_1$;
- 8) 令 $k=k+1$, 返回 2) 继续执行。

3 仿真对比研究

为验证上述方法的有效性, 以二自由度机械臂为研究对象, 分别用 MSCOA-PIDNN 和传统 BP-PIDNN 进行仿真研究。考虑平面二连杆机械臂的动力学模型^[16]

$$M(\theta)\ddot{\theta} + C(\theta, \dot{\theta})\dot{\theta} + G(\theta) + w = \tau. \quad (15)$$

式中:

$$M(\theta) = \begin{bmatrix} v + q_1 + 2\gamma \cos \theta_2 & q_1 + q_2 \cos \theta_2 \\ q_1 + q_2 \cos \theta_2 & q_1 \end{bmatrix}; C(\theta, \dot{\theta}) = \begin{bmatrix} -q_2 \dot{\theta}_2 \sin \theta_2 & -q_2 (\dot{\theta}_1 + \dot{\theta}_2) \sin \theta_2 \\ q_2 \dot{\theta}_1 \sin \theta_2 & 0 \end{bmatrix};$$

$$G(\theta) = \begin{bmatrix} 15g \cos \theta_1 + 8.75g \cos(\theta_1 + \theta_2) \\ 8.75g \cos(\theta_1 + \theta_2) \end{bmatrix}.$$

其中: $v = 13.33$; $q_1 = 8.98$; $q_2 = 8.75$; $g = 9.8$; $\theta \in R^n$ 为关节角位移量, rad; $M(\theta) \in R^{n \times n}$ 为惯性矩阵; $C(\theta, \dot{\theta}) \in R^n$ 表示离心力和哥氏力项; $G(\theta) \in R^n$ 为重力项; $\tau \in R^n$ 为控制力矩, $N \cdot m$; $w \in R^n$ 为各种误差和扰动。

设误差扰动为 $w = \begin{bmatrix} 2 + 3E + 6\dot{E} \\ 2 \cos t \end{bmatrix}$, 误差 E 为系统期望轨迹与实际输出的差值向量, 期望轨迹为

$\begin{cases} \theta_{1d} = \cos \pi t \\ \theta_{2d} = \sin \pi t \end{cases}$, 机械臂初始位移为 $[\theta_{10} \ \theta_{20}]^T = [0.5 \ -0.5]^T$ 。采用前三步预测的神经网络逆控制方法, 分别用 MSCOA-PIDNN 和 BP-PIDNN 对被控对象进行轨迹跟踪控制, 仿真对比结果如图 4—图 7 所示。




图 4 关节 1 轨迹跟踪曲线图

Fig. 4 The trajectory tracking of joint 1




图 5 关节 2 轨迹跟踪曲线图

Fig. 5 The trajectory tracking of joint 2




图 6 关节 1 轨迹跟踪误差曲线图

Fig. 6 The trajectory tracking error of joint 1




图 7 关节 2 轨迹跟踪误差曲线图

Fig. 7 The trajectory tracking error of joint 2

从图 4 和图 5 的轨迹跟踪曲线可以看出, 采用 MSCOA-PIDNN 和 BP-PIDNN 设计的机械臂轨迹跟踪

控制系统基本上都能准确跟踪期望轨迹,但采用 MSCOA-PIDNN 的控制系统的轨迹跟踪效果更加理想。从图 6 和图 7 可看出,采用 MSCOA-PIDNN 设计的控制系统进行跟踪控制,在 $t \geq 0.3$ s 时,两个关节跟踪误差基本保持为 $|e| \leq 0.1$ rad,而采用 BP-PIDNN 设计的控制系统两个关节跟踪的误差则相对较大。综上所述,采用 MSCOA-PIDNN 设计的机械臂轨迹跟踪控制系统具有较高的跟踪精度,且控制效果比采用 BP-PIDNN 所设计控制系统更好。

4 结论

1)利用变尺度混沌优化算法(MSCOA)优化 PID 神经网络权值,可以克服传统 BP 优化算法易陷入局部极小等不足,有利于 PID 神经网络的推广应用;

2)通过对二自由度机械臂系统对比仿真可知,将 MSCOA-PIDNN 应用于机械臂控制能很好地完成不确定性机械臂系统轨迹跟踪任务;

3)MSCOA-PIDNN 是一种动态神经网络,且不依赖于被控对象的精确数学模型,可将其推广应用于其他复杂非线性系统控制中。

参考文献:

- [1]舒怀林. PID 神经网络及其控制系统[M]. 北京:国防工业出版社,2006:21-51.
- [2]Shu H L, Pi Y G. PID neural networks for time-delay systems[J]. Computers and Chemical Engineering, 2000, 24(2): 859-861.
- [3]Chen S Y, Lin F J. Decentralized PID neural network control for five degree-of-freedom active magnetic bearing[J/OL]. Engineering Applications of Artificial Intelligence. [2013-01-05]. <http://dx.doi.org/10.1016/j.engappai.2012.11.002>.
- [4]张国翊,胡铮. 改进 BP 神经网络模型及其稳定性分析[J]. 中南大学学报:自然科学版, 2011, 42(1):115-124.
Zhang Guoyi, Hu Zheng. Improved BP neural network model and its stability analysis[J]. Journal of Central South University: Science and Technology, 2011, 42(1):115-124.
- [5]李祥飞,邹恩,张泰山. 一种新型的混沌 BP 混合算法[J]. 中南大学学报:自然科学版, 2003, 34(5):540-542.
Li Xiangfei, Zou En, Zhang Taishan. A new chaos BP hybrid learning algorithm[J]. Journal of Central South University: Science and Technology, 2003, 34(5):540-542.
- [6]Choi C, Lee J. Chaotic local search algorithm[J]. Artificial Life and Robotics, 1998, 2(1):41-47.
- [7]张彤,王宏伟,王子才. 变尺度混沌优化方法及其应用[J]. 控制与决策, 1999, 14(3):285-288.
Zhang Tong, Wang Hongwei, Wang Zicai. Mutative scale chaos optimization algorithm and its application[J]. Control and Decision, 1999, 14(3):285-288.
- [8]邹恩,陈建国,李祥飞. 一种改进的变尺度混沌优化算法及其仿真研究[J]. 系统仿真学报, 2006, 18(9):2426-2432.
Zou En, Chen Jianguo, Li Xiangfei. Improving mutative scale chaos optimization algorithm and simulation study[J]. Journal of System Simulation, 2006, 18(9):2426-2432.
- [9]史先鹏,刘士荣. 机械臂轨迹跟踪控制研究进展[J]. 控制工程, 2011, 18(1):116-122.
Shi Xianpeng, Liu Shirong. A survey of trajectory control for robot manipulators[J]. Control Engineering of China, 2011, 18(1):116-122.
- [10]靳其兵,王建辉,顾树生. 多步预测性能指标函数下的神经网络逆动态控制方法[J]. 控制与决策, 1999, 14(4):308-312.
Jin Qibing, Wang Jianhui, Gu Shusheng. A method of neural network inverse control under the multi-step predictive index function[J]. Control and Decision, 1999, 14(4):308-312.
- [11]刘莹,张燕,安连祥. 基于多步预测性能指标函数的神经网络逆动态控制方法[J]. 自动化仪表, 2005, 26(1):12-14.
Liu Ying, Zhang Yan, An Lianxiang. The neural network reverse dynamic control method based on multi-step predicted performance function[J]. Process Automation Instrumentation, 2005, 26(1):12-14.
- [12]魏东,张明廉. 基于预测控制方法的非线性神经网络逆控制[J]. 计算机工程与应用, 2005(1):185-189.
Wei Dong, Zhang Minglian. Neural network nonlinear inverse control based on predictive control method[J]. Computer Engineering and Applications, 2005(1):185-189.
- [13]聂娟,邵诚. 基于神经网络的机器人轨迹鲁棒跟踪控制[J]. 自动化技术与应用, 2002, 21(6):14-18.