

# 基于 CA-CMAC 的快速传感器故障诊断方法

朱大奇, 陈楚瑶, 颜明重

(上海海事大学信息工程学院, 上海 200135)

**摘要:** 针对动态系统的在线故障诊断问题, 将信度分配小脑神经网络 CA-CMAC (Credit Assigned Cerebellar Model Articulation Controller) 应用于主元分析模型, 实现多传感器在线故障检测与隔离. 首先, 应用传感器正常工作时测量的历史数据, 由主元分析模型得到所有传感器的预测值; 接着计算传感器系统的均方预期误差值 SPE (Squared Prediction Error), 由 SPE 值的变化, 判定是否发生故障, 根据重构单个传感器信号的特 SPE 值来隔离故障传感器; 最后应用一个多传感器故障诊断仿真实例说明了该算法的可行性, 并通过与误差反传 BP (Back Propagation) 神经网络和常规小脑神经网络 CMAC (Cerebellar Model Articulation Controller) 进行比较, 说明了基于 CA-CMAC 的主元分析模型的优越性.

**关键词:** 主元分析; 故障检测; 故障隔离; 信号重构

**中图分类号:** TP18; TP274 **文献标识码:** A **文章编号:** 0372-2112 (2008) 08-1646-05

## Fast Sensor Fault Diagnosis Method Based on CA-CMAC

ZHU Da qi, CHEN Chu yao, YAN Ming zhong, YAN Ming zhong

(Information Engineering College, Shanghai Maritime University, Shanghai 200135, China)

**Abstract:** For the problem of fault diagnosis in dynamic system, a principal component analysis model based on credit assigned cerebellar model articulation controller is proposed to carry out online fault detection and isolation for multiple sensor system. Firstly, the forecasting values of sensors are available from historical data measured in fault free condition based on principal component analysis model. Secondly, the Squared Prediction Error of the system is calculated, the fault occurred when the SPE is suddenly increased. Sensor values are reconstructed respectively to newly calculate the SPE to locate the faulty sensor. Finally, Compared to BP and CMAC, the method proposed is proved feasible and effective by a simulation of multiple sensor fault diagnosis.

**Key words:** principal component analysis; fault detection; fault isolation; signal reconstruction

## 1 引言

由于主元分析能有效地降低输入数据的维数, 提取有用信息, 提高数据分析的效率, 因此被广泛地应用于故障诊断领域<sup>[1-4]</sup>. 随着神经网络发展的日趋成熟, 一些基于误差反传 BP (Error Back Propagation) 神经网络<sup>[5]</sup>, 径向基函数 RBF (Radial Basis Function) 神经网络<sup>[6-8]</sup>, 自组织映射 SOM (Self Organizing Mapping) 神经网络<sup>[9]</sup> 的主元分析及信号重构模型在故障诊断领域不断被讨论. 但由于故障诊断系统对实时性要求较高, 而上述模型的结构复杂, 参数设计困难, 收敛性差, 影响了模型的实际应用效果. 特别是 BP 神经网络, 由于其全局逼近网络的特性, 收敛速度慢, 同时局部极小的存在, 使其在故障诊断系统中, 不仅难以达到实时性的要求, 而且诊断精度也存在不确定性<sup>[10, 11]</sup>. 本文针对在线故障诊断系统对实时性要求高的特性, 提出一种基于信度分配的小脑神经网络的主元分析故障诊断模型, 应用于多传感器信号

在线预测, 实现传感器系统故障在线检测与隔离. 仿真证明, 常规 CMAC 算法在学习速度与精度上远远超过了 BP 神经网络, 而且 CA-CMAC 算法进一步改善了 CMAC 性能, 提高了学习效率.

## 2 CMAC 神经网络模型

CMAC 神经网络算法由 J. S. Albus 于 1975 年提出<sup>[12, 13]</sup>, 是仿照小脑控制肢体运动的原理而建成的神经网络模型, 是一种局部逼近网络, 具有线性结构, 算法简单, 速度快, 精度高等特点, 有一定的泛化能力, 已经成功的应用于机器人控制, 模糊控制和非线性时间序列分析等领域<sup>[14, 15]</sup>. 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. 但随着输入空间的增加, 联想记忆空间急剧增加, 为节省存储空间, Albus 引入了 Hash Coding 编码方法, 但 Hashing 映射会造成数据碰撞的发生, 使得 CMAC 的逼近性能下降. 对此文献

[16] 用地址函数来产生所需要的存储单元的标识, 通过一定的规则为所有可能的存储单元编码, 由输入状态直接计算出激活的地址单元, 并且不存在数据碰撞等问题, 同时 Shurr-Feng S. 等还提出一种基于信度分配的权值调整算法, 有效提高了 CMAC 网络的学习效率。

### 2.1 常规 CMAC 算法

CMAC 算法实现过程分两个阶段: 结果输出阶段和权值学习阶段。结果输出阶段从 CMAC 存储单元产生一实际输出, 学习过程根据期望输出与实际输出的大小来更新 CMAC 存储单元中的权值。设  $S$  为某一状态,  $w_j(t)$  是经过第  $t$  次迭代后存储在第  $j$  个存储单元中的权值。在常规的 CMAC 算法中, 误差被平均分配到所有被激活的单元,  $w_j(t)$  更新的算法为:

$$w_j(t) = w_j(t-1) + \frac{\alpha}{m} a_j \left( \bar{y}_s - \sum_{j=1}^N a_j w_j(t-1) \right) \quad (1)$$

其中,  $\bar{y}_s$  为状态  $S$  的期望输出,  $\sum_{j=1}^N a_j w_j(t-1)$  为状态  $S$  的实际输出,  $\alpha$  为学习常数。只有被激活的存储单元的权值才会被更新。

### 2.2 基于信度分配的 CMAC 神经网络 (CA-CMAC)

在上述算法中, 误差被平均分配到所有被激活的单元, 但是 CMAC 经过  $t-1$  次迭代以后, 最初的存储单元已经包含了先前学习的知识, 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该有相同的可信度。假设存储单元更新次数越多, 其存储的值越可靠。因此, 存储单元的学习次数被看成其可信度, 可信度越高, 其权值修正越小。设  $f(j)$  是第  $j$  个存储单元的学习次数,  $m$  是某状态激活的存储单元数, 此种算法的思想是校正误差必须与激活单元的学习次数成反比, 用

$(f(j)+1)^{-1} \setminus \sum_{l=1}^m (f(l)+1)^{-1}$  代替式(1)中的  $1/m$ , 能够有效的改善学习性能。具体算法写为<sup>[16]</sup>:

$$w_j(t) = \frac{w_j(t-1) + \alpha a_j (f(j)+1)^{-1}}{\sum_{l=1}^m (f(l)+1)^{-1}} \left( \bar{y}_s - \sum_{j=1}^N a_j w_j(t-1) \right) \quad (2)$$

## 3 基于主元分析的传感器故障诊断模型

### 3.1 主元分析原理及信号预测模型

主元分析 PCA (Principal Component Analysis) 是一种能够处理数据相关性的统计分析技术, 能对高维原始变量进行降维处理, 忽略具有较小方差的线性组成部分, 保留具有较大方差项, 最大限度地携带原变量中的有效信息, 实现数据的有效压缩。设原始变量  $X = (X_1, X_2, \dots, X_m)^T$  为一  $m$  维随机矢量, 根据  $X$  的协方差矩阵的特征值, 可以求出显著性水平为  $\alpha$  的前  $s$  个能够代表随机变量  $X$  的各个分量共同特征的主成分数据分量  $Y_1, Y_2, \dots, Y_s$ , 一般  $s$  远小于  $m$ ,  $\alpha$  为介于 0 到 1 之间的数。对这  $s$  个主成分利用 CA-CMAC 神经网络进行建模预测, 对后  $m-s$  行数据, 因其数值一般相对较小, 对精度的影响很小, 所以不必建模<sup>[17]</sup>。在对传感器系统进行故障诊断时, 对于前  $s$  个主成分数据分量  $Y_1, Y_2, \dots, Y_s$ , 分别通过各自对应的已训练的 CA-CMAC 神经网络对其进行信号预测, 预测得到下一时刻的主成分  $Y'_i$ , ( $i = 1, 2, \dots, s$ )。最后再按照逆正交变换:  $X' = PY'$ , 获得历史数据的预测值  $X'$ 。具体的信号预测模型如图 1 所示。

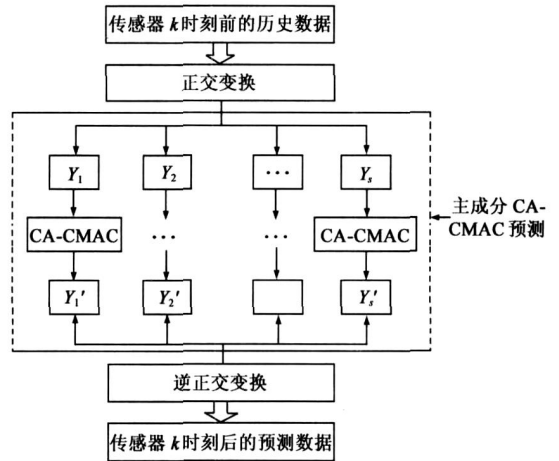


图 1 基于 PCA 的信号预测模型

和文献[5]的 5 层 BP 神经网络, 文献[6~8] 双 RBF 神经网络及文献[9]的 SOM 神经网络相比, 图 1 中应用 CA-CMAC 神经网络具有结构简单明了, 信号预测精度高的优点, 特别是其运算速度快的特点, 符合故障诊断系统对实时性的要求。本文应用该 PCA 信号预测模型进行多传感器故障检测与隔离。

### 3.2 基于主元分析的多传感器故障检测与隔离

#### 3.2.1 传感器故障检测

当传感器系统发生故障时, 根据新的实测数据样本与统计模型预测值的背离程度来检测故障, 在基于 PCA 的过程监控中, 通过对  $T^2$  和  $SPE$  统计量的检验可以实现故障检测, 一般会有四种检测结果: (1) 两者都不超过控制限; (2)  $T^2$  正常, 但  $SPE$  超过控制限; (3)  $T^2$  超出控制限, 但  $SPE$  正常; (4) 两者都超出控制限。本文同大多数文献一样, 认为(2)和(4)为故障, (1)和(3)为正常, 即以  $SPE$  统计量为判断标准。定义估计误差向量为:

$$e(k) = X(k) - \hat{X}(k) \quad (3)$$

$e(k)$  为各传感器在第  $k$  个时刻的误差向量,  $X(k) = [X_1(k), X_2(k), \dots, X_n(k)]$  为各传感器在第  $k$  个时刻的测量值,  $\hat{X}(k) = [\hat{X}_1(k), \hat{X}_2(k), \dots, \hat{X}_n(k)]$  为用  $k$  时刻前的历史数据由 PCA 模型得到的第  $k$  时刻数据的重构值, 则  $k$  时刻传感器系统的  $SPE$  值定义为:

$$SPE(k) = e^T(k) e(k) = \sum_{i=1}^n e_i^2(k) \quad (4)$$

正常无故障情况下, 误差较小, 因此  $SPE$  值很小, 但如果某传感器发生故障, 其实时测量值将与该时刻由 PCA 重构的数值有很大偏差, 显然其  $SPE$  会明显增大. 根据式(4) 计算可得传感器系统在各时刻  $SPE$  的变化曲线, 如果发现某时刻  $SPE$  值突然变大, 则表明该传感器系统有故障发生. 故障检测的规则为:

$$\begin{cases} SPE(k) < \delta_a, & \text{传感器系统无故障} \\ SPE(k) \geq \delta_a, & \text{传感器系统有故障} \end{cases} \quad (5)$$

其中  $\delta_a$  是  $SPE$  的故障阈值.

### 3.2.2 传感器故障隔离

检测到传感器系统发生故障后, 为了能及时排除故障, 必须能够准确发现故障源. 对一般的传感器系统来说, 在系统工作的同一时刻, 多个传感器同时出现故障, 是有可能的, 但其概率很小, 因此, 绝大多数故障诊断问题, 均是对单故障进行检测与隔离, 本文也主要讨论单故障诊断. 在此, 我们应用 Dunia 等曾提出的传感器故障隔离的线性变量重构方法<sup>[1]</sup> 实现故障隔离. 该方法的思想是: 假设任何一个传感器都是可能的故障源(同一时刻是单个故障), 用基于 PCA 的信号预测模型重构假定有故障的传感器信号, 其他传感器信号仍保留为原输入变量, 通过检查重构前后的  $SPE$  值来确定故障传感器.

在传感器系统发生故障之后, 基于 PCA 的信号重构模型, 应用  $k$  时刻以前的测量数据, 可以得到各传感器  $k$  时刻的重构值,  $\hat{X}(k) = [\hat{X}_1(k), \hat{X}_2(k), \dots, \hat{X}_j(k), \dots, \hat{X}_n(k)]$ , 在传感器的测量值中仅对第  $j$  个传感器  $k$  时刻的信号进行重构, 定义实际测量信号为:  $\hat{X}(k) = [X_1(k), X_2(k), \dots, X_j(k), \dots, X_n(k)]$ , 由定义(3), (4):

$$\overline{SPE}_j(k) = \sum_{i=1, i \neq j}^n e_i^2(k) \quad (6)$$

其中,  $\overline{SPE}_j(k)$  表示重构了第  $j$  个变量之后的  $SPE(k)$  值, 因此, 一旦有故障的传感器测量值被重构,  $\overline{SPE}_j(k)$  值会由于故障被重构排除, 而处于故障阈值以内. 相反, 若重构的不是故障变量,  $\overline{SPE}_j(k)$  值则仍会受故障影响, 而处于故障阈值之外. 总之, 当故障被检测出来, 分别计算重构后各传感器的  $\overline{SPE}_j(k)$  值, 若满足  $\overline{SPE}_j(k) \leq \delta_a^2$ , 则可以确定第  $j$  个传感器是有故障的, 从而实现传感器故障隔离.

## 4 仿真算例

### 4.1 传感器模型

设仿真系统由三个传感器组成, 其输出信号分别按照如式(7) 定义:

$$\begin{cases} x_1 = t^2 + 0.3 * \cos 2\pi t + e_1 \\ x_2 = t + e_2 \\ x_3 = t^3 + t + 1 + e_3 \end{cases} \quad (7)$$

$e$  是分布在  $[-0.1, 0.1]$  上的独立白噪声变量,  $t$  是定义在  $[-1, 1]$  上的变量,  $\Delta t = 0.005$ , 采用 400 个训练数据点.

### 4.2 基于主元分析的传感器故障诊断

#### 4.2.1 传感器故障检测

根据基于 PCA 信号预测模型, 通过正交变换得到历史信号  $X = (x_1, x_2, x_3)$  的主成分矩阵  $Y$ , 得到显著性水平为 0.9941 的前 2 个主成分数据分量  $Y_1, Y_2$ . 随后, 通过 CA-CMAC 神经网络对  $Y_1, Y_2$  进行预测, 在此采用  $(t-3, t-2, t-1)$  时刻的数据, 预测  $t$  时刻的数据. 最后, 通过逆正交变换得到  $X$  的估计值  $\hat{X} = (\hat{x}_1, \hat{x}_2, \hat{x}_3)$ . 再由式(4) 计算系统  $SPE(k)$ . 图 2(a) 为正常无故障状况下的  $SPE(k)$  值. 可见, 在正常情况下,  $SPE(k)$  值处于比较平稳的状态, 且处于故障阈值 ( $\delta_a = 0.01$ ) 以下.

为了说明故障检测的过程, 本文采用 400 个采样点, 对变量  $x_1$  从 250 到 400 个采样点进行故障模拟, 故障的幅度达到变量  $x_1$  变差范围的 13%. 图 2(b) 是有故障的情况下系统的  $SPE(k)$  值, 明显看出, 从第 250 个采样点开始,  $SPE$  值发生跳变, 超过了控制阈值  $\delta_a$ , 因此根据故障检测原理可以断定系统发生了故障.

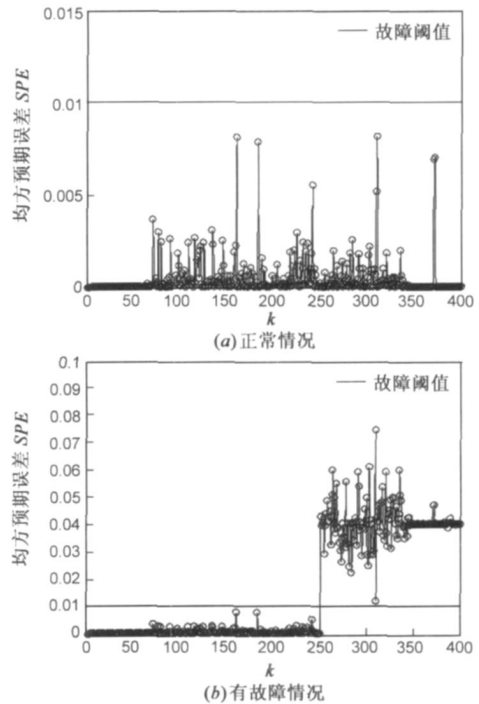


图 2 传感器系统的  $SPE(k)$  值比较

#### 4.2.2 传感器故障隔离

为对发生故障的传感器系统进行故障传感器的隔离, 分别单独对  $x_1, x_2, x_3$  进行重构. 由故障隔离原理, 若传感器  $j$  被重构后, 系统的  $\overline{SPE}_j(k)$  值小于控制阈值  $\delta_a$ , 则是传感器  $j$  发生了故障. 图 3 中分别显示了  $\overline{SPE}_1$  和  $\overline{SPE}_2$  值. 显然, 当  $x_1$  被重构后, 传感器系统的  $SPE$  值下降到故障控制阈值以下, 而当  $x_2$  被重构后, 传感器系

统的  $SPE$  值仍然处于故障控制阈值以上, 对  $x_3$  重构计算与  $x_2$  情况类似, 说明故障仍然没有被排除. 因此, 我们可以判定是变量  $x_1$ , 即传感器 1 发生了故障. 当明确传感器 1 发生故障后, 可以用估计值  $\hat{x}_1$  在短期内代替  $x_1$ , 模拟传感器 1 进行工作, 实现容错控制.

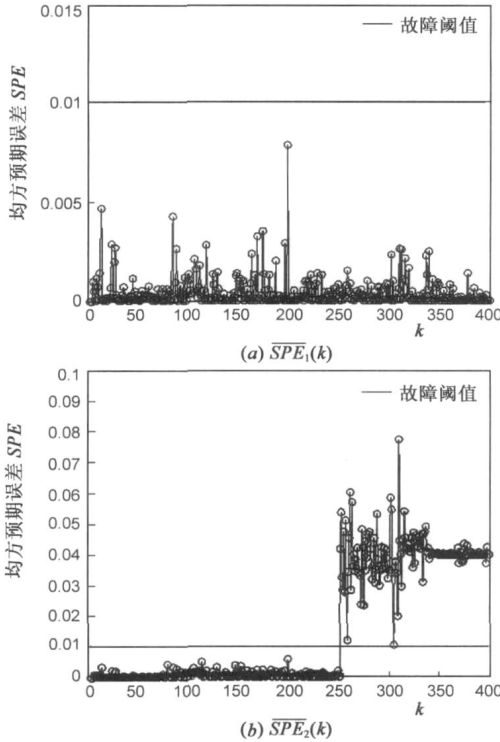


图 3 传感器值被重构后系统的  $\overline{SPE}_i(k)$  值

### 5 CA-CMAC 与常规 CMAC, BP 网络的性能比较

为了说明在本模型中采用的 CA-CMAC 神经网络的优势, 应用上述同样的传感器模型作为样本, 信号预测重构模型中分别采用不同的神经网络来比较各网络模型的预测性能. 其中 CMAC 与 CA-CMAC 采用同样的网络结构, 输入状态数为 3, 输出状态数为 1. BP 网络采用三层网络(输入层, 隐形层, 输出层), 各层的结点数分别为 3, 6, 1, 隐形层结点为 sigmoid 函数, 输出层结点为线性函数. 在比较不同结构 PCA 收敛速度时, 均采用均方误差(MSE)作为性能指标. MSE 定义如下:

$$MSE = \frac{1}{N} \sum_{k=1}^N (Y_{simk} - Y_{targetk})^2 \quad (8)$$

式中,  $Y_{simk}$  为网络输出值,  $Y_{targetk}$  为期望值,  $N$  为样本数.


针对本文的仿真算例, 图 4 给出在预测主元分量一和主元分量二的训练过程中, 均方误差值随学习周期下降情况曲线图. 从均方误差下降曲线可以明显看出, CA-CMAC 与 CMAC 的收敛速度远大于 BP 神经网络. 三种神经网络训练过程中两主元分量 MSE 值随周期变化的数据表如下:

表 1 采用不同的神经网络训练主元分量 1 时 MSE 随训练周期变化情况表

MSE \ 网络	训练周期					
	0	1	2	3	4	5
BP	1.241787	0.329584	0.110901	0.09208	0.044247	0.031561
CMAC	1.18143	3.49E-04	7.77E-04	6.77E-04	4.64E-04	2.43E-04
CA-CMAC	1.18143	1.88E-06	2.07E-06	2.24E-06	2.17E-06	1.89E-06

表 2 采用不同的神经网络训练主元分量 2 时 MSE 随训练周期变化情况表

MSE \ 网络	训练周期					
	0	1	2	3	4	5
BP	0.216519	0.044198	0.005617	0.002765	0.002501	0.002434
CMAC	0.161394	1.26E-04	6.96E-05	3.62E-05	1.47E-05	4.74E-06
CA-CMAC	0.161394	3.01E-05	4.76E-06	1.11E-06	3.58E-07	1.32E-07



从表格中的数据可以看出, CA-CMAC 的收敛速度远快于 BP 网络, 也高于 CMAC 网络, 满足故障诊断系统对实时性和误差的要求. BP 是一个全局逼近网络, 对于每一个输入输出数据对, 网络的每一个连接权值都需要进行调整, 且采用梯度下降算法, 从而导致速度较慢. CMAC 是局部逼近网络, 只调整部分权值, 采用简单的算法, 其收敛速度要比 BP 算法快很多, 且不存在局部极小问题, 在训练精度与训练时间上存在明显优势. 而 CA-CMAC 由于引入了信度分配的概念, 存储单元的学习次数越多, 其存储值越可靠, 使校正误差与激活单元的学习次数成反比, 避免了未学习状态产生的误差对先前学习的信息产生“腐蚀”, 从而进一步改善了 CMAC 的学习性能. 此外, 由于 BP 神经网络采用的是 Sigmoid 函数来反映神经元的饱和特性, 它为非线性函数, 因此使得 BP 网络易收敛于不同点(即造成输出结果不稳定), 甚至不收敛(即训练失败). 也就是说, 在采用 BP 进行多次训练时, 即使采用同一训练样本, 其输出结果也往往是不同的, 在训练样本产生波动时, 训练结果也会在个别点发生跳变. 而 CA-CMAC 网络可以看成是对外界函数的多维表查询系统, 只要调整泛化参数, 就能保证稳定的输出.

### 6 小结

通过比较基于 CA-CMAC, CMAC 和 BP 神经网络的信号预测及故障诊断模型的性能, 可以发现, 本文提出

的基于 CA-CMAC 神经网络的主元分析模型,具有输出稳定性好,计算速度快的优点,适用于动态系统的在线故障诊断.基于 CA-CMAC 神经网络的信号预测模型在多传感器故障诊断系统中的应用实例分析,也说明此模型在实际应用中的有效性.

#### 参考文献:

- [1] Dunia R, Qin S J, Edgar T F, McAvoy T J. Identification of faulty sensors using principal component analysis [J]. *AICHE Journal*, 1996, 42: 2797- 2812.
- [2] 仇韬,张清峰,丁艳军,吴占松,张毅,孔亮. PCA 在非线系统传感器故障检测和重构中的应用 [J]. *清华大学学报,自然科学版*, 2006, 46(5): 708- 711.  
Qu Tao, Zhang Qingfeng, Ding Yanjun, Wu Zhansong, Zhang Yi, Kong Liang. Nonlinear sensor fault detection and data rebuilding based on principle component analysis [J], *Journal of Singhua University*, 2006, 46(5): 708- 711. (in Chinese)
- [3] Ricardo Dunia, S Joe Qin, Thomas F Edgar and Thomas J M. Use of principal component analysis for sensor fault identification [J]. *Computers & Chemical Engineering*, 1996, 20(1): 713 - 718.
- [4] Rongyu Li, Gang Rong. Fault isolation by partial dynamic principal component analysis in dynamic process [J]. *Chinese Journal of Chemical Engineering*, 2006, 14(4): 486- 493.
- [5] William W Hsieh. Nonlinear Principal Component Analysis by Neural Networks [J]. *Tellus A*, 2001, 53A: 599- 615.
- [6] M Faouzi Harkat, Gilles Mourot, Jose Ragot. Nonlinear PCA combining principal curves and RBF Networks for process monitoring [A]. *Proceedings. 42th IEEE Conference on Decision and Control [C]*. Hawaii, USA, 2003. 1956- 1961.
- [7] 刘吉臻,牛征,牛玉广. 一种基于 RBF 神经网络的非线性 PCA 故障检测方法 [J]. *华北电力大学学报*, 2005, 32(5): 27- 31.  
Liu Ji zhen, Niu Zheng, Niu Yu guang. Nonlinear PCA fault detection method based on RBF networks [J]. *Journal of North China Electric Power University*, 2005, 32(5): 27- 31. (in Chinese)
- [8] Harkat M F, Mourot G. Variable reconstruction using RBF-NLPCA for process monitoring [A]. *IFAC Symposium on Fault Detection, Supervision and Safety for Technical Process [C]*. Washington, USA, 2003.
- [9] MA Kramer. Nonlinear principal component analysis using autoassociative neural networks [J]. *AICHE Journal*, 37(2): 233- 243.
- [10] Hinton G E, McClelland J L, Rumelhart D E. *Distributed Representation, Parallel Distributed Processing [M]*. Eds: MIP Press, 1986.
- [11] Kosko B. *A Dynamical Systems Approach to Machine Intelligence: Neural Networks and Fuzzy Systems [M]*. Englewood Cliffs, NJ: Prentice Hall, 1992.
- [12] Albus JS. A new approach to manipulator control: The cerebellar model articulation controller (CMAC) [J]. *Journal of Dynamic Systems, Measurement, and Control*, 1975, 97(2): 220 - 227.
- [13] Albus JS. Data storage in cerebellar model articulation controller (CMAC) [J]. *Journal of Dynamic Systems, Measurement, and Control*, 1975, 97(2): 228- 233.
- [14] 高阳,胡景凯,王本年,王冬黎. 基于 CMAC 网络强化学习的电梯群控调度 [J]. *电子学报*, 2007, 35(2): 362- 365.  
Gao Yang, Hu Jing kai, Wang Ben niang, Wang Dong li. Elevator group control using reinforcement learning with CMAC [J]. *Acta Electronica Sinica*, 2007, 35(2): 362- 365. (in Chinese)
- [15] Zhu Da Qi, Kong Min. Adaptive fault tolerant control of nonlinear systems: an improved CMAC-based fault learning approach [J]. *International Journal of Control*, 2007, 80(10): 1576- 1594.
- [16] Shur Feng 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.
- [17] 谢宏,陈志业,牛东晓. 短期电力负荷预测的数据主成分分析 [J]. *电力技术*, 2000, 24(1): 43- 46.  
Xie Hong, Chen Zhi ye, Niu Dong xiao. Principle component analysis of data processing for short term load forecasting [J]. *Power System Technology*, 2000, 24(1): 43- 46. (in Chinese)

#### 作者简介:

朱大奇 男, 1964 生于安徽安庆, 博士、教授、博导. 研究方向为故障诊断与容错控制.

E-mail: zdq367@yahoo.com.cn



陈楚瑶 女, 1983 生于湖北荆门, 硕士研究生. 研究方向为信号处理与故障诊断.

