

模糊 CMAC 及其在机器人轨迹跟踪控制中的应用

孙 炜, 王耀南

(湖南大学 电气与信息工程学院, 湖南 长沙 410082)

摘要: 小脑模型关节控制器(CMAC)具有结构简单,学习快速的优点,但是它的空间划分方式不能在线进行调整,影响了其自适应能力的提高. 本文将模糊理论引入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). 该控制器对CMAC的空间划分方式进行了模糊化处理,可通过BP学习算法对CMAC的空间划分方式进行在线调整,大大提高了CMAC的自适应能力. 所提出的FCMAC被应用于机器人的轨迹跟踪控制系统以克服机器人系统中非线性性和不确定性因素的影响. 仿真实验结果表明,所提FCMAC与传统的CMAC相比性能上有了很大的改善.

关键词: 小脑模型关节控制器; 模糊小脑模型关节控制器; 机器人

中图分类号: TP183 **文献标识码:** A

Fuzzy cerebellar model articulation controller and its application on robotic tracking control

SUN Wei, WANG Yao-nan

(College of Electrical and Information Engineering, Hunan University, Changsha Hunan 410082, China)

Abstract: Cerebellar model articulation controller (CMAC) has simple structure and rapid learning speed, but its space division way can not be adapted on line. This hinders the improvement of its self-adaptive ability. In this paper, fuzzy theory is introduced to CMAC, and a fuzzy cerebellar model articulation controller (FCMAC) is proposed. By fuzzifying the space division way of CMAC and adapting it on line through BP learning algorithm, the proposed FCMAC can reflect the fuzziness and continuity of human cerebella, and greatly improve the self-adaptive ability of CMAC. The proposed FCMAC is applied on robotic tracking control system to counteract the disadvantageous influences of nonlinearities and uncertainties in robotic system. Simulation results show that the performance of proposed FCMAC is much better than that of traditional CMAC.

Key words: cerebellar model articulation controller; fuzzy cerebellar model articulation controller; robot

1 引言(Introduction)

小脑模型关节控制器(CMAC)^[1]最初是由Albus于1975年提出的,它是一种基于神经生理学的、简单快速的神经网络,能够学习任意多维非线性映射,迄今已广泛用于许多领域.与BP网络之类的全局逼近方法相比,CMAC具有许多优点^[2-6],它具有局部逼近能力、连续(模拟)输入输出能力和一定的泛化能力,结构简单、学习速度快,特别适合于实时控制.

但是,传统的CMAC也有自身的不足,它在对输入空间进行划分时,将输入空间简单地划分为若干个“块”,输入状态与这些“块”之间是简单的“属于”与“不属于”的关系,即“1”和“0”的关系.此外,

输入状态与联想强度之间的关系也是简单的“激活”和“不激活”关系.这不符合人脑认知事物的模糊性和连续性.而且由于这种简单的“属于”与“不属于”的关系、“激活”和“不激活”关系是不可微分的,所以CMAC中输入空间的划分方式、输入状态和联想单元之间的关系是无法在线调整的,从而导致CMAC的自适应能力较差,不能很好地应用于不确定性严重的控制系统.本文针对CMAC的这些缺点,将模糊理论引入CMAC,对CMAC的输入空间划分方式和联想单元激活方式进行了模糊化处理,提出了一种模糊小脑模型关节控制器(FCMAC).在对CMAC进行模糊化处理时采用了连续可微分的高斯基隶属函数,使得输入空间划分方式以及联

想强度的激活活性可以在线调整,从而提高了控制器的自学习能力,使其能够更好地适应各种复杂控制对象的要求。

机器人是一种具有高度非线性、强耦合的对象,且具有诸如摩擦、负载变化等不确定因素。传统的基于对象的控制方法很难精确地控制机器人的跟踪轨迹。近年来,许多学者将 CMAC 引入机器人的控制^[3],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,但还不够理想。本文将所提 FCMAC 用于机器人的轨迹跟踪控制,仿真实验结果表明,这种控制方法与传统的 CMAC 相比具有更好的动静态性能和更强的鲁棒性。

2 小脑模型关节控制器 (CMAC)

如图 1 所示,CMAC 是一种模仿人类小脑的学习结构。在这种结构中,每个状态变量被量化并且问题空间被划分成离散状态。量化的输入构成的向量指定了一个离散状态并且被用于产生地址来激活联想单元中存储的联想强度从而恢复这个状态的信息。

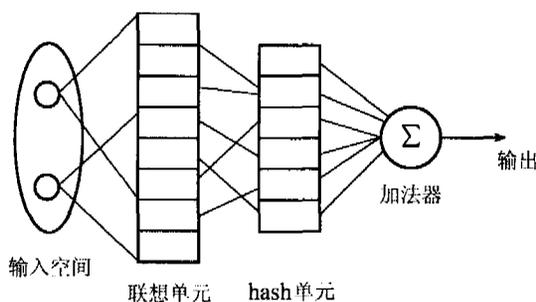


图 1 CMAC 的一般结构

Fig. 1 General structure of CMAC

图 2 描述了一个双输入单输出的 CMAC 的空间划分和量化机制。在这个简单的 CMAC 中,有两个输入变量 (v_1 和 v_2),每个输入变量在各自的论域上被划分为 4 个状态,从而使整个输入空间被划分为 16 个状态。每个输入变量的状态又被分别划分为 2 个离散的“块”。譬如, v_1 的状态可以被划分为 A, B 两个块; v_2 的状态可以被划分为 a, b 两个块。不同输入变量上定义的块在输入空间中交迭的区域被称之为“超立方体”。例如, A, B 和 a, b 在输入空间中交迭的区域构成了 4 个超立方体: Aa, Ab, Ba 和 Bb。每个输入变量上块的划分方式并不唯一,在图 2 中,各输入变量都有 3 种块的划分方式,从而可以组成 3 组共 12 个超立方体 (Aa, Ab, Ba, Bb; Cc, Cd, Dc, Dd; Ee, Ef, Fe, Ff)。

从图 2 可看出,两输入变量对应的每一种状态 (1, 2, ..., 16) 都被 3 个不同的超立方体覆盖,也就是

说,每一种状态将激活 3 个不同的超立方体。CMAC 将每个超立方体和物理的存储单元地址 (联想单元) 联系在一起,而联想单元中存储的是各单元的联想强度。对于输入空间大的情况,联想单元数量巨大,为了节省存储空间,Albus 提出了 hash 编码,几个联想单元可以通过 hash 映射被分配同一个存储单元。每个联想单元与一个“任意的但确定性的”物理存储地址 (hash 单元) 相联系,这样联想强度被存储于数量大大少于联想单元的 hash 单元中,而联想单元中只存储 hash 单元的散列地址编码。

通过以上的空间划分和量化机制,CMAC 的工作原理可以描述为:CMAC 接收到一组输入变量,首先将其量化为一个离散的状态,该状态激活覆盖它的所有超立方体,并进而激活相对应的联想单元,所有被激活的联想单元根据其各自存储的联想强度进行加权求和,来得到 CMAC 的输出。CMAC 可以通过在线调整联想强度来逼近所要描述的函数关系。

从上面的分析可以看出,块的数量及划分方式对于 CMAC 的性能影响很大,在传统的 CMAC 中,块的划分方式以及由其形成的输入状态和联想单元之间的激活关系无法在线进行调整,影响了其自适应能力的提高。在本文中,我们将把模糊理论引入 CMAC,对 CMAC 中块的划分方式以及联想单元激活方式进行模糊化处理,使得输入空间划分方式以及联想单元的激活活性可以在线调整,从而提高控制器的自适应能力。

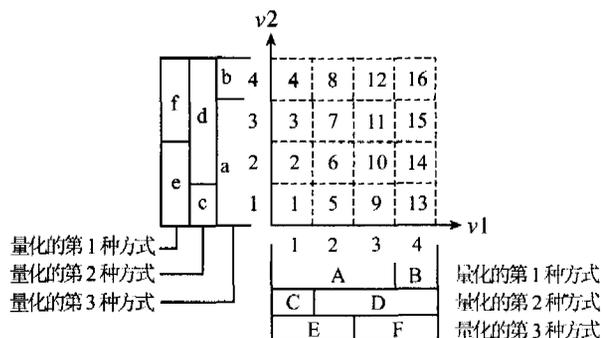


图 2 双变量 CMAC 的空间划分

Fig. 2 Space division of CMAC for a two-variable case

3 模糊小脑模型关节控制器 (FCMAC)

3.1 FCMAC 的工作原理和结构 (Principle and structure of FCMAC)

在图 2 描述的 CMAC 的量化机制中,输入变量与各状态之间,与各“块”之间,与各“超立方体”之间的隶属关系都是简单的“1”或“0”的关系。而实际上,人脑对于事物的认识是模糊的和连续的,而不是

简单的离散的“1”或“0”的关系. 所以本文下面将模糊的概念引入量化的过程中, 提出了一种 FCMAC. 所提出的 FCMAC 的工作机理可以这样描述: 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. 下面以 m 输入单输出的 FCMAC 为例(如图 3 所示)来说明 FCMAC 的结构.

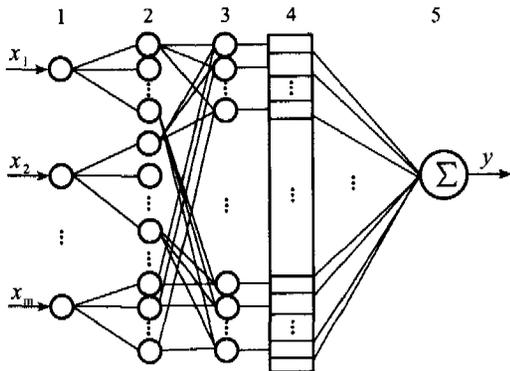


图 3 FCMAC 的结构
Fig. 3 Structure of FCMAC

用 $O_i^{(j)}, I_i^{(j)}$ 分别表示网络第 j 层第 i 个神经元的输出和输入, 则网络各层的含义和输入输出关系可以描述如下:

网络第 1 层的作用是将输入引入网络:

$$O_i^{(1)} = I_i^{(1)} = x_i, \quad i = 1, 2, \dots, m. \quad (1)$$

第 2 层对输入进行模糊量化, 模糊量化的过程如下:

假设所有输入 (x_1, x_2, \dots, x_m) 是连续和有界的, 我们在每个输入 x_i 的论域上定义 n 个块 $(A_{i1}, A_{i2}, \dots, A_{in})$. 输入 x_i 对应第 j 个“块”的模糊隶属关系采用高斯基隶属函数关系, 定义为

$$\begin{cases} \mu_{A_{ij}}(x_i) = \exp\left[-\frac{(x_i - \sigma_{ij})^2}{v_{ij}^2}\right], \\ i = 1, 2, \dots, m; j = 1, 2, \dots, n. \end{cases} \quad (2)$$

式中 σ_{ij} 表示高斯基隶属函数的中心值, v_{ij} 表示宽度.

假设第 2 层的第 p 个神经元是对第 i 个输入进行第 j 个块的模糊量化, 则该神经元的输入输出关系为

$$\begin{cases} O_p^{(2)} = I_p^{(2)} = \mu_{A_{ij}}(x_i), \\ p = 1, 2, \dots, m \times n. \end{cases} \quad (3)$$

第 3 层用于得出输入对联想单元的激活强度. 所有输入论域上相对应的块组成了 n^m 个超立方体, 每个超立方体与一个联想单元相对应, 每个联想单元中存储着相应的联想强度. 假设超立方体 H_q 由块

$A_{1q_1}, A_{2q_2}, \dots, A_{mq_m}$ 组成, 则系统输入 x_1, x_2, \dots, x_m 与 H_q 的隶属关系, 即对联想单元的激活强度为

$$\begin{cases} O_q^{(3)} = I_q^{(3)} = \prod_{i=1}^m \mu_{A_{iq_i}}(x_i), \\ q = 1, 2, \dots, n^m; q_1, q_2, \dots, q_m \in \{1, 2, \dots, n\}. \end{cases} \quad (4)$$

第 4 层以第 3 层求出的激活强度激活联想单元中的联想强度. 如果第 q 个联想单元中存储的联想强度为 w_q , 则其输入输出关系为

$$O_q^{(4)} = I_q^{(4)} = O_q^{(3)} \cdot w_q, \quad q = 1, 2, \dots, n^m. \quad (5)$$

定义 $b_q = O_q^{(3)}$, 则式(5)可简化为

$$O_q^{(4)} = I_q^{(4)} = b_q \cdot w_q. \quad (6)$$

第 5 层对激活的联想强度进行求和以恢复系统的信息, 得到系统的输出.

$$y = O^{(5)} = I^{(5)} = \sum_{q=1}^{n^m} O_q^{(4)} = \sum_{q=1}^{n^m} b_q \cdot w_q = \mathbf{b}^T \mathbf{w}. \quad (7)$$

式中 $\mathbf{b} = [b_1 \ b_2 \ \dots \ b_{n^m}]^T, \mathbf{w} = [w_1 \ w_2 \ \dots \ w_{n^m}]^T$.

3.2 FCMAC 的学习算法 (Learning algorithm of FCMAC)

FCMAC 用迭代算法来产生存储信息. 在学习中, 将 N_s 个训练数据重复用于学习.

假设 \hat{y}_s 为网络对应第 s 个样本的期望输出, y_s 为网络对应第 s 个样本的实际输出, 定义目标误差函数为

$$E = \frac{1}{2}(\hat{y}_s - y_s)^2 = \frac{1}{2}(\hat{y}_s - \mathbf{b}_s^T \mathbf{w}_s)^2. \quad (8)$$

网络采用 BP 算法进行学习, 联想强度 $w_{q,s}$ 的学习律为

$$w_{q,s+1} = w_{q,s} + \Delta w_{q,s}, \quad (9)$$

其中, $\Delta w_{q,s}$ 为第 q 个联想强度对应第 s 个样本的增量, 可表示为

$$\begin{aligned} \Delta w_{q,s} &= -\alpha \frac{\partial E}{\partial w_{q,s}} = -\alpha \frac{\partial E}{\partial y_s} \cdot \frac{\partial y_s}{\partial w_{q,s}} = \\ &= \alpha (\hat{y}_s - \mathbf{b}_s^T \mathbf{w}_s) \cdot b_{q,s}. \end{aligned} \quad (10)$$

式中 α 为学习率.

同理可以调整各隶属函数的中心值和宽度, 其公式推导本文不再一一列出. 事实上, 调整隶属函数的中心值和宽度就相当于调整图 2 中块的划分方式, 从而调整超立方体的空间位置和对输入状态的覆盖程度. 由于 FCMAC 中块的划分方式可以在线调整, 因此无须再对输入空间进行多种方式的量化, 超立方体的数量将大大减少, 相对应的存储空间也将大大减少. 例如图 2 所示的双变量 CMAC 的量化方式中, 块的数量是 2, 对应的划分方式有 3 种, 超

立方体有 3 层,每层 4 个超立方体,对应 $3 \times 4 = 12$ 个存储单元;而在双变量的 FCMAC 中,如果块的数量是 2,由于无须多种量化方式,则超立方体的数量是 $2 \times 2 = 4$ 个,仅为 CMAC 的 1/3. 如果块的数量越多,块的划分方式越多,则 FCMAC 节省的存储空间越大.

4 用于机器人轨迹跟踪控制的 FCMAC (FCMAC for robotic tracking control)

对于具有多个自由度的多关节机器人来说,每个关节的驱动力矩都由伺服控制器根据各个关节的期望轨迹给定. 本文采用 FCMAC 作为机器人关节伺服控制器. 图 4 给出了用作二关节机械手伺服控制器的 FCMAC 的结构. 网络有 4 个输入,分别对应两个关节的轨迹跟踪误差及其变化率 (e_1, ec_1, e_2, ec_2). 每个关节的两个输入构成一个输入子空间. 网络对每个输入子空间进行模糊空间划分,得到输入状态对联想单元的激活活性. 两组联想单元分别存储对应于两个关节输出力矩 t_1 和 t_2 的联想强度. 考虑到各关节之间的耦合作用,各关节的输入状态对两组联想单元均有激活作用. 网络各层的输入输出关系如式(1)~(7). 我们在每个输入的论域上定义 5 个块,每组联想单元占用的物理存储单元数量为 $5 \times 5 \times 2 = 50$ 个,数量不大,因此没有必要采用 hash 映射.

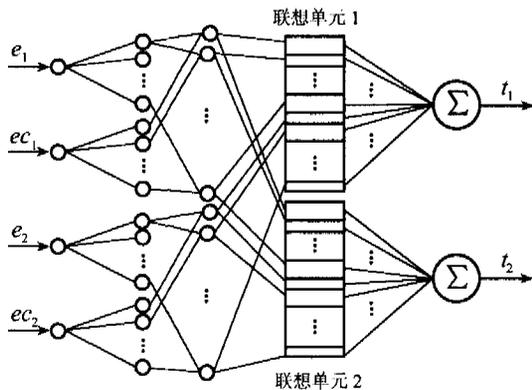


图 4 用于机械手轨迹跟踪控制的 FCMAC
Fig. 4 FCMAC for robotic tracking control

5 仿真实验 (Simulation experiments)

本文对一个两关节机械手(如图 5)进行仿真以验证所提方法的正确性. 图 5 中 m_1, m_2 是臂 1 和臂 2 的质量. 假设质量集中于臂的末梢. l_1, l_2 分别为臂 1 和臂 2 的长度. t_1, t_2 分别为作用在关节 1 和关节 2 上的驱动力矩. θ_1, θ_2 为关节 1 和关节 2 在 t_1, t_2 作用下

转过的角度. 图 5 所示的机械手的动力学特性可描述为:

$$M(\theta)\ddot{\theta} + V(\theta, \dot{\theta})\dot{\theta} + G(\theta) + f(\dot{\theta}) + t_d(\theta, \dot{\theta}) = t. \quad (11)$$

式中 $\theta = [\theta_1 \ \theta_2]^T, \dot{\theta} = [\dot{\theta}_1 \ \dot{\theta}_2]^T, \ddot{\theta} = [\ddot{\theta}_1 \ \ddot{\theta}_2]^T, t = [t_1 \ t_2]^T. M(\theta)$ 是惯性矩阵, $V(\theta, \dot{\theta})$ 是离心力和哥氏力矩阵, $G(\theta)$ 是重力矩阵, $f(\dot{\theta})$ 是静态和动态摩擦向量, $t_d(\theta, \dot{\theta})$ 代表所有由负载变化或建模误差所引起的扰动向量. 令 c_i 代表 $\cos \theta_i, s_i$ 代表 $\sin \theta_i, c_{ij}$ 代表 $\cos(\theta_i + \theta_j)$. 则:

$$M(\theta) = \begin{bmatrix} m_1 l_1^2 + m_2 (l_1^2 + l_2^2 + 2l_1 l_2 c_2) & m_2 l_2^2 + m_2 l_1 l_2 c_2 \\ m_2 l_2^2 + m_2 l_1 l_2 c_2 & m_2 l_2^2 \end{bmatrix}. \quad (12)$$

$$V(\theta, \dot{\theta}) = \begin{bmatrix} -m_1 l_1 l_2 s_2 \dot{\theta}_2^2 - 2m_2 l_1 l_2 s_2 \dot{\theta}_1 \dot{\theta}_2 \\ m_2 l_1 l_2 s_2 \dot{\theta}_1^2 \end{bmatrix}. \quad (13)$$

$$G(\theta) = \begin{bmatrix} m_2 l_2 g c_{12} + (m_1 + m_2) l_1 g c_1 \\ m_2 l_2 g c_{12} \end{bmatrix}. \quad (14)$$

本文中用于仿真的机械手的参数为 $m_1 = 10\text{kg}, m_2 = 2\text{kg}$ 和 $l_1 = 1.1\text{m}, l_2 = 0.8\text{m}$. 初始条件为 $\theta_1(0) = \theta_2(0) = 0 \text{ rad}, \dot{\theta}_1(0) = \dot{\theta}_2(0) = 0 \text{ rad/s}$. 期望轨迹为 $\theta_1^d(t) = \theta_2^d(t) = \sin(2\pi t) \text{ rad}$, 采样周期为 0.0005s . 摩擦项和扰动项分别为 $f(\dot{\theta}) = 0.5 \text{sgn}(\dot{\theta}) \text{ N} \cdot \text{m}, t_d(\theta, \dot{\theta}) = \begin{bmatrix} 5 \cos(5t) \\ 5 \cos(5t) \end{bmatrix} \text{ N} \cdot \text{m}$. 图 6

和图 7 分别给出了关节 1 和关节 2 的跟踪轨迹曲线并与传统 CMAC 的跟踪曲线进行了比较;图 8 和图 9 分别给出了关节 1 和关节 2 的跟踪误差曲线并与传统 CMAC 的误差曲线进行了比较. 由图 6~9 可看出,所提 FCMAC 与传统的 CMAC 相比,具有更精确的跟踪特性和更强的鲁棒性.

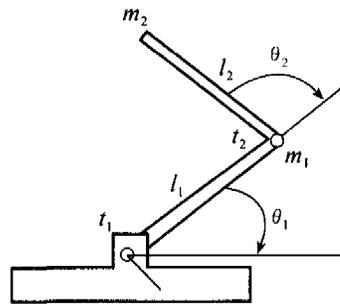


图 5 二关节机械手
Fig. 5 Robotic manipulator with two joints

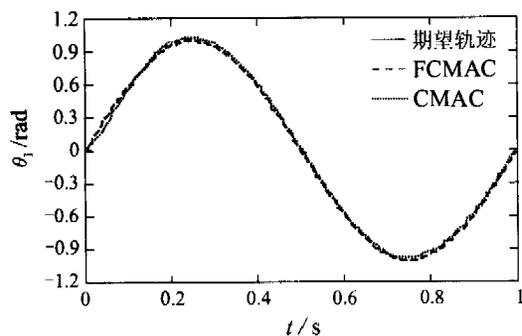


图6 关节1的轨迹跟踪曲线
Fig. 6 Tracking curve of joint 1

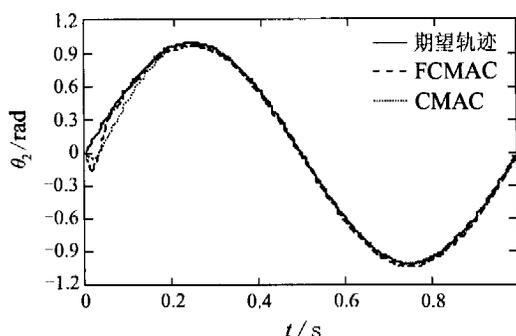


图7 关节2的轨迹跟踪曲线
Fig. 7 Tracking curve of joint 2

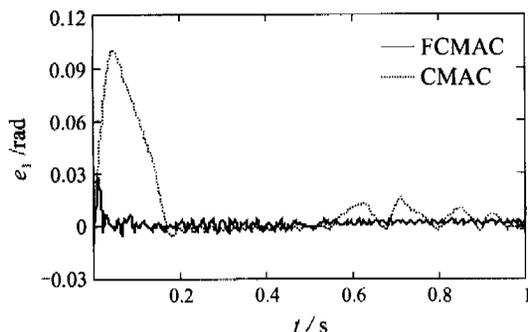


图8 关节1的跟踪误差曲线
Fig. 8 Tracking error curve of joint 1

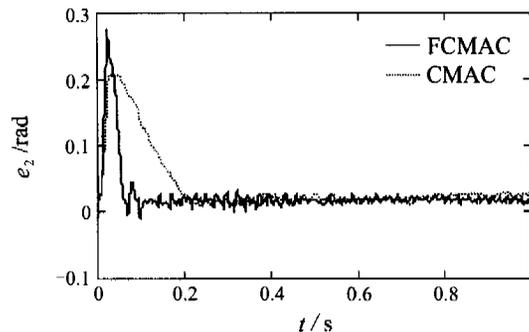


图9 关节2的跟踪误差曲线
Fig. 9 Tracking error curve of joint 2

6 结论(Conclusions)

本文将模糊理论引入CMAC,在划分输入空间和激活联想强度时采用了模糊化的方法,提出了一种模糊小脑模型关节控制器.这种网络学习算法简单,易在线学习,克服了CMAC的缺点,具有连续可微性和模糊性,更好地反映了人脑的特性,可在线对空间划分方式和联想强度激活活性进行调整.仿真实验结果表明,所提FCMAC具有比CMAC更好的性能,是一种行之有效的控制器.

参考文献(References):

[1] ALBUS J S. A new approach to manipulator control: the cerebellar model articulation controller (CMAC) [J]. *J of Dynamic Systems, Measurement, and Control Trans of ASME*, 1975, 5(2): 220-227.
[2] MILLER T W, GLANZ F H. An associative neural network alternative to backpropagation [J]. *Proceedings of IEEE*, 1990, 78(10): 1561-1567.

[3] MILLER T W. Real-time application of neural networks for sensor-based control of robots [J]. *IEEE Trans on Systems Man and Cybernetics*, 1989, 19(4): 825-831.
[4] WONG Y, SIDERIS A. Learning convergence in the cerebellar model articulation controller [J]. *IEEE Trans on Neural Networks*, 1992, 3(1): 115-121.
[5] CHANG C T, LIN C S. CMAC with general basis functions [J]. *Neural Networks*, 1996, 9(7): 1199-1211.
[6] 王耀南. 中心计算智能信息处理技术及其应用[M]. 长沙: 湖南大学出版社, 1999: 325-329.
(WANG Yaonan. *Computational Intelligent Information Processing Technologies and Their Applications* [M]. Changsha: Hunan University Press, 1999: 325-329.)

作者简介:

孙炜 (1975—),男,博士,湖南大学电气与信息工程学院副教授,研究领域:智能控制理论及应用,智能机器人控制等,E-mail: david-sun@tom.com;

王耀南 (1957—),男,博士,湖南大学电气与信息工程学院教授,研究领域:智能控制理论及应用,智能信息处理,智能机器人控制,电力电子,电动汽车控制等,E-mail: yaonao@mail.hunu.edu.cn.