

基于平衡学习的CMAC神经网络非线性滑模容错控制

朱大奇¹, 孔 敏²

(1. 上海海事大学 信息工程学院, 上海 浦东 200135; 2. 江南大学 智能控制研究所, 江苏 无锡 214122)

摘要: 以一改进的信度分配CMAC(cerebellar model articulation controllers)神经网络为在线故障诊断的手段, 将变结构滑模控制技术引入容错控制器设计之中, 提出一种动态非线性系统主动容错控制方法. 在常规CMAC学习算法中, 误差被平均地分配给所有被激活的存储单元, 不管各存储单元存储数据(权值)的可信程度. 改进的CMAC中, 利用激活单元先前学习次数作为可信度, 其误差校正值与激活单元先前学习次数的 $-p$ 次方成比例, 从而提高神经网络的在线学习速度和精度; 在此基础上利用滑模控制算法进行容错控制律的在线重构, 实现动态非线性系统在线故障诊断与容错控制的集成. 分析了系统的稳定性, 仿真结果表明改进故障学习算法及容错控制的有效性.

关键词: 信度分配; 平衡学习; 故障诊断; 容错控制

中图分类号: TP273 **文献标识码:** A

Fault-tolerant control of nonlinear system based on balanced learning CMAC neural network

ZHU Da-qi¹, KONG Min²

(1. Information Engineering College, Shanghai Maritime University, Pudong Shanghai 200135, China;

2. Institute of Intelligent Control, Southern Yangtze University, Wuxi Jiangsu 214122, China)

Abstract: A fault-tolerant control scheme of dynamic nonlinear system based on improved CMAC neural network and sliding model control technique is presented in this paper. In the conventional CMAC learning scheme, the correcting amounts of errors are equally distributed into all addressed hypercubes, regardless of the credibility of those hypercubes. The proposed improved learning approach employs the number of learnings of addressed hypercubes as the credibility of learned value. The correcting amounts of errors are inversely proportional to the p th power of the number of learnings of addressed hypercubes. With this idea, the fault learning speed can be improved. Based on the improved CMAC learning approach and the effective control law of reconfiguration strategy using sliding model control technique, a combination of on-line diagnosis and fault-tolerant control for a dynamical nonlinear system is realized. The system stability and performance are also analyzed. Finally, the numerical simulation demonstrates the effectiveness of the improved CMAC algorithm and the proposed fault-tolerant controller.

Key words: credit assigned; balanced learning; fault diagnosis; fault-tolerant control

1 引言 (Introduction)

近20年来, 容错控制技术无论是在故障诊断研究方面, 还是在控制律重构算法设计上都取得了不少进展, 文献[1, 2]对近些年的研究状况进行了较好的综述. 但从现有的研究报道看, 大多是针对特定系统展开故障诊断或容错控制研究^[3~9], 而将智能故障诊断技术与控制律重构设计相结合的一般性非线性集成容错控制研究成果还较少^[9], 特别是在线故障辨识快速性研究及控制律在线重构方面, 仍有许多问题有待探索. 对主动容错控制来说, 故障诊断的准确性和实时性是保证控制系统稳定运行的重要前提. 这是因为动态非线性系统的状态及参数变化极

快, 为保证系统故障时运行稳定, 必须在最短的时间内辨识故障, 重构控制规律. 神经网络的研究和发展为动态非线性系统故障诊断提供了一重要的工具, 但常用的RBF(radial basis function)神经网络, 由于其基函数选择、隐节点数目的确定一直是一个非常困难的问题, 影响了网络学习逼近效果及收敛速度, 从而制约了RBF神经网络在动态系统故障诊断中的有效应用.

自从Albus提出一种模拟小脑学习机构的小脑模型关节控制器CMAC(cerebellar model articulation controllers)以来^[10, 11], CMAC以其局部泛化和收敛速度的优势得到广泛关注, 1992年W.Yiu-

fai^[12], 等人证明了只要输入空间被量化得足够好, 分辨率足够高, 则CMAC可以任意精度逼近任意非线性函数, 不过带来的问题是量化级数越高存储开销越大, 计算越复杂, 导致故障学习的实时性降低; 同时常规CMAC的HASHING映射技术又造成数据碰撞的发生, 也使得CMAC的逼近性能下降. 为了提高CMAC学习速度, 文献[13]将模糊集引入CMAC中, 提出了一种模糊CMAC算法, 省去了CMAC的离散、量化、编码、HASHING映射等运算, 提高了故障学习速度和精度. 文献[14]针对常规CMAC权值调整的误差平均分配方法, 从CMAC权值学习遗忘的角度出发, 提出一基于信度分配的权值学习策略, 在此基础上, 文献[15]从网络权值“学习”和“遗忘”平衡的角度, 进一步提出一CMAC平衡学习算法. 本文将平衡学习思想推广应用到动态非线性系统在线故障辨识中, 从而达到提高动态系统故障辨识实时性的目的.

在容错控制器设计方面, 目前研究较多的是控制律重新调度的方法^[16]和模型跟随重组控制方法^[17], 控制律重新调度方法首先必须准确检测系统故障, 其次必须预先了解各种故障模式, 对未知故障模式无能为力; 而模型跟随重组控制方法其主要不足是缺少有效的方法对控制算法中的参数矩阵进行优化. 本文在基于平衡学习CMAC神经网络快速故障辨识的基础上, 利用变结构滑模控制算法进行控制规律的在线重构^[18,19]. 将在线CMAC神经网络故障诊断算法与容错控制器在线设计相结合, 构造一自适应的集成故障诊断与容错控制系统.

2 集成故障诊断与容错控制 (Integrated fault diagnosis and fault-tolerant control)

集成故障诊断与容错控制系统是将系统故障诊断与容错控制律重构进行在线综合. 利用在线故障检测与辨识器实现故障在线监测与辨识, 未发现故障时, 系统在正常模式下运行; 当探测到故障发生后, 初始化在线故障辨识器, 进行在线故障诊断, 同时在线重构控制规律. 以基于平衡学习的CMAC神经网络为故障诊断的手段, 根据故障学习评估结果, 由离散滑模控制算法进行控制律重构, 以保证系统的稳定性和控制性能.

2.1 基于平衡学习的CMAC学习算法 (The balanced learning-based CMAC algorithm)

CMAC网络又称为CMAC模型. 它具有学习速度快、无局部极小点和局部泛化性能. 能够学习任意多维非线性函数, 因此得到广泛的关注. CMAC的基本思想就是将学习的数据(知识)存储在交叠的存储单元(记忆空间)中, 其输出为相应激活单元数据的累加和. 常规CMAC模型包括两方面运算: 一

是结果计算输出; 二是网络权值(存储的数据)学习调整. CMAC可用来逼近函数 $y = f(x)$, 其中 $x \in X \subset \mathbb{R}^n, y \in Y \subset \mathbb{R}^m$, 并由映射 $X \rightarrow A \rightarrow Y$, A 为 N 维存储单元空间, $a \in A \subset \mathbb{R}^N$ 为二进制联想向量. 使输入 X 激活 N_L ($N_L < N$)个存储单元; 映射 $A \rightarrow Y$ 完成存储单元的权值求和:

$$y_i = \sum_{j=1}^{N_L} w_j a_j(x), i = 1, \dots, m. \quad (1)$$

式(1)中 w_j 为第 j 个存储单元的权值, 若 $a_j(x)$ 激活, 则其值为1, 否则为0, 因此只有 N_L 个被激活的存储单元对输出有影响. 常规CMAC算法中利用误差平均分配来调整权值, 训练规则为:

$$w_j^k = w_j^{k-1} + \rho(y_d - \sum_{j=1}^{N_L} w_j^{k-1} a_j(x))/N_L, \quad (2)$$

其中: y_d 为期望值, ρ 为学习率. 在上面的常规算法中误差被平均分配到所有被激活的存储单元, 但是经过 $k-1$ 次迭代后, 最初的存储单元已经包含了一些先前学习的知识, 不是每一个存储单元都有相同的学习历史, 所以这些存储单元也不应有相同的可信度. 无视这些差异, 所有被激活的存储单元都获得相同的校正误差, 那么那些由未学习状态产生的误差将对先前学习的信息产生“腐蚀”(corrupt), 使网络权值学习需要反复调整, 从而使学习时间延长, 实时性降低.

为了克服常规CMAC神经网络的“腐蚀”效应, 文献[14]提出了信度分配的概念, 校正误差必须根据存储单元的可信度进行分配; 文献[15]在此基础上提出一种“基于平衡学习的CMAC学习算法”, 本文称为ICMAC(Improved CMAC) 此时式(2)被改写为:

$$w_j^k = w_j^{k-1} + \rho \left\{ \frac{(f(j)+1)^{-p}}{\sum_{l=1}^{N_L} (f(l)+1)^{-p}} \right\} (y_d - \sum_{j=1}^{N_L} a_j w_j^{k-1}). \quad (3)$$

式(3)中 $f(j)$ 是激活存储单元的学习次数, p 是一平衡学习常数, 很明显当 p 为0或1时, 基于平衡学习CMAC模型分别为常规CMAC和文献[14]的基于信度分配的CMAC模型. 也就是说, 常规CMAC和基于信度分配的CMAC是基于平衡学习CMAC的一种特殊情形.

$f(j)$ 越大, 则其存储的知识(先前学习的信息)越多; 平衡学习常数 p 越大, 对学习次数 $f(j)$ 较大的存储单元, 其权值改变较少. 在 p 很大时, 对学习次数 $f(j)$ 较大的存储单元其权值基本不变. 此时未学习的或者学习次数 $f(j)$ 较少的激活单元在权值修正时, 将获得大多数误差校正. 此种情形下, 网络学习中“记忆”即“已学习知识的保持”占主导地位.

反之当 p 值很小时, 学习次数 $f(j)$ 对信度分配的

影响也较小. 当 $p=0$ 时, 学习次数 $f(j)$ 对信度分配的影响为零. 此时, 误差被平均分配到所有被激活的存储单元. 所有被激活的存储单元都有相同的信度分配, 而不管学习次数 $f(j)$ 的大小. 这时在网络学习中“遗忘”占主导地位.

可见 p 是一平衡学习常数, 它反映了在网络训练过程中, 先前学习的信息与未学习或少学习信息对存储单元权值调整的影响程度. 对不同的非线性函数, 不同的 p , 平衡学习CMAC将会有不同的学习结果. 在后面的故障学习中 $p=0.8$ 时, 其学习速度最快. 说明此时网络的“记忆”与“遗忘”达到了最佳平衡. 关于平衡学习算法更具体内容见文献[15]. 本文将平衡学习CMAC神经网络模型引入非线性系统故障辨识之中, 实现动态非线性系统快速故障诊断.

2.2 容错控制器的设计 (The design of fault-tolerant control)

滑模控制系统的最大特点就是系统具有极强的鲁棒性, 即对被控对象的模型误差, 对象参数的变化以及外部干扰具有不敏感性. 其基本原理是: 根据系统状态和某些预先设定的超平面之间的关系来重构系统控制器, 即当系统状态穿越系统状态空间预先设定的超平面时, 控制系统从一个结构自动转向另外一个确定的结构, 以保证系统状态变量达到并约束在给定的超平面上, 并使之自始至终沿着滑模超平面运行至系统状态空间的平衡点, 从而使系统性能达到某个期望的指标. 容错控制的目的是要尽量保证动态系统在发生故障时仍然可以稳定运行, 且具有可以接受的性能指标. 可见应用变结构滑模控制算法在线构造容错系统的控制规律是合理而有效的. 当系统发生故障后, 通过控制规律重构的方法对故障系统进行调节, 控制器重构设计是根据故障系统的新环境, 重新设置系统的工作点, 并给出可改善系统性能的新控制器. 考虑如下未知的非线性故障系统:

$$y(k+1) = y(k) + \Delta t [\hat{f}(y(k)) + g(y(k))u(k)] + \sum_{i=1}^n \beta_i(k - T_i) f_i(y(k)), \quad (4)$$

此处式(4)代表一类实际非线性控制系统, 如文献[18]的直流电机控制模型等. 其中 $\sum_{i=1}^n \beta_i(k - T_i) f_i(y(k))$ 为故障项, $u(k)$ 为系统控制输入信号, $y(k)$ 为系统输出函数, $g(y(k)) = \Delta g \hat{g}(y(k))$, 令 $1/\mu \leq \Delta g \leq \mu$, 且 $\mu \geq 1$. $\hat{f}(y(t))$ 和 $\hat{g}(y(t))$ 为状态矢量 $y(t)$ 的已知非线性函数, Δt 为采样周期, $\beta_i(k - T_i)$ 为故障形式, 一般有渐进性故障(如系统的元件老化等)和突发性故障(如系统部件失效等) T_i 是故障发生的时间, $f_i(y(k))$ 代表第 i 个未知故障模式, 此处设为系统

输出矢量的函数.

容错控制的目标就是在故障情形下, 产生使系统稳定的控制信号, 尽可能使系统回到期望轨迹, 而控制信号的产生又与故障的特性密切相关, 因此首要的任务是在线辨识故障. 本文应用改进的CMAC神经网络设计故障辨识器, 此辨识器可以逼近任意的非线性函数, 假设辨识器输出值为 $NF(k)$. 定义 $F(k)$ 为系统第 k 步的故障数值, 一般说来, $F(k)$ 是未知的. 可用在线故障辨识器来近似它, $F(k)$ 可表达为:

$$F(k) = NF(k) + \Delta NF(k), \quad (5)$$

$\Delta NF(k)$ 为在线故障辨识器的故障辨识误差, 可以看作是系统的不确定性, 利用文献[18, 19]的离散非线性不确定系统滑模控制规律的设计思想. 在不同的故障模式下, 容错控制律 $u(k)$ 可以在正常控制律 $u_1(k)$ 的基础上增加一纠错控制律 $u_2(k)$ 来实现, 这样容错控制 $u(k) = u_1(k) + u_2(k)$. 其中正常控制律为:

$$u_1(k) = \frac{D(k)}{D(k)\hat{g}(y(k))} [-\hat{f}(y(k)) + \frac{\Delta y_d}{\Delta t}]. \quad (6)$$

纠错控制律 $u_2(k)$ (具体推导见文献[20]):

$$u_2(k) = \frac{K(k)}{D(k)\hat{g}(\cdot)} \text{sat} \left(\frac{S(k)}{\phi(k)} \right) + U(k-T) \frac{-NF(\cdot)}{\hat{g}(\cdot)}, \quad (7)$$

式(7)第1项与神经网络故障辨识器的故障辨识误差有关. 其第2项 $U(k-T) \frac{-NF(\cdot)}{g(\cdot)}$ 是用来补偿正常控制器的纠正信号, T 为故障发生时间. $NF(\cdot)$ 是跟踪故障 $\sum_{i=1}^n \beta_i(\cdot) f_i(\cdot)$ 的在线辨识器输出.

为了使问题简化且不影响容错控制本质, 令 $\mu = 1$, 则 $\Delta g = 1$, 也即 $g(y(k)) = \Delta g \hat{g}(y(k))$ 是已知的. $\phi(k)$ 为边界层厚度, $K(k)$ 是控制增益, Ω 为用来评估控制效果的在线辨识器参数, δ 为其阈值.

$$\phi(k) = \Delta t [\eta(k) + \varepsilon], \quad (8)$$

$$K(k) = \eta(k) + 2\varepsilon, \quad (9)$$

此处 η 是一微小的正数, $\eta(k)$ 则按下式动态更新:

$$\eta_{\text{new}}(k) = \begin{cases} \sup_L \{ |D(k) \Delta NF(\cdot)| \} = \\ \sup_L \{ |D(k) \tilde{g}(k) - D(k) NF(k)| \}, & \Omega \leq \delta, \\ \eta_{\text{old}}, & \text{其他}, \end{cases} \quad (10)$$

$$S(k) = \frac{y_d(k) - y_d(k-1)}{\Delta t} - \frac{y(k) - y(k-1)}{\Delta t} + m(y_d(k) - y(k)), \quad (11)$$

$$D(k) \approx \frac{S(k+1) - S(k)}{\tilde{y}(k+1) - \tilde{y}(k)}, \tilde{y}(k) = y_d(k) - y(k), \quad (12)$$

式中: y_d 是系统第 k 步的期望输出, $\phi(k)$ 是边界层厚度, 故障辨识误差 $\Delta NF(\cdot)$ 为故障系统的不确定性. 参数 l 表示一时间周期, 在每一个时间段 $L \in [k-l, k]$, 故障辨识误差的上界被评估. 式(8)的边界层厚度和控制器增益根据在线评估器输出在线自动调整, 以进一步减少控制误差. 在线学习结果按下列准则进行监测和评估:

$$SSAE0 = \sum_{k=k_0}^{k_0+l-1} (fy(k) - nfy(k))^2, \quad (13)$$

$$SSAE1 = \sum_{k=k_0+l}^{k_0+2l-1} (fy(k) - nfy(k))^2, \quad (14)$$

$$\Omega = |SSAE1 - SSAE0|. \quad (15)$$

此处 $SSAE0$ 和 $SSAE1$ 代表两个连续窗口在线辨识器近似误差的平方和. $nfy(k)$ 是辨识器输出, $fy(k)$ 为系统第 k 步实际测试值与正常模型输出的差值. Ω 为在线辨识器参数, δ 为一阈值. 当 $\Omega \leq \delta$ 时, 表明在线辨识器足够精确, ICMAC 神经网络故障辨识器收敛.

2.3 容错控制器的实现 (The realization of fault-tolerant control)

根据上述讨论, 容错控制可按以下步骤实现:

第1步 离线获取系统正常模型, 设计正常状况控制器. 定义系统正常工作范围, 以便定义故障探测阈值 λ . 简单的故障探测准则为: $\psi = \frac{1}{\omega} \sum_{k=k_0}^{k_0+\omega-1} (y_d(k) - y(k))^2$, 当 $\psi > \lambda$, 则故障发生.

第2步 设定初始化参数 η_0 , 决定阈值 δ , 设定参数 l ; 一旦 $\psi > \lambda$ 则故障发生, 初始化故障辨识器, 应用期望目标输出与实际测试输出的差值, 作为神经网络在线故障辨识器的期望输出, 进行故障在线学习; 如果 $\psi \leq \lambda$, 则系统一直处于正常范围, 不必启动故障辨识器.

第3步 加入纠正控制信号 u_2 , 在每个时间段 l 计算 Ω 值, 如果 $\Omega \leq \delta$, 调整系统不确定的上界 $\eta(k)$, 更新 u_2 .

第4步 采集下一故障训练模式值, 继续训练故障辨识器, 同时观察故障辨识器故障误差, 返回第3步.

3 集成容错控制仿真 (Simulation of the integrated fault-tolerant control)

3.1 非线性模型 (Nonlinear model)

为了进一步说明所提故障诊断和控制规律重构算法的有效性, 考虑下面的 SISO 正常系统模型:

$$y(k+1) = y(k) - \Delta t[a * y(k)^2 + b * (y(k-1))] + \Delta t u(k), \quad (16)$$

其中: $y(k+1)$ 和 $u(k)$ 分别表示系统在 $k+1$ 和 k 的输出与控制输入, Δt 是采样周期, a 和 b 是已知的系统参数. 在不可预知故障模式下(此处设为单故障, 且为渐近型故障形式), 系统由以下方程表达:

$$y(k+1) = y(k) - \Delta t[ay(k)^2 + by(k-1)] + \Delta t[u(k) + \beta(k-T)f(y(k), y(k-1))], \quad (17)$$

其中令 $f(y(k), y(k-1)) = c \sin y(k) \cos y(k-1)$ 假定未知, c 表示未知增益. 渐近型故障形式为

$$\beta(k-T) = (1 - e^{-\alpha(k-T)})U(k-T), \quad (18)$$

其中: $\delta = 0.01$, $a = 5$, $b = 100$, $c = 0.5$, $T = 100$, $\alpha = 0.05$, $U(\cdot) = 1$. 为了跟踪期望曲线 $y_d(k+1)$, 则正常情况的控制输入 $u_1(k)$ 由式(16)决定:

$$u_1(k) = \frac{1}{\Delta t} \{-y(k) + \Delta t[a * y(k)^2 + b * y(k-1)] + y_d(k+1)\}. \quad (19)$$

参考输入: $r(k) = 0.2 \sin(\frac{k\pi}{20}) + 0.2 \cos(\frac{k\pi}{30})$, 期望输出: $y_d(k+1) = r(k)$, 其他参数选择如下: $m = 10$, $\omega = 5$, $\lambda = 3 * 10^{-5}$, $\eta_0 = 0.5$, $\delta = 0.001$, $l = 10$, 神经网络学习率 $\rho = 1$, 平衡学习参数 $p = 0.8$.

3.2 仿真结果分析 (Simulation result analysis)

在渐进型故障形式下, 所得仿真结果如图1至图5. 当仅有正常控制器单独作用时, 图1显示了系统在500个采样周期的实际输出与期望输出, 在第100个周期突然加上一渐进型故障后, 系统实际输出与期望轨迹出现较大偏差, 可见系统的控制性能下降.




图1 正常控制器单独作用系统实际输出与期望输出
Fig. 1 The system response vs. desired output with nominal controller only

图2显示了加入纠正控制律 $u_2(k)$ 后系统的输出特性. 很明显, 系统的性能得到了较大的改善, 容错控制器成功地驱动未知故障系统回到期望的输出轨迹上, 而且仅有很小波动. 实际上在第116周期时, 故障即被系统检测到, 初始化故障在线辨识器在线辨

识故障,同时加入纠正控制信号 $u_2(k)$,在第137个周期,在线故障辨识器收敛。

图3为在线故障辨识器的误差曲线,在第116周期前,其数值为零,因为系统是在116周期后才检测到故障存在,从而启动故障辨识器。在刚刚初始化在线故障辨识器后,其故障辨识误差较大,接着很快变小,收敛于137周期,其后在一个很小的范围内波动。




图2 加入纠正控制律后系统实际输出与期望输出
Fig. 2 The system response vs. desired output with the alternative corrective control law




图3 ICA-CMAC 故障辨识器的辨识误差
Fig. 3 The ICA-CMAC model identification error with the alternative corrective control law

图4给出了实际的窗函数和边界层曲线,从中可见,容错控制器在线不断调整边界层厚度,同时滑模窗函数被限制于边界层内,根据滑模控制原理,说明滑模边界层是吸引的,系统能够稳定。




图4 窗函数S和系统边界层厚度

Fig. 4 The S function and the estimated boundary layer thickness

图5显示了系统的实际控制信号 $u(k)$,它在116周期前仅有正常控制律 $u_1(k)$,在116到137周期之间它是一个变化的数值,这时纠正控制律 $u_2(k)$ 已加入,

但故障评估器还未收敛, $u_2(k)$ 的变动较大,在137周期后控制信号 $u(k)$ 趋于稳定,系统也趋于稳定。




图5 系统的实际控制信号

Fig. 5 The control input with the alternative corrective control law

从以上仿真结果可以看出,基于平衡学习的CMAC神经网络能即时准确地在线辨识系统故障,在此基础上应用滑模容错控制成功驱动故障系统回到期望曲线,使系统稳定。

4 小结 (Conclusion)

本文针对渐进型非线性故障模式,以基于平衡学习的CMAC神经网络为非线性故障诊断的手段,在此基础上,利用离散滑模控制算法实现动态非线性系统的在线容错控制,以保证系统的稳定性和控制性能。仿真结果表明容错控制器成功驱动故障系统回到期望曲线,取得了较好的控制效果。

参考文献 (References):

- [1] PATTON R J. Fault-tolerant control: The 1997 situation(survey)[C]// *Proc of Int Federation of Automatic Control(IFAC) Symposium. Fault Detection, Supervision, and Safety for Technical Processes*. Hull: England, 1997: 1029 – 1052.
- [2] ISERMANN R, SCHWARZ R, STOLZL S. Fault-tolerant drive-by-wire systems-concepts and realization[C]// *Proc of Int Federation of Automatic Control(IFAC) Symposium. Fault Detection, Supervision, and Safety for Technical Processes*. Safeprocess: Budapest, 2000: 1 – 15.
- [3] 陈茂银, 周东华. 线性系统的鲁棒故障诊断[J]. *控制理论与应用*, 2005, 22(5): 718 – 722.
(CHEN Maoyin, ZHOU Donghua. Robust fault diagnosis of linear systems[J]. *Control Theory & Applications*, 2005, 22(5): 718 – 722.)
- [4] WANG H, HUANG Z J, DALEY S. On the use of adaptive updating rules for actuator and sensor fault diagnosis[J]. *Automatica*, 1997, 33(2): 217 – 225.
- [5] KABORE P, WANG H. Design of fault diagnosis filters and fault-tolerant control for a class of nonlinear systems[J]. *IEEE Trans on Automatic Control*, 2001, 46(11): 1805 – 1809.
- [6] CHEN S H, TAO G, JOSHI S M. Adaptive control scheme for systems with unknown actuator failures[J]. *Automatica*, 2002, 38(8): 1027 – 1034.

- [7] ZHANG X, PARISINI T, POLYCARPOU M M. Adaptive fault-tolerant control of nonlinear uncertain systems: An information-based diagnosis approach[J]. *IEEE Trans on Automatic Control*, 2004, 49(8): 1259 – 1274.
- [8] ASHARI A E, SEDIGH A K, YAZDANPANAHI M J. Reconfigurable control system design using eigenstructure assignment: static, dynamic and robust approaches[J]. *Int J Control*, 2005, 78(13): 1005 – 1016.
- [9] POLYCARPOU M M. Fault Accommodation of a class of multivariable nonlinear dynamical systems using a learning approach[J]. *IEEE Trans on Automatic Control*, 2001, 46(5): 737 – 742.
- [10] ALBUS J S. A new approach to manipulator control: The cerebellar model articulation controller(CMAC)[J]. *J of Dynamic Systems, Measurement and Control*, 1975, 79(2): 220 – 227.
- [11] ALBUS J S. Data storage in cerebellar model articulation controller(CMAC)[J]. *J of Dynamic Systems, Measurement and Control*, 1975, 79(2): 228 – 233.
- [12] YIU F W, ATHANASIOS S. Learning convergence in the cerebellar model articulation controller[J]. *IEEE Trans on Neural networks*, 1992, 3(1): 115 – 121.
- [13] NIE J, LINKENS D A. FCMAC: A fuzzified cerebellar model articulation controller with self-organizing capacity[J]. *Automatica*, 1994, 30(4): 655 – 664.
- [14] SHUN F S, TED T, HUNG T H. Credit assigned CMAC and its application to online learning robust controllers[J]. *IEEE Trans on Systems, Man, and Cybernetics-part B: Cybernetics*, 2003, 33(2): 202 – 213.
- [15] 朱大奇, 张伟. 基于平衡学习的CMAC神经网络非线性辨识算法[J]. *控制与决策*, 2004, 19(12): 1425 – 1428.
- (ZHU Daqi, ZHANG Wei. Nonlinear identification algorithm of the improved CMAC based on balanced learning[J]. *Control and Decision*, 2004, 19(12): 1425 – 1428).
- [16] GAO Z, ANTSAKLIS P J. Stability of the pseudo-inverse method for reconfigurable control systems[J]. *Int J Control*, 1991, 55(3): 717 – 729.
- [17] HANG M L, YEONG M L, KUEI H C. A VSS speed controller with model reference response for induction motor drive[J]. *IEEE Trans on Industrial Electronics*, 2001, 48(6): 1136 – 1142.
- [18] MISAWA E A. Discrete-time sliding mode control for nonlinear systems with unmatched uncertainties and uncertain control vector[J]. *J of Dynamic Systems, Measurement, and Control*, 1997, 119(4): 503 – 511.
- [19] DRAKUNOV S, UTKIN V. On discrete-time sliding modes[C] // *Proc of Int Federation of Automatic Control(IFAC) Symposium on Nonlinear Control System Design*. England: [s.n.], 1998: 484 – 489.
- [20] ZHU D Q, KONG M. Fault-tolerant control of dynamic nonlinear system using credit assign fuzzy CMAC[J]. *Acta Automatica Sinica*, 2006, 32(3): 329 – 336.

作者简介:

朱大奇 (1964—), 男, 上海海事大学信息工程学院教授, 博士生导师, 目前主要研究方向为故障诊断与容错控制、多传感器信息融合, E-mail: zdq367@yahoo.com.cn;

孔敏 (1981—), 女, 江南大学智能控制研究所硕士生, 主要研究方向为故障诊断与容错控制。