基于 FCMAC 的鲁棒自适应迭代学习控制算法①

孙开林，王 宪，杨 坤

(江南大学 物联网工程学院，无锡 214122)

摘 要：工业机器人在改变运动轨迹时往往伴随着系统噪声、干扰的引入以及自身的惯量参数发生变化，采用传统的迭代控制算法难以达到高精度、高速控制的要求。将自适应与鲁棒控制与迭代控制相结合，提高迭代算法的控制精度；给定任务发生改变时，引入模糊小脑关节控制器作为前馈控制，经历史控制经验训练后估算出变化后系统的期望估计输入，作为迭代控制器的初始输入，避免了在新任务产生时盲目的选择初始量，达到高速控制目的。对机器人系统的仿真结果验证了本算法的有效性和合理性。

关键词：FCMAC；迭代学习控制；鲁棒自适应

FCMAC-Based Robust Adaptive Iterative Learning Control Algorithm

SUN Kai-Lin, WANG Xian, YANG Kun

(Things of Internet, Jiangnan University, Wuxi 214122, China)

Abstract: Trajectory Changing of the industrial robots are often accompanied by system noise, interference, and the introduction of its own inertia parameters change, and the traditional iterative control algorithm is difficult to achieve high precision and high-speed control requirements. This article combines adaptive control and robust control and the iterative algorithm together to improve the control precision; when the given task is changed, the historical control experience estimates the changes in training estimated input after the system's expectations, as the initial iteration controller input, the controller works as joint fuzzy cerebellar feed-forward control, when new tasks arise it avoids the choice of the initial amount of the blind in the order to achieve high-speed control purposes. At last the robot system simulation results show the validity and rationality of the algorithm.

Key words: FCMAC; iterative Learning control; robust adaptive

作为机电一体化的代表产品，在工业生产中得到了广泛的应用，随着社会的进步和社会的发展，对机器人控制的要求也越来越高。轨迹跟踪是机器人控制系统中的重要组成部分，其控制算法的好坏直接关系到机器人控制性能，由于机器人是一 种高度耦合非线性的动态系统，轨迹变化时往往伴随着各种噪声和外在干扰的引入，其自身惯量的改变也导致模型参数的变化。为了达到高速高精度的控制要求，我们需要算法能对不确定因素具有较强的抵抗力，并能快速的收敛。

在轨迹跟踪领域，目前已经有了不少研究。1984 年，Arimoto[1,2]等人提出了迭代学习控制的概念，它的算法较为简单，且能在不依赖系统精确数学模型的情况下以高精度跟踪给定期望轨迹，尤其适合于工业机器人领域。变学习增益[3]、遗忘因子[4]、模糊控制[5]等方法也被用来提高迭代学习控制的学习速率和收敛性能。传统的迭代控制初始控制值往往随意选取一个控制量，然后根据误差变化情况完全由控制律来修正控制量，这样造成前期的误差过大，加大了算法的工作量，严重影响了实时性。所以如何根据历史经验合理推导出一个初始控制量对算法学习速度的改善具有较大的意义。另一方面，许多学者将小脑模型关节控制

① 收稿时间:2011-03-24;收到修改稿时间:2011-05-12

器（CMAC）引入机器人的控制，利用 CMAC 学习速度快、网络收敛所需的训练次数少的特点，取得了较好的效果。针对 CMAC 空间划分方式粗糙，不能在线调整的不足，侯海军、孙炜、程启明[6-8]等将模糊理论引入 CMAC，提出了一种能够反映人类小脑认知的模糊性和连续性的模糊小脑模型关节控制器(FCMAC)，相比传统 CMAC 大大提高了动静态性能和自适应性。

结合迭代算法和 FCMAC 各自优点，本文先将鲁棒控制和自适应控制的思想引入到迭代算法中去，提出一种鲁棒自适应迭代控制器[9-11]，提高算法对自身参数变化和外在干扰的抵抗力。利用 FCMAC 构成一种数据库形式的前馈控制，记录已有的控制经验并训练，当给定任务变化时由 FCMAC 的输出值作为鲁棒自适应迭代学习控制的初始值，再由前面的迭代学习律进一步进行优化，从而在较少的迭代次数下就能达到高精度的控制要求，大大提高了收敛速度。

1 鲁棒自适应迭代学习控制器

1.1 控制器设计

考虑如下具有一般形式的机器人 n 关节动态方程：

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

其中 j 为迭代次数，$t\in[0,t_f], q(t),q^j(t)\in R^n$，和 $\ddot{q}^j(t)\in R^n$ 分别为关节角度，角速度和角加速度，$D(q^j(t))\in R^{n\times n}$ 为惯性项，$C(q^j(t),\dot{q}^j(t))\dot{q}^j(t)\in R^n$ 表示离心力和哥氏力，$G(q^j(t),\dot{q}^j(t))\in R^n$ 为重力加摩擦力项，$T_a(t)\in R^n$ 为可重复的未知干扰，$T^j(t)\in R^n$ 为控制输入。

机器手动态方程满足如下特性和条件：

1 $D(q^j(t))$ 为对称正定的有界矩阵；

2 $x^T(\dot{D}(q^j(t))-2C(q^j(t),\dot{q}^j(t)))x==0$ ；

3 期望轨迹 $q_d(t)$ 在 $t\in[0,t_1]$ 内 3 阶可导；

4 迭代过程满足初始条件，即：

$$q_d(0)-q^j(0)=0 \quad \dot{q}_d(0)-\dot{q}^j(0)=0, j\in N$$

针对机器手的鲁棒自适应迭代学习控制律设计：

$$T^j(t)=K_p^j e(t)+K_d^j\dot{e}(t)+T^{j-1}(t), j=0,1,...,N \quad (2)$$

控制率中增益切换规则为：

$$K_d^j=\beta(j)K_d^0, \quad \beta(j+1)>\beta(j) \quad (3)$$

其中 $j=1,2,...,N,\ T^{-1}(t)=0, e^j(t)=q_d(t)-q^j(t)$，$\dot{e}^j(t)=\dot{q}_d(t)-\dot{q}^j(t)$，$K_p^0$ 和 K_d^0 为 PD 控制中的初始对角增益阵，且都为正定，$\beta(j)$ 为控制增益，且满足 $\beta(j)>1$。

1.2 算法收敛条件

对于满足机器特性和条件的系统（1），采用控制律（2）和增益切换规则式（3），则对于 $t\in[0,t_f]$，

$$q^j(t)\overset{j\to\infty}{\to}q_d(t), \dot{q}^j(t)\overset{j\to\infty}{\to}\dot{q}_d(t)$$

其中控制增益需要满足如下条件：

$$\left.\begin{aligned} l_p&=\lambda_{\min}(K_d^0+2C_1-2\Lambda D)>0\\ l_r&=\lambda_{\min}(K_d^0+2C+2F/\Lambda-2\dot{C}_1/\Lambda)>0\\ l_p l_r&\geq\left\|F/\Lambda-(C+C_1-\Lambda D)\right\|_{\max}^2\end{aligned}\right\} \quad (4)$$

其中 $\lambda_{\min}(A)$ 为矩阵 A 的最小特征值，$\|M\|_{\max}=\max\|M(t)\|, t\in[0,t_f]$，$\|M\|$ 为矩阵 M 的欧式范数。

1.3 初始值研究的意义

由上小节收敛条件可知，迭代初始控制量的选择不会影响到算法的收敛性和稳定性。在采用满足收敛条件(4)的控制值参数后，有：

$$\|e_{k+1}(t)\|\leq\rho\|e_k(t)\| \quad (5)$$

式中，$0<\rho<1$，$e(k+1)$ 为第 $k+1$ 次迭代时的误差，$e(k)$ 为第 k 次迭代时的误差则由（5）可进一步推出：

$$\|e_{k+1}(t)\|\leq\rho^k\|e_0(t)\| \quad (6)$$

由(6)可知，常数 ρ 和初始误差 e_0 是影响收敛速度的主要因素，为了提高迭代学习算法的收敛速度，本文采用的鲁棒自适应算法能合理改变常数 ρ，在此基础上，采用算法合理估算出一个初始控制值，使得初

始误差e_0减小，就能极大加快收敛速度。

$$\Theta=\{P_1,P_2,...P_i..]$$

2　基于FCMAC的初始值控制

2.1 FCMAC 概述

CMAC 简单实用，但最大不足之处在于简单将输入空间划分为若干个，这不符合人脑认知事物的模糊性和连续性，导致无法在线调整输入空间的划分方式和输入状态和联想强度之间的关系，将模糊理论引入到 CMAC，利用模糊推理系统则在对人类知识进行推理和决策方面的优势，提出一种模糊小脑模型关节控制器（FCMAC）。FCMAC 对输入空间的划分方式以及输入状态激活联想强度的关系值是可以在线调整的，从而能够克服传统 CMAC 的缺点，很好适应不确定性或干扰严重的复杂控制对象。

2.2 FCMAC 的工作原理和结构

FCMAC 的工作原理可以这样描述：通过对输入的模糊量化，得出输入向量激活联想强度的活性，进而激活联想强度以恢复系统的信息。图（1）为一双输入单输出的 FCMAC 结构。

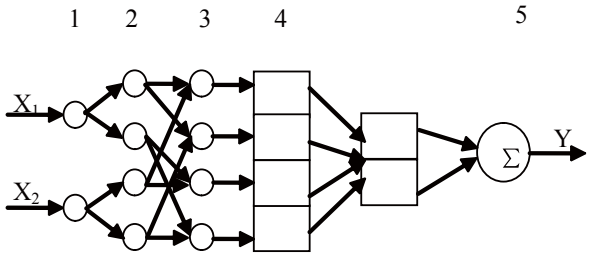

图 1　FCMAC 的结构

控制器的第一层的作用是将输入引入，第二层对输入进行模糊量化，第三层用于得出输入对联想单元的激活强度，第四层以第三层求出的激活强度激活联想单元中的联想强度，第五层对联想单元的输出进行求和以恢复系统的信息，得到系统的输出。对于输入控件的一个状态，从存储单元中找到对应于该状态的地址，将这些存储单元的内容求和得到 CMAC 的输出，将此输出与期望值进行比较，并根据学习算法对以激活的存储单元的内容进行修改。

2.3 FCMAC 的学习算法

FCMAC 训练的权值包括联想强度ω_{ij}、高斯隶属函数的中心值σ_{ij}和宽度v_{ij}。假设$\hat{y}$为 FCMAC 的期望输出，y 为 FCMAC 的实际输出，定义目标误差函数为：

$$E=\frac{1}{2}(\hat{y}-y)^2 \tag{7}$$

采用 BP 算法进行学习，则各权值的迭代公式为：

$$\begin{aligned} w_{ij}(k+1)&=w_{ij}(k)+\Delta w_{ij}(k)\\ \sigma_{ij}(k+1)&=\sigma_{ij}(k)+\Delta\sigma_{ij}(k)\\ \nu_{ij}(k+1)&=\nu_{ij}(k)+\Delta V_{ij}(k)\end{aligned} \tag{8}$$

$\Delta W,\Delta\sigma,\Delta V$ 为每次学习时权值的增加值

2.4 控制器的设计

与一般的迭代学习控制器相比，首先采用鲁棒自适应迭代算法提高系统的抗干扰性和鲁棒性，数据库用来存储不同轨迹所得到的经验知识，而 FCMAC 网络逆模型学习控制器用来对系统的新期望轨迹的初始控制值。

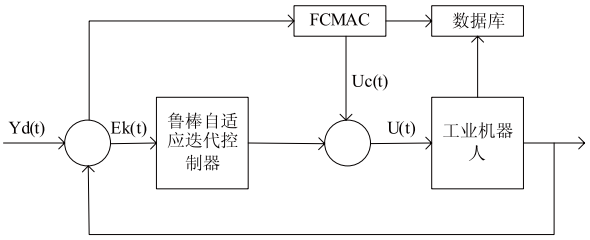

图 2　控制器结构图

2.5 初始值算法描述

可以将式（1）的逆模型写作：

$$u(t)=\psi(\dot{q}(t),q(t),y(t)) \tag{9}$$

$q(t),\dot{q}(t)$为状态向量及其倒数，$y(t)$为系统输出。

在前期利用鲁棒自适应迭代学习控制取得若干任务的控制经验后，可建立$\dot{Z}_i=[\dot{q}_i,q_i,y_i]$表示系统某一状态及输出变量，用表示相应的控制量，则将其用$p_i=[Z_i,u]$ (10)表示数据库中的一个数据。用Θ表示数据库中数据的集合

(11)

对于任给的点$p=[Z,u]$，可以在集合Θ中找到 k 个相互距离较近的数据点，这 k 点组成数据点 P 的一个临近集合Γ，对于Γ，满足：

$$d(p,p_i)<d(p,p_j),i\in k,j\in n-k \quad (12)$$

对于给定的新任务，可用上述数据库形式描述为：

$$\begin{cases} P(t)=[Z_d(t),u_d(t)] \\ Z_d^T(t)=[\dot{q}_d(t),q_d(t),y_d(t) \end{cases} \quad (13)$$

Z_d,u_d 分别表示系统的期望轨迹和期望控制输入量，迭代学习的目的就是找到一个输入量，使得 $u_i(t)\to u_d(t)$。对于新任务轨迹上的任意时刻的数据点 $p(\tau)$，其迭代学习控制的初始输入量记为 $u(\tau)$，相应地，对于 $p(\tau)$ 在数据库的 k 临近集 $\Gamma_k(\tau)$，其元素为

$$P_i(\tau)=[Z_i(\tau),u_i(\tau)],i=1,2,..k \quad (14)$$

根据欧式范数距离，确定 $p(\tau)$ 的 k 临近集 $\Gamma_k(\tau)$ 中的各元素后，根据 $p_i(\tau)=[Z_i(\tau)u_i(\tau)]$ 的隶属度，隶属函数采用高斯基函数进行相应的模糊化，得到输入状态对应存储数据库中各个临近集元素的激活程度，然后对这些临近元素进行求和运算，最后去模糊化输出作为迭代控制器的初始值并与期望值相比较后修改各单元的激活程度。

3 仿真分析

为验证本文算法的有效性，针对二关节机器人控制系统模型进行仿真，假设机器人为均匀刚性细杆，并设双臂质量和长度分别为 m_1,l_1,m_2,l_2，对于式（1）表示的模型，其中：

$$D(q)=\begin{bmatrix} i_1+i_2+2m_2r_2l_1\cos(q_2) & i_2+m_2r_2l_1\cos(q_1) \\ i_2+m_2r_2l_1(q_2) & i_2 \end{bmatrix}$$

$$C(q,\dot{q})=\begin{bmatrix} -m_2r_2l_1\dot{q}_2\sin(q_2)-m_2r_2l_1(\dot{q}_1+\dot{q}_2)\sin(q_2) \\ m_2r_2l_1\dot{q}_1\sin(q_2) \end{bmatrix} \quad 0$$

$$G(q)=\begin{bmatrix} (m_1r_1+m_2l_1)g\cos(q_1)+m_2r_2g\cos(q_1+q_2) \\ m_2r_2g\cos(q_1+q_1) \end{bmatrix}$$

可重复的干扰 $d_1(t)=0.3a\sin t,d_2(t)=0.1a(1-e^{-t})$

$a=1,T_a=[d_1d_2]^T$。

系统参数取 $m_1=10,m_2=5,l_1=0.5,l_2=0.5$，

$r_1=0.5,r_2=0.5,i_1=0.83+m_1r_1^2+m_1l_1^2$，

$i_2=0.3+m_2r_2^2$

期望轨迹 1 中 $q_1=\sin 3t,q_2=\cos 3t$，期望轨迹 2 中

$q_1=q_2=\frac{1}{2}t^2-\frac{1}{15}t^3$，取 $\Lambda=\begin{bmatrix}1 & 0\\ 0 & 1\end{bmatrix}$

控制器参数设计为 $K_p^0=K_d^0=\begin{bmatrix}210 & 0\\ 0 & 210\end{bmatrix}$

$\beta(j)=2j,K_p^j=2jK_p^0,K_d^j=2jK_d^0,j\in N$

图 3 和图 4 显示了 10 次迭代后的控制效果。

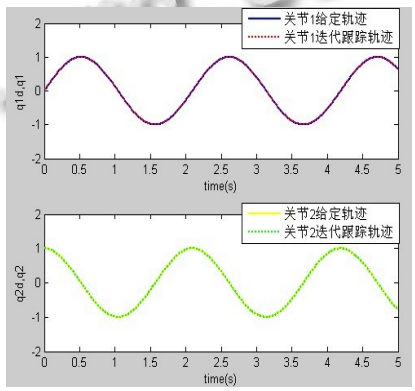

图 3 期望轨迹 1 的跟踪曲线

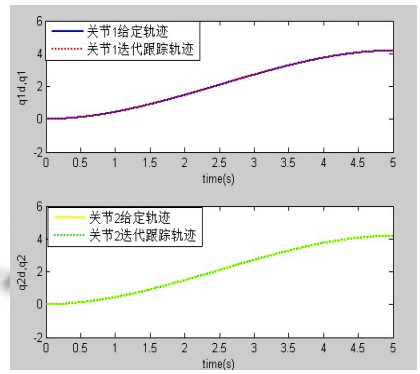

图 4 期望轨迹 3 的跟踪曲线

当切换到期望轨迹 3 时，$q_1=q_2=2-\frac{1}{6}e^{2-t}$

用前两次已取得的控制经验去训练神经网络。为便于对比，初始控制输入量利用 FCMAC 选取和取为 0 两种方法来确定，所得两种方案系统误差均方和迭代次数的关系如图 5 所示，其中 l_1 表示初始值为 0 的关系曲线，l_2 表示利用 FCMAC 法确定的关系曲线，可以明显看出选取初始控制量的方法具有明显的优势。

4 结语

本文在首先将自适应控制和鲁棒控制算法融合到传统迭代控制方法中去，以提高机器人在强干扰及不确定情况下的控制精度，由图 3 和图 4 可知算法能够跟踪给定的运动轨迹,但是在任务发生变化时,由图 5 可知，收敛所需迭代次数较大，迭代到 12 次时才收敛，为进一步改善系统的实时性，再采用快速简单的 FCMAC 加以前馈改善初始值，当任务轨迹改变时加入 FCMAC 仅用 4 次就可收敛，在更短的时间内达到了精度的要求，在时间效率上较之前提高了 75%。

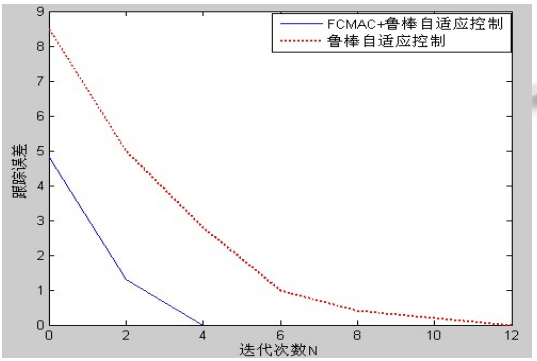

图 5 2 种算法效果对照图

参考文献

1 谢胜利,田森平,谢振东,等.迭代学习控制的理论与应用.北京:科学出版社.

2 Arimoto S, Kawamura S, Miyazaki F. Bettering Operation of robotics by learning. Journal of Robotic System, 1984,1(2): 123–140.

3 徐敏,林辉,刘震.可变学习增益的迭代学习控制.控制理论与应用,2007,24(5):857–861

4 姚仲舒,王宏飞,杨成梧.一种机器人轨迹跟踪的迭代学习控制方法.兵工学报,2004,25(3):330–334.

5 Zhao YJ, Dong XJ. A new solution to the inverse position analysis of the redundant serial robot. Journal of Shanghai Jiaotong University (Science), 2010, 15(5): 610–614.

6 侯海军,雷勇,叶小勇.基于模糊 CMAC 网络的非线性自适应逆控制.系统仿真学报,2008,20(8):2039–2042.

7 孙炜,王耀南.模糊 CMAC 及其在机器人轨迹跟踪控制中的应用.控制理论与应用,2006,2(1):38–42.

8 程启明,王勇浩.模糊 CMAC 神经网络控制系统及混合学习算法.电机与控制学报,2006,10(2):216–221.

9 Morris J, Zhang J. Performance Monitoring and Batch to Batch Control of Biotechnological Processes. 2009, 218: 281–310.

10 Levskii MV. Optimal control of reorientation of a spacecraft using free trajectory method,2011,49(2):131–149.

11 Rose M. Automated Generation of Efficient Real-Time Code for Inverse Dynamic Parallel Robot Models. Springer Tracts in Advanced Robotics, 2011,67:39–57.

(上接第 71 页)

11 Dike J. A user-mode port of the Linux kernel. Proc. of the 2000 Linux Showcase and Conference, 2000, 2.

12 Elson J. Girod L. FUSD-a linux framework for user-space devices. University of California, Los Angeles, Unpublished technical report, 2003.

13 Shen YT, Elphinstone K, Heiser G. User-Level Device Drivers: Achieved Performance.

14 Zhou F, Condit J, Anderson Z, Bagrak I, Ennals R, Harren M, Necula G, Brewer E. SafeDrive: Safe and recoverable extensions using language-based techniques. Proc. of the 7th Symposium on Operating Systems Design and Implementation. USENIX Association, 2006. 45–60.

15 Bovet D, Cesati M, Oram A. Understanding the linux kernel. O'Reilly & Associates, Inc. Sebastopol, CA, USA, 2002.

16 Love R. Safari Tech Books Online. Linux kernel development, Novell Press USA, 2005, 50.