

文章编号: 1002-0446(2001)04-0294-06

基于层迭 CMAC 网络的 6-DOF 机器人自适应控制*

方 浩 周 冰 冯祖仁

(西安交通大学系统工程研究所 西安 710049)

摘 要: 研究了标称自适应+ 迭代学习控制算法的稳定性, 并利用层迭 CMAC 网络的优良特性, 提出了基于层迭 CMAC 的标称自适应+ 迭代学习控制方法. 此方法将标称自适应控制中确定的模型信息与未知的信息分离, 充分利用模型中确定的信息进行前馈控制; 而对于未知信息, 则利用层迭 CMAC 进行自适应学习. 仿真实验表明用本文所设计的控制系统对 6-DOF 并行机器人进行轨线控制, 可获得比以往的普通 CMAC+ PD 控制系统更好的控制效果.

关键词: CMAC 神经网络; 并行机器人; 自适应控制; 稳定性

中图分类号: TP24 **文献标识码:** B

ADAPTIVE CONTROL OF 6-DOF PARALLEL MANIPULATOR BASED ON CASCADED CMAC

FANG Hao ZHOU Bing FENG Zu-ren

(Xi'an Jiaotong University, Xi'an 710049)

Abstract: In this paper, the stability of nominal adaptive plus iterative learning control is discussed. Using the excellent characteristics of cascaded CMAC, a new kind of adaptive control method based on cascaded CMAC is also proposed. This method divides the robot model into deterministic part and uncertain part. So the deterministic information can be employed to enrich advantages in control strategies and the uncertain part can be adaptively learned by using cascaded CMAC. Simulation had verified that using this control system for trajectory control of 6-DOF parallel manipulator, we can get more effective results than ordinary CMAC+ PD control.

Keywords: CMAC based on NN, parallel manipulator, trajectory tracing control, stability, dynamic model

1 引言(Introduction)

并行机器人同传统的串行机器人相比具有许多优点, 例如更高的机械刚性、更高的位置精度、更高的承重比等等^[1]. 其中六自由度机器人(Stewart 平台)作为并行结构机器人中特殊的一类, 在飞行模拟器、重型工件的精细加工等方面得到了广泛的应用. 因此其控制问题已成为机器人研究领域的热点之一.

对于六自由度机器人, 许多文献讨论了各种自适应控制和鲁棒控制方法, 但由于其具有强耦合、高度非线性、复杂的动力学模型, 使得一些自适应控制方法因计算量大, 而难以满足快速实时性的要求, 对结构未知的不确定性也不能很好地处理. 而鲁棒控

制需要估计未知干扰的界, 难以兼顾控制精度和鲁棒性要求^[2], 因此不适用于此类复杂系统.

在机器人快速高精度控制中, 基于模型的控制是所必须的. 而神经网络因其自学习能力和非线性映射能力, 在处理复杂的非线性控制问题方面有广泛的应用. 其中 CMAC 由于其局部连接性、收敛速度快、局部推广能力、只有唯一全局极小点等特点, 在机器人控制中得到大量的应用. 层迭 CMAC 作为 CMAC 进一步完善的结果, 具有比一般 CMAC 更优良的特性. 因此, 将基于模型的控制与基于层迭 CMAC 的控制相结合是本文的一个尝试.

2 标称自适应+ 迭代学习控制方法 (Normal adaptive+ iterative learning control)

2.1 问题的描述

考虑一个六自由度机器人动力学模型

$$M(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) + T_a(t) = T \quad (1)$$

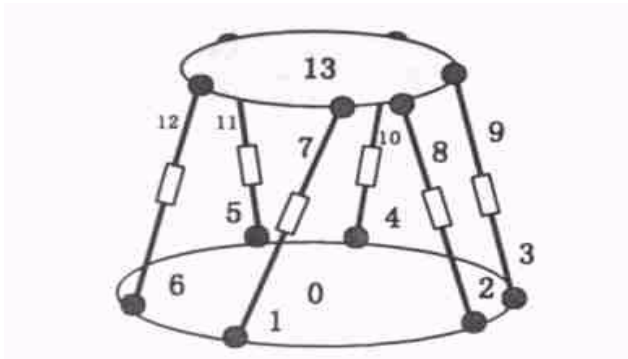


图 1 简单杆操纵器的联接

Fig. 1 Connection of the simple manipulator

其中: $M(q)$ 是对称正定的惯性矩阵; $C(q, \dot{q})\dot{q}$, $G(q)$ 分别是哥氏力, 向心力和重力向量; $q \in R^6$ 是广义坐标向量, $T \in R^6$ 是与广义坐标对应的广义力向量. $T_a(t)$ 为未知的有界干扰.

将机器人动力学模型写成如下惯性参数灵敏度模型:

$$M(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) = Y(q, \dot{q}, \ddot{q})\theta \quad (2)$$

其中 $Y(q, \dot{q}, \ddot{q}) \in R^{6 \times 1}$ 是确定性的非线性结构矩阵, $\theta \in R^{6 \times 1}$ 是未知的参数向量. 定义 6 维向量

$$\Delta W = Y(q, \dot{q}, \ddot{q})\theta - Y(q_d, \dot{q}_d, \ddot{q}_d)\theta + M(q)\dot{r} + C(q, \dot{q})r$$

$$= M(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) - Y(q_d, \dot{q}_d, \ddot{q}_d)\theta \quad (3)$$

其中 $\dot{q} = \dot{q}_d + r$, $\ddot{q} = \ddot{q}_d + \dot{r}$. 利用上面定义式, 可将机器人动力学模型改写为

$$M(q)\dot{r} + C(q, \dot{q})r - \Delta W = T_d - T \quad (4)$$

其中

$$T_d = M(q_d)\ddot{q}_d + C(q_d, \dot{q}_d)\dot{q}_d + G(q_d) + T_a \quad (5)$$

为机器人标称控制力矩.

这样, 可以将轨线控制问题表示为: 寻找控制序列 T , 使机器人在 $t \in [0, t_f]$ 上的实际运动轨线跟踪标称轨线 q_d .

取广义误差 $r = e + ae$, ($a > 0$); $e = q_d - q$. 下面引理^[3]说明了 ΔW 的有关性质:

引理 1 对于(3)式定义的 ΔW 和 $r = e + ae$, ($a > 0$); $e = q_d - q$. 下式成立:

$$\begin{aligned} r^T \Delta W &\leq r^T [aM(q) + b_1 I] r + \\ &r^T [-a^2 M(q) + b_2 I] e + \\ &b_3 (|r|^2 |e| + a |r| |e|^2) \end{aligned} \quad (6)$$

其中 I 表示单位矩阵; b_1, b_2 和 b_3 是 \dot{q}_d, \ddot{q}_d 的有界函数, 且都大于零.

2.2 标称自适应+ 迭代学习控制方法

考虑标称控制项 T_d 由两部分组成:

$$\begin{aligned} T_d &= M(q_d)\ddot{q}_d + C(q_d, \dot{q}_d)\dot{q}_d + \\ &G(q_d) + T_a = Y(q_d, \dot{q}_d, \ddot{q}_d)\theta + T_a \end{aligned} \quad (7)$$

第一部分为机器人惯性参数灵敏度模型, 矩阵 Y 可以准确知道, 而惯性参数 θ 是未知的, 可以采用自适应辨识方法获得; 而第二部分 T_a 为未知的有界干扰, 可以用迭代学习方法完成对未知干扰的学习. 因此对(4)式所示系统, 提出如下自适应+ 迭代学习控制算法:

$$T^j = U^j + Y_d \theta^j + U^j \quad (8)$$

$$U^j = k_v r^j + k_p e^j + f^j \quad (9)$$

$$r^j = \dot{e}^j + a e^j \quad (10)$$

$$f^j = k_f |e^j|^2 r^j \quad (11)$$

$$\dot{\theta}^j = \Gamma Y_d^T r^j \quad (12)$$

$$U^j = U^{j-1} + \beta k_v r^{j-1} \quad (13)$$

将上述算法代入机器人动力学方程(4)得到如下误差动态方程:

$$\begin{aligned} M(q^j)\dot{r}^j + C(q^j, \dot{q}^j)r^j + k_v r^j + \\ k_p e^j + f^j - \Delta W = Y_d \dot{\theta}^j + \tilde{U}^j \end{aligned} \quad (14)$$

其中 $\dot{\theta}^j = \dot{\theta} - \dot{\theta}^j$, $\dot{\theta}$ 为系统的真实惯性参数, $\tilde{U}^j = T_d - U^j$. 对于上述学习控制器, 其稳定性证明如下:

定理: 对于(4)所示系统, 若使用(8)~(13)所示的自适应+ 迭代学习方法, 则通过选择足够大的 k_v, k_p 和 k_f , 以及适当的 $\beta (0 < \beta < 2)$, a 和 Γ , 可以得到:

$$1) V^{j+1} \leq V^j$$

$$2) \lim_{j \rightarrow \infty} e^j(t) = 0, \text{ 对一切 } t \in [0, t_f]$$

其中 V^j 是如下定义的李亚普诺夫函数

$$V^j = V_1(j t_f) + \int_{j t_f}^{(j+1)t_f} \tilde{U}^j \beta^{-1} k_v^{-1} \tilde{U}^j d\tau \quad (15)$$

$$V_1(t) = r^T M(q) r + e^T k_p e + \theta^T \Gamma^{-1} \theta \quad (16)$$

证明: 定义 $\Delta \tilde{U}^j = \tilde{U}^{j+1} - \tilde{U}^j = (T_d - U^{j+1}) -$

$(T_d - U^j) = -U^{j+1} + U^j = -\beta k_v r^j$
根据动态误差方程(14)和引理(1)以及 $\dot{M}(q) - 2C(q, \dot{q})$ 的反对称性, 可计算 $V_1(t)$ 的导数

$$\dot{V}_1(t) = 2r^T \dot{M}(q) r + r^T \dot{M}(q) r + 2e^T k_p \dot{e} + 2\dot{\theta}^T \Gamma^{-1} \theta$$

$$\begin{aligned}
 &= -2r^T k_v r - 2ae^T k_p e - 2r^T f + 2r^T \Delta W + 2r^T \tilde{U} \\
 &\leq -r^T [2k_v - 2M(q) - (\lambda_1 + 2b_1 + b_3)I]r - \\
 &\quad e^T [2ak_p - (\lambda_1 + ab_3)I]e \\
 &\quad - [2k_f - (a + 1)b_3] |e|^2 |r|^2 - \lambda_1 (|r|^2 - |e|^2)^2 \\
 &\quad - b_3 |r|^2 (1 - |e|^2)^2 - ab_3 |e|^2 (1 - |r|^2)^2 + 2r^T \tilde{U}c
 \end{aligned} \tag{17}$$

其中 $\lambda_1 = a^2 \lambda_M + b_2$, $\lambda_M = \max \lambda [M(q)]$, 为 $M(q)$ 的最大特征值. 则离散李亚普诺夫函数的差值可计算如下:

$$\begin{aligned}
 \Delta V^j &= V^{j+1} - V^j = \int_{t_f^j}^{(j+1)t_f} \dot{V}_1(\tau) d\tau + \\
 &\quad \int_{(j+1)t_f^j}^{(j+2)t_f^j} (\tilde{U}^{j+1T} \beta^{-1} k_v^{-1} \tilde{U}^{j+1}) d\tau - \\
 &\quad \int_{t_f^j}^{(j+1)t_f^j} (\tilde{U}^{jT} \beta^{-1} k_v^{-1} \tilde{U}^j) d\tau \\
 &= \int_{t_f^j}^{(j+1)t_f^j} \dot{V}_1(\tau) d\tau + \int_{t_f^j}^{(j+1)t_f^j} (\Delta \tilde{U}^{jT} \beta^{-1} k_v^{-1} \Delta \tilde{U}^j + \\
 &\quad 2\Delta \tilde{U}^{jT} \beta^{-1} k_v^{-1} \tilde{U}^j) d\tau \leq \\
 &\leq - \int_{t_f^j}^{(j+1)t_f^j} \{ r^{jT} [(2 - \beta)k_v - 2M(q) - \\
 &\quad (\lambda_1 + 2b_1 + b_3)I]r^j + \\
 &\quad e^{jT} [2ak_p - (\lambda_1 + ab_3)I]e^j + \\
 &\quad [2k_f - (a + 1)b_3] |e|^2 |r|^2 + \lambda_1 (|r|^2 - |e|^2)^2 + \\
 &\quad b_3 |r|^2 (1 - |e|^2)^2 + ab_3 |e|^2 (1 - |r|^2)^2 \} d\tau
 \end{aligned} \tag{18}$$

由上式可知, 只要选择足够大的 k_v , k_p 和 k_f , 以及适当的 $\beta (0 < \beta < 2)$, a 和 Γ , 使

$$(2 - \beta)k_v - \beta Y_d^T \Gamma Y_d^T - (\lambda_1 + 2\lambda_M + 2b_1 + b_3)I > 0 \tag{19}$$

$$2ak_p - (\lambda_1 + ab_3)I > 0 \tag{20}$$

$$2k_f - (a + 1)b_3 > 0 \tag{21}$$

就可以保证 $\Delta V^j \leq 0$, $\{V_j\}$ 单调下降并收敛到某个非负常数. 即当 $j \rightarrow \infty$ 时, $\Delta V^j \rightarrow 0$. 由(18)得到, 当 $j \rightarrow \infty$, 对一切 $t \in [0, t_f]$, 必然有 $r^j \rightarrow 0$, $e^j \rightarrow 0$. 证毕.

3 基于层迭 CMAC 的自适应+ 迭代学习控制方法 (Normal adaptive + iterative learning control based on cascaded CMAC)

3.1 层迭 CMAC 结构原理

Albus 提出的基于小脑模型的联结控制器

CAMC, 由于其快速性和简单性, 近年来在机器人控制中得到了大量的应用. 但 CAMC 有以下不足:

CMAC 的收敛性严重依赖函数在泛化邻域上的光滑性. 如果函数值在泛化邻域内缓变, 则可以很快找到一组网络权值, 使其在可接受的误差范围内任意逼近被学习函数. 但如果函数值在泛化邻域内变化剧烈, 则网络权值很难甚至无法找到. 因此 CMAC 泛化邻域的选取就显得十分重要. 当泛化邻域选取较小时, 可以满足对函数值变化的要求, 但无法提供必要的泛化特性; 而选取较大的泛化邻域, 虽然可以满足对网络泛化能力的要求, 但无法保证网络收敛. 这是 CMAC 自身无法解决的矛盾. 为解决这一矛盾, 本文利用层迭 CMAC 来建立系统模型.

层迭 CMAC 网络结构如图 2 所示^[4], 由两个 CMAC 子网络组成, 分别为粗 CMAC 和细 CMAC.

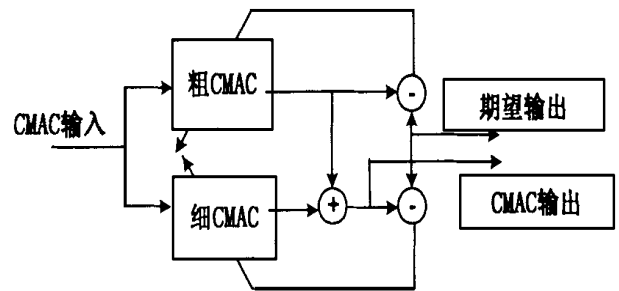


图2 层迭 CMAC 结构图

Fig. 2 Structural diagram of cascaded CMAC

粗 CMAC 对输入空间进行较粗地量化, 产生的输入状态少, 因此可以对这些系统状态进行详尽地训练. 另一方面, 由于实际物理系统的连续性, 在输入空间中的同一个单元内的输入可以产生近似的输出. 因此粗 CMAC 对整个网络输出起主导作用. 经过重复训练, 粗 CMAC 可以一定的精度近似被学习函数.

细 CMAC 与粗 CMAC 结构相同, 只是在输入空间的划分上更加细化. 网络输出的变化范围更小. 细 CMAC 的作用主要是用来补偿由于粗 CMAC 量化单位过于粗糙而引起的输出误差. 由于两个子网络的参数选取是独立的, 因此这种层迭 CMAC 结构可以同时逼近被学习对象的整体趋势和细节分量.

由图可以看出, 层迭 CMAC 的输出为

$$Z(u) = Z_1(u) + Z_2(u) \tag{22}$$

其中 $Z_1(u)$ 是粗 CMAC 输出, $Z_2(u)$ 是细 CMAC 输出. 其各自的网络权值的调整律为

$$\delta w_{ij} = \beta_1 \{Z_0 - Z_1(u_0)\} / C_1 \tag{23}$$

$$\delta w_{2j} = \beta_2 \{ Z_0 - Z_1(u_0) - Z_2(u_0) \} / C_2 \quad (24)$$

其中 $\delta w_{1j}, \delta w_{2j}$ 分别为粗 CMAC 和细 CMAC 在第 j 个训练周期的调整值. 其训练步骤为

1) 先训练粗 CMAC 的网络权值, 经过训练的粗 CMAC 输出为 $Z_1(u_0)$.

2) 利用粗 CMAC 的误差 ($Z_0 - Z_1(u_0)$) 对细 CMAC 进行训练. 由于细 CMAC 的输入划分细且输出范围小, 则细 CMAC 可在更为细化的网格上进一步精细地调整输出, 使层迭 CMAC 的输出以更高的精度逼近被学习函数.

层迭 CMAC 较比以往的普通 CMAC 具有以下优点:

1) 层迭 CMAC 是一种应用面广泛的自适应系统. 层迭结构中的每一个 CMAC 都是可以产生多维非线性映射的自适应系统. 这种非线性映射是通过查表技术而不是方程计算来实现的, 因此速度快. 并且每一个 CMAC 的参数是可以独立选取的, 通过合理地选择两网络的参数, 可以近似一大类实际的非线性系统.

2) 层迭 CMAC 比单 CMAC 学习速度快. 层迭网利用相同的数据集合来连续训练两个子网络, 因为两个子网络的量化、泛化参数不同, 所以层迭 CMAC 可更充分有效地利用训练数据, 产生更为复杂精确的非线性映射.

3) 提供更强的鲁棒性. 当粗 CMAC 经过多次训练达到一定的拟合精度时, 这时只需调节细 CMAC, 由于细 CMAC 的输出范围小, 因此细 CMAC 的学习不会使层迭 CMAC 的输出发散.

3.2 基于层迭 CMAC 的标称自适应+ 迭代学习控制方法

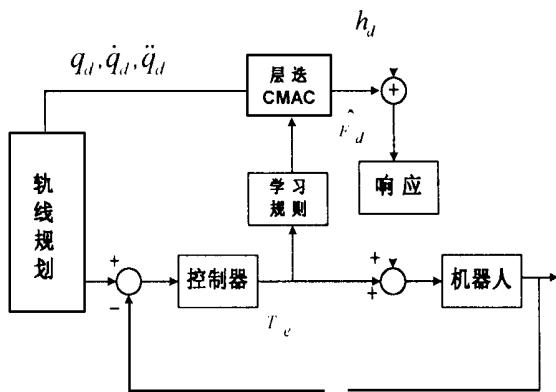


图 3 基于层迭 CMAC 控制系统

Fig. 3 Control system based on cascaded CMAC

将 CMAC 用于串型机械臂的实时控制方法已

有许多文献论述. 但由于 6-DOF 并行机器人结构复杂, 且高度非线性、强耦合, 所以使用一般的 CMAC 控制器会出现学习速度慢, 或者精度不高、最大转矩过大等问题. 另一方面, 标称自适应+ 迭代学习控制方法的稳定性在前文已经证明. 但在实际应用中, 由于 6-DOF 并联机器人模型复杂, 因此对其进行建模即计算矩阵 $Y(q, \dot{q}, \ddot{q})$ 是一项烦琐的工作. 并且当机器人的结构参数发生改变时, $Y(q, \dot{q}, \ddot{q})$ 还必须重新计算; 参数 θ 的自适应辨识方案, 计算量大, 难以满足快速实时性要求; 对结构未知的不确定性 (如建模误差, 未建模态) 也不能很好处理. 因此本文提出基于层迭 CMAC 的自适应控制.

在标称自适应控制中, 考虑系统标称动力学模型: 假设与负载有关的参数不能确切知道, 可定义需要辨识的参数向量为 θ_l , 则动力学方程可写为

$$M(q_d) \ddot{q}_d + C(q_d, \dot{q}_d) \dot{q}_d + G(q_d) + T_a = Y_l(q_d, \dot{q}_d, \ddot{q}_d) \theta_l + h_d + T_a \quad (15)$$

其中 Y_l 是与负载参数对应的灵敏度矩阵, h_d 包含了机器人模型中与未知参数 θ_l 无关的项, 根据 q, \dot{q} 和 \ddot{q} 可以准确计算出 h_d . 将上式中确定的信息 h_d 分离出来, h_d 是模型中与未知量无关的项在标称轨线上的取值, 可以离线计算. 而不确定部分 $Y_l \theta_l + T_a$ 可利用层迭 CMAC 的优良特性自适应学习获得.

根据标称自适应+ 迭代学习控制策略 (8) 式, 结合 (25) 式我们设计基于层迭 CMAC 的控制系统如图 3 所示, 控制器输出为

$$T = T_e + \hat{F}_d + h_d \quad (26)$$

其中 h_d 为前馈项, 代表标称模型中确定部分的输出; T_e 为 PD 控制项; \hat{F}_d 为层迭 CMAC 网的输出, 主要是用来完成对未知干扰项 T_a 的迭代学习和标称模型中未知项 $Y_l \theta_l$ 的自适应辨识. 所以此控制系统的输出实际上就是控制策略 (8) 式基于 CMAC 的一个具体实现. 可以看出此方法既利用层迭 CMAC 学习速度快, 鲁棒性强的特点来学习并行机器人动力学模型中不确定部分. 又可利用已知的模型信息为控制系统提供适当的前馈控制量. 前馈控制量的加入不但可以解决初始性能与迭代收敛之间的矛盾, 还可以降低最大转矩.

4 仿真实验 (Simulation)

利用本文所介绍的控制系统对六自由度并行机器人进行轨线跟踪控制. 考虑上平台做如图 4 所示的圆周运动, 运动方程如下:

$$X = [x_1 \ x_2 \ x_3]^T = A(t) X_0 \quad (27)$$

其中

$$A(t) = \begin{bmatrix} \cos[\mathcal{Q}(t)] & -\sin[\mathcal{Q}(t)] & 0 \\ \sin[\mathcal{Q}(t)] & \cos[\mathcal{Q}(t)] & 0 \\ 0 & 0 & 1 \end{bmatrix},$$

$$X_0 = \begin{bmatrix} 0 \\ -R \\ 1.3 \end{bmatrix}$$

$$\mathcal{Q}(t) = \frac{2\pi}{T}t, 0 \leq t \leq T \quad (28)$$

T 是仿真时间, 在本例中, $T = 4.0$ (s);




图 4 上平台做圆周运动

Fig. 4 Circular motion of the MP

在仿真计算中, 研究网络参数对控制效果的影响, 发现 CMAC 的泛化参数对控制效果影响最为显

著; 若粗 CMAC 的泛化参数选取过大, 则粗 CMAC 最初收敛速度很快, 但最终迭代学习结果存在较大误差. 这时依靠细 CMAC 去修整网络输出则会增加细 CMAC 的负担. 若粗 CMAC 的泛化参数选取过小, 虽然可以保证粗 CMAC 以满意的精度逼近被学习函数, 但由于泛化参数小, 所以初始性能不好, 收敛速度慢, 而且使整个层迭 CMAC 的泛化特性降低. 因此合理调整两个网络的泛化参数对控制效果极为重要, 既要利用粗 CMAC 来改善初始性能, 又要利用细 CMAC 来改善迭代学习的收敛误差. 经多次实验, 选定粗 CMAC 的泛化参数为 13, 细 CMAC 为 4. 通过实验还发现对输入空间的划分也不是越细越好, 因为 CMAC 是一种多对少的映射, 当网络的泛化能力和加权空间一定时, 输入空间划分越细, 越可能导致冲突增加和推广能力降低, 反而降低学习精度. 本文根据泛化参数和加权空间的大小, 选取粗 CMAC 的量化单位为 10, 细 CMAC 量化单位为 5. 为验证层迭 CAMC 自适应控制系统的有效性, 我们采用普通 CMAC+ PD 控制构成类似控制系统. 仿真计算的结果如下: 图中, 实线表示标称轨线, 虚线表示普通 CMAC+ PD 控制效果, 点划线表示层迭 CMAC 自适应控制效果. 由实验结果看出, 层迭 CMAC 比普通 CMAC 控制效果好. 本文还对最大力矩和负载变化的鲁棒性进行了对比实验, 同样是层迭 CMAC 具有更好的控制效果, 由于篇幅问题, 不在累述.




图 5 第一根杆长变化

Fig. 5 Length of rod 1 with respect to time




图 6 第二根杆长变化

Fig. 6 Length of rod 2 with respect to time




图 7 第三根杆长变化

Fig. 7 Length of rod 3 with respect to time




图 8 第四根杆长变化

Fig. 8 Length of rod 4 with respect to time




图 9 第五根杆长变化

Fig. 9 Length of rod 5 with respect to time




图 10 第六根杆长变化

Fig. 10 Length of rod 6 with respect to time

5 结论(Conclusion)

(1) 利用李亚普诺夫函数稳定性判据, 证明了标称自适应+ 迭代学习控制方法的稳定性.

(2) 介绍了层迭 CMAC 的结构与原理, 说明层迭 CMAC 比普通层迭 CMAC 收敛速度更快, 学习精度更高, 且鲁棒性强.

(3) 利用层迭 CMAC 的特性, 提出了基于层迭 CMAC 的标称自适应+ 迭代学习控制方法. 这种控制算法充分利用机器人动力学模型中已知的信息作为前馈信号, 减轻控制器负担, 又利用层迭 CMAC 的自适应特性, 对动力学模型中的未知部分和未知扰动进行自适应学习, 具有鲁棒性. 仿真结果验证基于层迭 CMAC 的标称自适应+ 迭代学习控制方法较以往单纯的 CMAC+ PD 控制具有更好的控制效果.

参考文献 (References)

- 1 Stewart D. A Platform with Six Degree of Freedom. Proc Inst Mech Eng, 1965, 180: 371- 378
- 2 Reed J, Ioannou P. Instability Analysis and Robust Adaptive Control of Robot Manipulators. Proc IEEE Conf Decision and Control, 1988, 1507- 1612
- 3 Sadegh N, Horowitz R. Stability and Robustness Analysis of a Class of Adaptive Controllers for Robotic Manipulators. The Int J Robotics Research, 1990, 9(3): 74- 91
- 4 Zheng Geng, Leonard S, Haynes. Neural Network Solution for the Forward Kinematics Problem of a Stewart Platform. Robotics & Computer- Integrated Manufacturing, 1992, 9(6): 485- 495

作者简介:

方 浩 (1973-), 男, 博士生. 研究领域: 机器人学与机器人控制.

周 冰 (1972-), 女, 博士生. 研究领域: 机器人学与机器人控制.

冯祖仁 (1953-), 男, 博导. 研究领域: CIMS, 机器人控制.