

# 深海载人潜水器推进器系统故障诊断的新型主元分析算法

程学龙<sup>1</sup>, 朱大奇<sup>1†</sup>, 孙 兵<sup>1</sup>, 陈云赛<sup>2</sup>

(1. 上海海事大学 水下机器人与智能系统实验室, 上海 201306; 2. 国家深海中心, 山东 青岛 266237)

**摘要:** 针对“蛟龙号”深海载人潜水器多推进器系统的故障检测与快速定位难题, 将基于信度分配的模糊小脑神经网络(credit assignment-based fuzzy cerebellar model articulation controller, FCA-CMAC)应用于主元分析模型, 提出一种基于主元分析(principal component analysis, PCA)的深海载人潜水器推进器系统故障诊断模型. 首先, 应用推进器系统正常运行的历史电流样本数据, 由主元分析模型得到各推进器的电流预测值. 其次, 计算出故障检测统计量均方预测误差(squared prediction error, SPE), 根据SPE值是否跳变, 判断推进器系统有无故障发生. 通过分别重构各推进器电流信号的SPE值对故障推进器进行定位和隔离. 最后, 通过对实际海试数据进行仿真处理说明了该算法的可行性, 并通过与多层前馈神经网络(back propagation, BP)和常规小脑神经网络(cerebellar model articulation controller, CMAC)神经网络进行比较, 说明基于FCA-CMAC神经网络的主元分析模型的优越性.

**关键词:** 载人潜水器; 主元分析; 信号预测; 故障检测; 信号重构; 故障隔离

**引用格式:** 程学龙, 朱大奇, 孙兵, 等. 深海载人潜水器推进器系统故障诊断的新型主元分析算法. 控制理论与应用, 2018, 35(12): 1796 – 1804

中图分类号: TP273 文献标识码: A

## Principal component analysis algorithm for fault diagnosis of thruster system in deep-sea human occupied vehicle

CHENG Xue-long<sup>1</sup>, ZHU Da-qi<sup>1†</sup>, SUN Bing<sup>1</sup>, CHEN Yun-sai<sup>2</sup>

(1. Laboratory of Underwater Vehicles and Intelligent Systems, Shanghai Maritime University, Shanghai 201306, China;  
2. National Deep-Sea Center, Qingdao Shandong 266237, China)

**Abstract:** Aiming at the problem of fault detection and fault isolation in the multi-thruster system, a fault diagnosis model of thruster system in deep-sea human occupied vehicle based on principal component analysis (PCA) and credit assignment-based fuzzy cerebellar model articulation controller neural network (FCA-CMAC) is proposed. Firstly, the forecasting electric current values of thrusters are computed by using historical data measured under fault-free conditions and the PCA model. Secondly, the squared prediction error (SPE) is calculated to characterize the operational status of the thruster system. A fault can be detected when the SPE increases suddenly. Current values are reconstructed respectively to newly calculate the SPE to locate the faulty thruster. Finally, compared to BP and conventional CMAC, the method proposed is proved feasible and effective by the simulation of the actual sea trial data.

**Key words:** human occupied vehicle; principal component analysis; signal forecast; fault detection; signal reconstruction; fault isolation

**Citation:** CHENG Xuelong, ZHU Daqi, SUN Bing, et al. Principal component analysis algorithm for fault diagnosis of thruster system in deep-sea human occupied vehicle. *Control Theory & Applications*, 2018, 35(12): 1796 – 1804

### 1 引言(Introduction)

工作在复杂的海洋环境, 深海潜水器一旦出现故障, 不仅无法完成水下作业任务, 更难以进行回收. 作为“蛟龙号”深海载人潜水器的重要组成部分, 推进器系统肩负着潜水器在水下运动航行的重任, 并且完

全裸露于深海环境中, 是潜水器故障发生率最高的子系统之一, 因此针对载人潜水器推进器系统的故障诊断技术研究尤为重要<sup>[1]</sup>.

目前主流的故障诊断方法主要分为两大类<sup>[2]</sup>: 基于解析模型诊断方法和无模型诊断方法. 由于深海载

收稿日期: 2018-08-20; 录用日期: 2018-12-05.

<sup>†</sup>通信作者. E-mail: zdq367@aliyun.com; Tel.: +86 21-38284331.

本文责任编辑: 张伟.

国家自然科学基金项目(51575336, U1706224), 国家重点研发计划(2017YFC0306302)资助.

Supported by the National Natural Science Foundation of China (51575336, U1706224) and the National Key Research and Development Project (2017YFC0306302).

人潜水器自身的强耦合、非线性及模型不确定特性和受深海洋流的影响, 无法获得准确的数学模型参数, 因此常规的基于解析模型的故障诊断技术无法应用<sup>[3]</sup>. 而基于数据驱动的主元分析诊断算法不依赖研究对象的解析模型, 该方法用一组个数较少的新变量参数(各变量参数间线性无关)去替代原变量, 实现高维数据降维的同时, 最大程度上保留了原变量的信息<sup>[4-5]</sup>, 它本身的降维与抗干扰特性, 特别适合深海载人潜水器的大数据故障诊断. 传统的主元分析(principal component analysis, PCA)方法难以满足潜水器故障诊断的实时性要求, 如基于多层前馈神经网络(back propagation, BP)的故障诊断模型<sup>[6-8]</sup>, 收敛速度较慢, 输出精度较低, 因而在实际故障诊断应用中效果较差. 对此, 本文应用引入信度分配和模糊自组织竞争算法的小脑神经网络(credit assigned fuzzy cerebellar model articulation controller, FCA-CMAC)神经网络构造一种新的潜水器主元分析故障检测与定位模型<sup>[9-11]</sup>, 利用FCA-CMAC网络的快速收敛和稳定输出特性, 提高载人潜水器推进器系统故障诊断的准确性和实时性. 以“蛟龙号”深海载人潜水器多推进器系统为研究对象, 利用推进器系统海试应用的电流数据, 应用基于FCA-CMAC神经网络的信号预测模型对“蛟龙号”深海载人潜水器推进器系统进行故障诊断<sup>[12-13]</sup>.

本文组织如下: 第2章介绍“蛟龙号”载人潜水器推进器系统模型及主要典型故障模式; 第3章简述常规CMAC、模糊CMAC和FCA-CMAC算法; 第4章解释本文提出的推进器系统故障诊断算法; 第5章进行海试数据处理与算法结果分析; 第6章, FCA-CMAC神经网络学习性能的仿真分析与总结.

## 2 深海载人潜水器推进器系统 (Thruster system in deep-sea human occupied vehicle)

“蛟龙号”深海载人潜水器共7个推进器和一个纵倾调节装置, 分别为艏部横向槽道推进器( $T_H$ )、垂向左右舷可回转推进器各一台( $T_{BR}$ ,  $T_{BL}$ )和艉部成“十”字形矢量布置的4个推进器( $T_U$ ,  $T_D$ ,  $T_L$ ,  $T_R$ ). 推进器系统如图1-2所示.

根据国家深海中心(青岛)的“蛟龙号”潜水器海试实验总结, 深海工作时推进器系统的典型故障主要为推进器桨叶破裂、桨叶脱落、电机堵转、推进器抱箍脱落、推力器桨叶整套部件丢失、推力器磁钢套筒根部断裂、推力器传动机构变形卡死、海水渗入推进器内部等, 这些故障影响推进器系统的正常运行甚至完全失效, 继而威胁到潜水器的正常航行和安全. 推进器系统的监控传感器采集到大量的电机控制电压、转速和电流数据. 其中电机电流信号与螺旋桨叶负载大小相关, 表征推进器电机与螺旋桨叶的工作状态, 本文正是利用7个推进器电机电流向量对推进器系统进行故障诊断.




图 1 “蛟龙号”推进器系统模型(前视图)

Fig. 1 Thruster system in deep-sea human occupied vehicle (front view)




图 2 “蛟龙号”推进器系统模型(顶视图)

Fig. 2 Thruster system in deep-sea human occupied vehicle (vertical view)

## 3 CMAC神经网络(CMAC neural network)

### 3.1 常规CMAC神经网络算法 (Conventional CMAC neural network)

常规CMAC神经网络<sup>[14-15]</sup>的基本思想是将学习的知识存储在交叠的存储单元中, 其输出为相应激活存储单元数据的累加和. 其工作过程包括两个阶段: 结果输出及误差生成阶段和权值学习阶段; 在结果输出阶段, CMAC将所有被输入激活的存储单元的权值求和得到输出, 其输出表达式为

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

其中:  $w_j$  是第  $j$  个存储单元的权值,  $a_j(x)$  为当输入为  $x$  时存储单元的活性值, 当其被激活时值为 1, 而其他未被激活的存储单元活性值为 0.

CMAC网络在学习过程中根据期望输出与实际输出的误差大小来调整被激活存储单元的权值, 基本思想是将误差平均分配到所有被激活的存储单元, 只有被激活的  $N_L$  个存储单元对网络输出结果有影响, 因此只有这些被激活的存储单元权值得到更新调整. 当输入为  $x$  时, 设  $w_j(t)$  是经过第  $t$  次迭代后存储在第  $j$  个存储单元中的权值. 常规CMAC的权值更新算法为

$$w_j(t) = w_j(t-1) +$$

$$\alpha \frac{a_j(x)}{N_L} (y_d - \sum_{j=1}^{N_L} a_j(x)w_j(t-1)), \quad (2)$$

式中:  $w_j(t-1)$ 为上一次迭代后存储单元权值,  $y_d$ 为输入 $x$ 的期望输出,  $\sum_{j=1}^{N_L} a_j(x)w_j(t-1)$ 为实际输出,  $\alpha$ 为学习常数.

### 3.2 模糊CMAC神经网络(Fuzzy CMAC neural network)

为了提高CMAC学习的实时性和准确性,在网络输出计算阶段针对被激活存储单元的活性值引入模糊思想来改造常规CMAC神经网络,其结构如图3所示,并有如下定义<sup>[16]</sup>:

**定义1** CMAC中某个输入 $x$ 激活的 $N_L$ 个存储单元可以看做中心为 $z_j(j=1, 2, \dots, N_L)$ ,宽度为 $2\delta$ 的一个领域 $\psi_j$ ,称 $\psi_j$ 为联想域.对于常规CMAC来说,若 $a_j \in \psi_j$ ,则 $a_j = 1$ ,否则为0.联想域有交叠,使网络有局部泛化能力.

**定义2** 设输入 $x \in \mathbb{R}^n$ ,联想域 $\psi_j$ 的中心为 $z_j$ ,半径为 $\delta$ .将每个存储单元用一与输入 $x$ 同维的向量 $a_j$ 表示,则联想度为

$$a_{fj} = \begin{cases} \frac{\delta - \|a_j - x\|}{\delta}, & \|a_j - x\| \leq \delta, \\ 0, & \|a_j - x\| > \delta. \end{cases} \quad (3)$$

基于上述联想度的概念,可获得一模糊化的联想向量 $a_{fj}(x) = (a_{f1}, \dots, a_{fN_L})^T$ ,则模糊CMAC神经网络的输出为

$$y_i = \sum_{j=1}^{N_L} w_j a_{fj}(x). \quad (4)$$

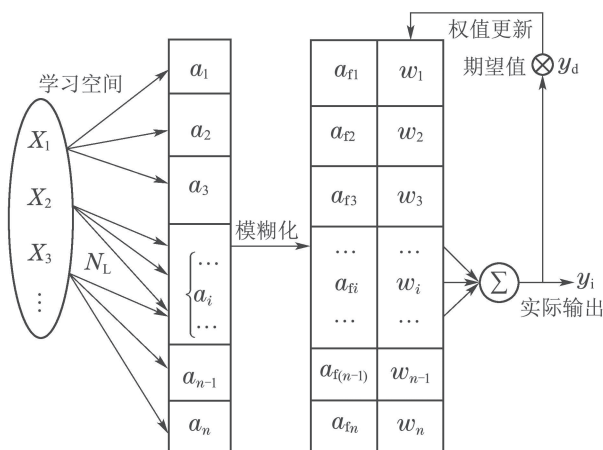


图3 模糊CMAC的基本结构及原理

Fig. 3 Basic structure diagram of fuzzy CMAC

由于联想度的引入,模糊CMAC的被激活存储单元的活性值大小介于0到1之间,而不再是简单的全部为1,这种改进使得网络学习过程更加合理高效.当令 $a_{fj} = 1(j=1, 2, \dots, N_L)$ ,其他情况为0时, $a_{fj}(x)$ 退化为二进制向量,则常规CMAC为模糊CMAC的特

殊情况.模糊CMAC的权值更新算法为

$$w_j(t) = w_j(t-1) + \alpha \frac{a_{fj}}{\sum_{j=1}^{N_L} a_{fj}} (y_d - \sum_{j=1}^{N_L} a_{fj}w_j(t-1)). \quad (5)$$

### 3.3 基于信度分配的模糊CMAC神经网络算法(Credit assignment-based fuzzy CMAC neural network)

在常规CMAC及模糊CMAC学习算法中的权值学习过程中,误差被平均分配给被激活的存储单元,而未考虑各激活存储单元对误差的贡献率,即在经过多次学习后,对调整次数不同的激活存储单元其权值的可信度仍被看做完全相同的.这种权值更新算法使那些权值不该更新或应该较少调整的存储单元(其权值可信度高)需反复学习调整;而对误差贡献较大的存储单元(其权值可信度低),本应该使其权值得到较大调整,但实际上学习调整量较少.为了达到预定的逼近精度,网络必须多次反复学习,从而使得学习效率降低,收敛速度变慢.为了提高CMAC的学习效率,考虑到已学习知识的可信度,文献[17]提出了基于信度分配的CMAC改进算法并假设存储单元学习更新次数越多,其存储的数值越可靠.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.基于信度分配的模糊CMAC(FCA-CMAC)学习算法的基本思想是将信度分配的思想引入到FCMAC的权值学习调整之中,校正误差与激活单元的学习次数成正比,从而使网络的学习更加合理高效.将式(2)和式(5)相结合得到其权值调整算法为

$$w_j(t) = w_j(t-1) + \alpha \frac{a_{fj}}{\sum_{j=1}^{N_L} a_{fj}} \left\{ \frac{(f(j)+1)^{-1}}{\sum_{l=1}^{N_L} (f(l)+1)^{-1}} \right\} \times (y_d - \sum_{j=1}^{N_L} a_{fj}w_j(t-1)), \quad (6)$$

式中:  $f(j)$ 是第 $j$ 个存储单元权值学习次数,考虑到在初始学习阶段,当 $f(j) = 0$ 时使得式 $f(j)^{-1}$ 分母为0的情况发生,因此用 $(f(j)+1)^{-1}$ 代替 $f(j)^{-1}$ .

## 4 深海载人潜水器推进器系统故障诊断算法(Fault diagnosis of thruster system in deep-sea human occupied vehicle)

基于PCA信号预测模型的载人潜水器故障诊断方法思想是利用系统中各推进器电流变量间的相关性建立正常工况下潜水器主元模型,通过检测样本相对主元模型的背离程度发现故障.根据推进器系统不同运行过程中存在的不同特性,利用推进器系统正常运行的历史电流数据建立起主元分析模型,然后通过FCA-CMAC网络预测下一时刻的主元分量,并由逆

正交变换得到推进器系统对应时刻的电流预测值, 由电流预测值和实测值计算出系统SPE值, 当SPE值超过设定故障阈值时, 则可判定推进器系统发生异常故障, 接着用系统电流预测值分别对各推进器电流实测值进行信号重构, 实现故障推进器的快速定位。

#### 4.1 PCA信号预测模型(Principle of PCA and signal forecasting model)

具体PCA信号预测模型如图4所示, 根据主元分析原理, 将正常运行的推进器系统历史电流信号 $I = [I_1 \ I_2 \ \dots \ I_7]^T$ 通过正交变换求出正交矩阵 $P \in \mathbb{R}^{7 \times 7}$ 和主成分矩阵 $T = [T_1 \ T_2 \ \dots \ T_7]^T$ , 求出显著性水平为 $\alpha$ 的前 $k$  ( $k \leq 7$ )个能代表系统电流信号 $I$ 的各个分量共同特征的主元分量 $T_1, T_2, \dots, T_k, \alpha$ 为介于0

到1之间的数. 对这 $k$ 个主元分量利用FCA-CMAC神经网络进行建模预测, 而对于主元分量 $T_{k+1}, T_{k+2}, \dots, T_7$ , 因其数值较小, 对模型精度影响可忽略不计。

在FCA-CMAC网络学习过程中, 输入是正常工况下的历史电流数据的主元分量 $T_1, T_2, \dots, T_k$ 在时刻 $(t-3, t-2, t-1)$ 的数值, 期望输出是时刻 $t$ 的主元分量值. 对主元分量 $T_1, T_2, \dots, T_k$ 由各自对应的已训练的FCA-CMAC网络经过多次学习后, 得到预测主元, 最后通过逆正交变换

$$\hat{I} = PT', \quad (7)$$

获得推进器系统正常运行的电流预测值

$$\hat{I} = [\hat{I}_1 \ \hat{I}_2 \ \dots \ \hat{I}_7]^T.$$

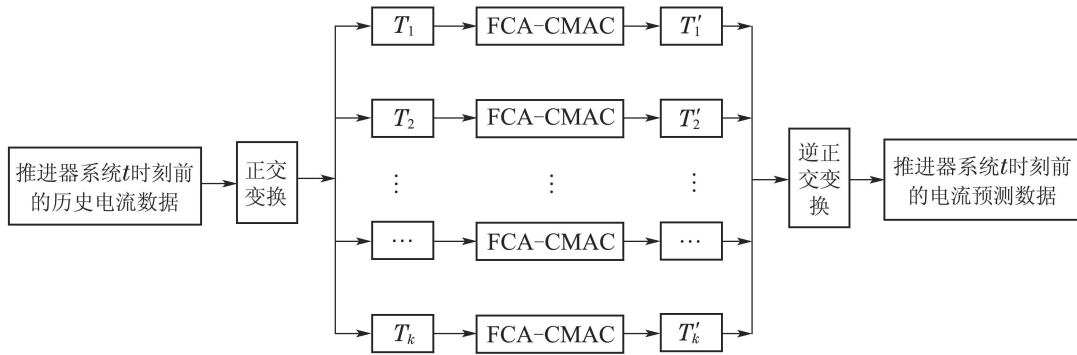


图 4 基于FCA-CMAC网络的推进器电流信号预测模型

Fig. 4 Signal forecasting model based on PCA and FCA-CMAC network

#### 4.2 推进器系统故障检测(Fault detection of thruster system)

当推进器系统发生故障时, 根据新的电流实测数据与主元分析模型预测值的背离程度来检测故障. 对一组新测电流数据, 在残差子空间上定义检测统计量均方预测误差(squared prediction error, SPE)进行假设检测, 通过系统SPE值及变化曲线对推进器系统进行故障检测<sup>[18]</sup>. 利用历史电流数据建立起PCA统计模型, 当新测电流数据的分布情况与历史不相符合, 则认为推进器系统在运行过程中发生异常故障<sup>[19]</sup>.

首先, 定义 $t$ 时刻推进器系统电流信号的预测误差向量和SPE值为

$$e(t) = I(t) - \hat{I}(t), \quad (8)$$

$$\text{SPE}(t) = e^T(t)e(t) = \sum_i e_i^2(t), \quad (9)$$

其中:  $e_i(t)$ 为推进器 $i$ 的电流信号在 $t$ 时刻的预测误差,  $e(t) = [e_1(t) \ \dots \ e_i(t) \ \dots \ e_7(t)]^T$ ,  $I(t) = [I_1(t) \ I_2(t) \ \dots \ I_7(t)]^T$ 为各推进器电流实测值,  $\hat{I}(t) = [\hat{I}_1(t) \ \hat{I}_2(t) \ \dots \ \hat{I}_7(t)]^T$ 为由PCA预测模型得到的 $t$ 时刻

各推进器电流预测值。

由式(8)–(9)计算出推进器系统在各时刻的SPE值, 系统故障检测规则定义如下:

$$\text{SPE}(t) \leq \delta_\alpha^2, \quad (10)$$

其中 $\delta_\alpha^2$ 为设定故障阈值. 当推进器系统正常运行时, 系统电流信号预测误差较小, SPE值始终处在故障阈值 $\delta_\alpha^2$ 以下. 当某推进器某时刻发生异常故障, 则系统电流实测值与该时刻预测值的估计误差很大, 此时系统SPE值会明显增大(跳变)并处于故障阈值 $\delta_\alpha^2$ 以上。

#### 4.3 推进器系统故障隔离(Fault isolation of thruster system)

当通过SPE曲线的跳变检测到推进器系统发生故障, 需及时准确地定位到故障推进器. 假设推进器系统任一推进器都是可能且唯一故障源, 逐一用PCA模型得到的电流信号预测值重构假定有故障的推进器电流信号实测值, 而其他假设为正常推进器电流信号保留, 通过检查电流信号重构前后的系统SPE值来确定故障推进器<sup>[20]</sup>.

由上述原理, 对于推进器系统 $t$ 时刻的电流预测

值  $\hat{I}(t) = [\hat{I}_1(t) \ \hat{I}_2(t) \ \cdots \ \hat{I}_7(t)]^T$  和电流实测值  $I(t) = [I_1(t) \ I_2(t) \ \cdots \ I_7(t)]^T$ , 当检测到系统发生故障时, 用第  $j$  个推进器  $t$  时刻的电流预测值  $\hat{I}_j(t)$  重构实测值  $I_j(t)$ , 并重新定义  $t$  时刻系统电流实测值为  $\bar{I}(t) = [I_1(t) \ I_2(t) \ \cdots \ \hat{I}_j(t) \ \cdots \ I_7(t)]^T$ . 对各推进器电流信号依次进行重构, 由式(8)–(9)得

$$\bar{e}(t) = \bar{I}(t) - \hat{I}(t), \quad (11)$$

$$\overline{\text{SPE}}_j(t) = \bar{e}^T(t) \bar{e}(t) = \sum_{i=1}^7 \bar{e}_i^2(t), \quad (12)$$

其中  $\overline{\text{SPE}}_j(t)$  为推进器  $j$  的电流信号被重构后推进器系统的SPE值. 当故障推进器的电流实测值被电流预测值重构后, 由于系统故障会被暂时排除,  $\overline{\text{SPE}}_j(t)$  变小并处于故障阈值以内. 若重构的不是故障推进器,  $\overline{\text{SPE}}_j(t)$  值仍受故障信号影响而处于故障阈值之外<sup>[21]</sup>. 根据上述故障隔离原理, 分别计算7个推进器电流信号重构后的系统  $\overline{\text{SPE}}_j(t)$  值, 当  $\overline{\text{SPE}}_j(t) \leq \delta_\alpha^2$  则可以确定第  $j$  个推进器是有故障的, 从而实现故障推进器的隔离与定位.

## 5 数据处理与结果分析(Data processing and result analysis)

### 5.1 主元信号预测模型结果分析(Result of PCA and signal forecasting model)

取“蛟龙号”第87次潜航推进器系统正常工作的推进器电机电流数据, 航行时间段为14: 26–14: 39, 推进器系统连续工作13 min. 已知电流传感器信息采集间隔为0.5 s, 共计1512组推进器反馈电流数据. 将经过预处理的推进器系统反馈电流向量矩阵表示为

$$I^0 = (I_1^0 \ I_2^0 \ I_3^0 \ I_4^0 \ I_5^0 \ I_6^0 \ I_7^0)^T,$$

其中  $I^0 \in \mathbb{R}^{7 \times N}$ ,  $N = 1485$  (野值剔除后的样本数); 其中:  $I_1^0, I_2^0, I_3^0, I_4^0, I_5^0, I_6^0, I_7^0$  分别为  $T_H$  推进器反馈电流、 $T_{BL}$  推进器反馈电流、 $T_{BR}$  推进器反馈电流、 $T_L$  推进器反馈电流、 $T_R$  推进器反馈电流、 $T_U$  推进器反馈电流、 $T_D$  推进器反馈电流.

对预处理后各推进器电机电流分量进行标准化处理(各分量零均值、单位方差), 记为  $I = (I_1 \ I_2 \ I_3 \ I_4 \ I_5 \ I_6 \ I_7)^T$ . 对其协方差矩阵  $A = E[I \ I^T]$  进行特征值分解, 将得到的特征值按从大到小顺序排列, 即  $\lambda_1 \geq \lambda_2 \geq \cdots \geq \lambda_7 \geq 0$  并求出与之相对应的特征向量分别为  $p_1, p_2, \cdots, p_7$ . 则由上述特征值和特征向量分别组成的对角阵  $\Lambda = \text{diag}\{\lambda_1, \lambda_2, \cdots, \lambda_7\}$ 、正交矩阵  $P = [p_1 \ p_2 \ \cdots \ p_7]$  满足

$$P^T A P = \Lambda, \quad (13)$$

其中:

$$\Lambda = \text{diag}\{\lambda_1, \lambda_2, \cdots, \lambda_7\} =$$

$$\begin{bmatrix} 2.7201 & & & & & & \\ & 1.9917 & & & & & \\ & & 1.0215 & & & & \\ & & & 0.8113 & & & \\ & & & & 0.3267 & & \\ & & & & & 0.0772 & \\ & & & & & & 0.0515 \end{bmatrix},$$

$$P = [p_1 \ p_2 \ \cdots \ p_7] =$$

$$\begin{bmatrix} 0.270 & 0.400 & 0.298 & -0.670 & -0.183 & 0.434 & 0.078 \\ 0.085 & -0.56 & 0.188 & -0.597 & 0.166 & -0.504 & -0.069 \\ 0.008 & 0.115 & -0.919 & -0.367 & 0.095 & -0.003 & -0.006 \\ 0.549 & 0.251 & -0.014 & 0.144 & 0.098 & -0.419 & 0.656 \\ 0.541 & 0.276 & 0.011 & 0.126 & 0.152 & -0.21 & -0.74 \\ 0.412 & -0.46 & -0.05 & 0.117 & 0.516 & 0.577 & 0.094 \\ 0.395 & -0.41 & -0.17 & 0.103 & -0.79 & 0.077 & -0.033 \end{bmatrix}.$$

然后由式  $T = P^T I$  求得系统电流向量  $I$  的主元分量  $T = [T_1 \ T_2 \ T_3 \ T_4 \ T_5 \ T_6 \ T_7]^T$ . 则推进器系统的电流向量前4个主元分量所携带能量占系统总能量的比例为

$$\alpha = \frac{\lambda_1 + \lambda_2 + \lambda_3 + \lambda_4}{\lambda_1 + \lambda_2 + \lambda_3 + \lambda_4 + \lambda_5 + \lambda_6 + \lambda_7} \approx 0.9349.$$

此时称  $T_1, T_2, T_3, T_4$  为系统显著性水平为  $\alpha = 0.9349$  的主元分量, 可认为主元分量  $T_1, T_2, T_3, T_4$  携带了电流向量  $I$  的93.49%的有用信息. 由PCA方法, 本文用主元分量  $T_1, T_2, T_3, T_4$  替代推进器系统电流向量  $I$ , 既实现了数据降维, 又保留了推进器各时刻的运行信息. 而对于主元分量  $T_5, T_6, T_7$  因其所占比例较小, 对预测模型精度的影响可忽略不计.

由式(8)–(9)计算出推进器系统正常运行时的SPE值, 如图5所示, 可以看出正常状态下的SPE变化曲线相对稳定且处于故障阈值  $\delta_\alpha^2 = 0.35$  以下.

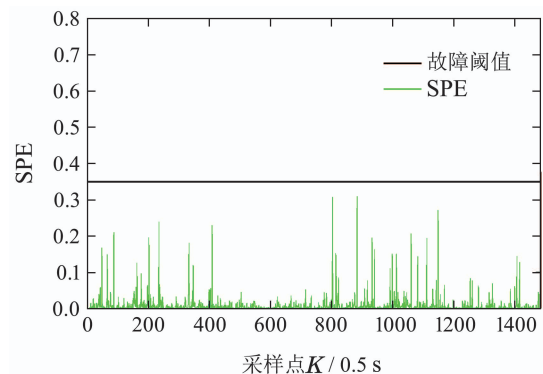


图5 正常运行的推进器系统SPE值

Fig. 5 SPE value without fault

### 5.2 故障诊断结果分析 (Fault diagnosis based on PCA)

为了验证本文所使用的基于FCA-CMAC网络的推进器电流信号预测模型的准确性, 将推进器系统正常运行的各推进器电机电流测量值、模型预测值和同一工况下的故障值进行对比, 易发现 $T_R$ 推进器电机电流在第760个采样点时开始偏离正常值, 如图6所示. 根据故障检测原理, 由式(8)–(9)计算推进器系统故障状态下的SPE值, 如图7所示. 从第760个采样点开始, 系统SPE曲线发生跳变, 并且远超故障阈值 $\delta_\alpha^2 = 0.35$ , 此时可断定推进器系统发生故障.

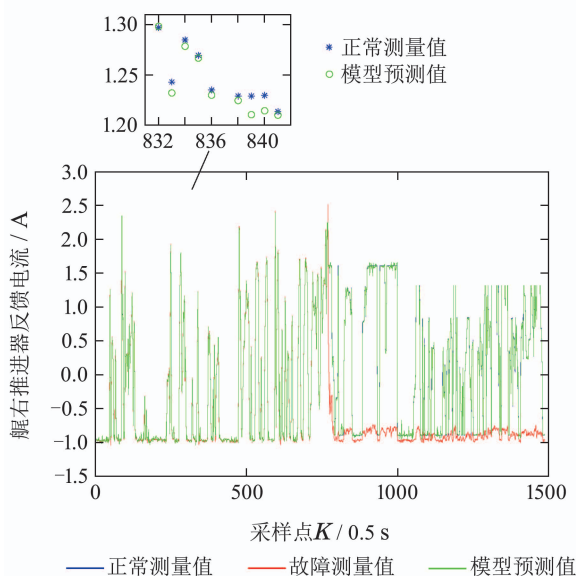


图 6  $T_R$  推进器电机电流的正常值、模型预测值和故障值的比较

Fig. 6 Comparison of normal current value, model prediction value and fault value of thruster  $T_R$




图 7 故障发生时推进器系统SPE值

Fig. 7 SPE value with fault

根据故障隔离原理, 由式(5)–(6)分别对各推进器电机电流信号 $I_1, I_2, I_3, I_4, I_5, I_6, I_7$ 进行重构并计算出系统SPE.




图 8  $T_H$  电机电流被重构后的系统SPE值

Fig. 8  $\overline{SPE}$  value with thruster  $T_H$  reconstructed




图 9  $T_{BL}$  电机电流被重构后的系统SPE值

Fig. 9  $\overline{SPE}$  value with thruster  $T_{BL}$  reconstructed




图 10  $T_{BR}$  电机电流被重构后的系统SPE值

Fig. 10  $\overline{SPE}$  value with thruster  $T_{BR}$  reconstructed




图 11  $T_L$  电机电流被重构后的系统SPE值

Fig. 11  $\overline{SPE}$  value with thruster  $T_L$  reconstructed

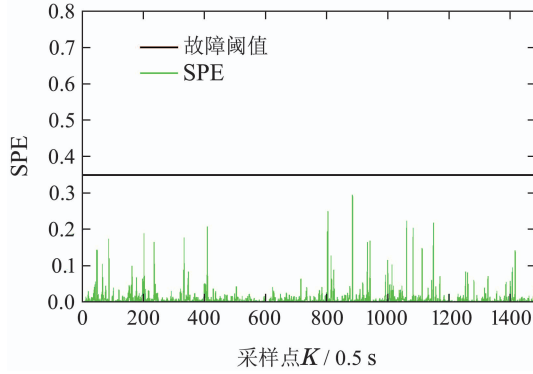


图 12  $T_R$  电机电流被重构后的系统  $\overline{SPE}$  值Fig. 12  $\overline{SPE}$  value with thruster  $T_R$  reconstructed图 13  $T_U$  电机电流被重构后的系统  $\overline{SPE}$  值Fig. 13  $\overline{SPE}$  value with thruster  $T_U$  reconstructed图 14  $T_D$  电机电流被重构后的系统  $\overline{SPE}$  值Fig. 14  $\overline{SPE}$  value with thruster  $T_D$  reconstructed

图8-14分别为 $T_H$ 推进器电机电流、 $T_{BL}$ 推进器电机电流、 $T_{BR}$ 推进器电机电流、 $T_L$ 推进器电机电流、 $T_R$ 推进器电机电流、 $T_U$ 推进器电机电流和 $T_D$ 推进器电机电流被重构后的系统 $\overline{SPE}$ 值. 易看出, 当 $I_1, I_2, I_3, I_4, I_6, I_7$ 被重构后, 系统 $\overline{SPE}$ 值仍然处于故障阈值 $\delta_\alpha^2 = 0.35$ 以上; 而当 $T_R$ 推进器电机电流 $I_5$ 被重构后, 系统因受故障信号影响暂时消失使得 $\overline{SPE}$ 值降到故障阈值 $\delta_\alpha^2 = 0.35$ 以下, 据此可以断定 $T_R$ 推进器出现故障. 这恰好与上述 $T_R$ 推进器电机电流故障值和正常值的比较结果相吻合, 进一步

证实了本文所提出的多推进器系统故障诊断模型对深海载人潜水器推进器系统进行故障诊断的有效性.

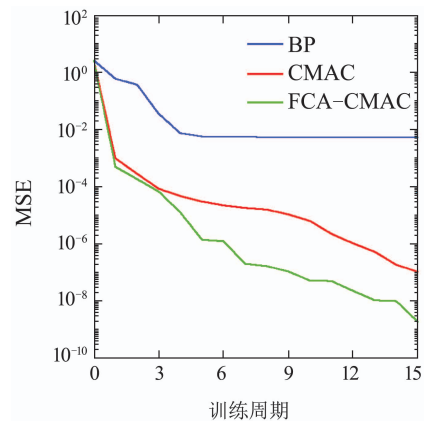
## 6 FCA-CMAC神经网络的学习性能分析 (Learning performance analysis of FCA-CMAC)

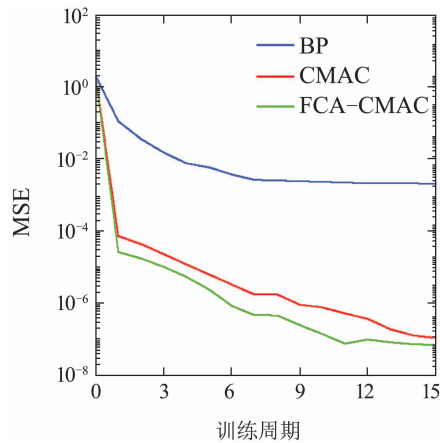
为说明本文提出的多推进器系统故障诊断模型采用FCA-CMAC神经网络的优势, 应用上述推进器电流数据的主元分量 $T_1, T_2$ 作为训练样本, 在图4所示的PCA信号预测模型中, 分别采用BP、常规CMAC和FCA-CMAC3种神经网络对样本数据进行学习, 并对3者的输出精度和收敛速度进行比较. 在对主元分量 $T_1$ 进行训练过程中, 常规CMAC与改进的FCA-CMAC采用同样的网络结构, 3个输入分别为主元分量 $T_1$ 在 $(t-3, t-2, t-1)$ 时刻的值, 输出为 $t$ 时刻的预测值. 而BP网络采用3层结构, 各层节点分别为3, 5, 1, 隐层和输出层的神经元功能函数分别为Sigmoid函数和线性函数, 3个输入分别为主元分量 $T_1$ 在 $(t-3, t-2, t-1)$ 时刻的值, 输出为 $t$ 时刻的预测值. 同理, 对主元分量 $T_2$ 进行训练学习. 训练过程中采用均方误差(mean square error, MSE)作为性能指标, MSE定义如下:

$$MSE = \frac{1}{N} \sum_{k=1}^N (Y_{simuk} - Y_{targk})^2, \quad (14)$$

式中:  $Y_{simuk}$ 为网络实际输出值,  $Y_{targk}$ 为期望值,  $N$ 为样本数.

主元分量 $T_1, T_2$ 的神经网络训练过程中, 均方差值MSE随学习周期下降情况如图15-16所示. 从MSE下降曲线可以看出, 在收敛速度和输出精度上FCA-CMAC都明显优于BP和常规CMAC网络. 3种神经网络训练过程中主元分量 $T_1, T_2$ 的MSE值随训练周期变化数据分别如表1-2所示.

图 15 预测主元分量 $T_1$ 训练过程中MSE随周期变化曲线Fig. 15 MSE decline curve in the training course of predicting the principal component  $T_1$

图 16 预测主元分量 $T_2$ 训练过程中MSE随周期变化曲线Fig. 16 MSE decline curve in the training course of predicting the principal component  $T_2$ 表 1 不同神经网络训练过程中主元分量 $T_1$ 的MSE值Table 1 MSE values by using different networks to train principal component  $T_1$ 

训练周期	BP	CMAC	FCA-CMAC
0	2.716	2.716	2.716
1	8.074e-02	9.863e-04	4.960e-04
2	3.671e-02	2.823e-04	1.839e-04
3	7.345e-03	8.494e-05	6.730e-05
4	5.480e-03	4.664e-05	1.269e-05
5	4.812e-03	1.198e-05	1.329e-06

表 2 不同神经网络训练过程中主元分量 $T_2$ 的MSE值Table 2 MSE values by using different networks to train principal component  $T_2$ 

训练周期	BP	CMAC	FCA-CMAC
0	1.991	1.991	1.991
1	1.14e-02	7.18e-05	2.61e-05
2	7.51e-03	4.36e-05	1.72e-05
3	2.34e-03	2.27e-05	5.33e-06
4	2.48e-03	1.184e-05	2.39e-06
5	2.21e-03	6.22e-06	8.91e-07

由图表中数据可看出, FCA-CMAC的收敛速度快、输出精度高等优点, 更适于故障诊断系统对误差的要求。

BP是全局逼近网络, 每一对输入输出都需要对网络的所有连接权值进行调整, 权值更新过程中采用梯度下降算法, 使得网络收敛速度较慢且存在局部极小值问题。CMAC是局部逼近网络, 只需调整部分存储单元权值, 权值更新过程中采用 $\delta$ 算法, 其

收敛速度比BP网络快并且不存在局部极小值问题, 在输出精度和学习时间上有着明显优势。而引入了信度分配算法的模糊CMAC不仅在CMAC的存储单元激活、结果输出阶段省去了复杂的hashing编码等运算, 而且在权值学习调整阶段根据各激活存储单元的权值可信度(学习次数)分配误差, 使权值学习调整更加合理有效, 进一步提高网络学习速度和输出精度。

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, 使得BP网络易收敛于不同点, 造成输出结果不稳定。而FCA-CMAC网络可以看做是对外界函数的多维查询系统, 因而只要调整泛化参数, 就能保证稳定的输出。通过比较FCA-CMAC, CMAC和BP神经网络的学习性能, 快速收敛和稳定输出的FCA-CMAC神经网络更适于应用在深海载人潜水器推进器系统故障诊断模型中。

## 7 结语(Conclusions)

本文采用基于FCA-CMAC神经网络的主元分析模型对“蛟龙号”深海潜水器推进器系统进行故障诊断, 成功检测出系统故障并快速定位到故障推进器。通过比较BP、常规CMAC和FCA-CMAC神经网络的对样本的学习性能, 进一步证实了所提出的故障诊断模型在工程应用中的有效性。

## 参考文献(References):

- [1] DUAN Zuohua, CAI Zixing, YU Jinxia. Fault diagnosis and fault tolerant control of mobile robots in unknown environment: a survey [J]. *Robot*, 2005, 27(4): 373 - 379.  
(段琢华, 蔡自兴, 于金霞. 未知环境中移动机器人故障诊断与容错控制技术综述 [J]. 机器人, 2005, 27(4): 373 - 379.)
- [2] LI Han, XIAO Deyun. Survey on data driven fault diagnosis methods [J]. *Control and Decision*, 2011, 26(1): 1 - 9.  
(李晗, 萧德云. 基于数据驱动的故障诊断方法综述 [J]. 控制与决策, 2011, 26(1): 1 - 9.)
- [3] LIU Xinyu, LI Yiping, FENG Xisheng. Real-time measurement method of buoyancy of a full-ocean-depth underwater robot [J]. *Robot*, 2018, 40(2): 216 - 221.  
(刘鑫宇, 李一平, 封锡盛. 万米级水下机器人浮力实时测量方法 [J]. 机器人, 2018, 40(2): 216 - 221.)
- [4] QI Yongsheng, WANG Pu, GAO Xuejin. Fault detection and diagnosis of multiphase batch process based on kernel principal component analysis-principal component analysis [J]. *Control Theory & Applications*, 2012, 29(6): 69 - 79.  
(齐咏生, 王普, 高学金. 基于核主元分析—主元分析的多阶段间歇过程故障监测与诊断 [J]. 控制理论与应用, 2012, 29(6): 69 - 79.)
- [5] XIE Ziqiang, GE Weimin, WANG Xiaofeng. Real time feature extraction method of developmental robot [J]. *Robot*, 2017, 39(2): 189 - 196.  
(谢自强, 葛为民, 王肖锋. 发展型机器人实时特征提取方法研究 [J]. 机器人, 2017, 39(2): 189 - 196.)



- [6] HSIEH W W. Nonlinear principal component analysis by neural networks [J]. *Tellus Series A-dynamic Meteorology & Oceanography*, 2001, 53(5): 599 – 615.
- [7] LIU Jizhen, NIU Zheng, NIU Yuguang. Nonlinear PCA fault detection method based on RBF networks [J]. *Journal of North China Electric Power University*, 2005, 32(5): 27 – 31.  
(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.)
- [8] KRAMER M A. Nonlinear principal component analysis using autoassociative neural networks [J]. *Aiche Journal*, 2010, 37(2): 233 – 243.
- [9] SU S F, TAO T, HUNG T H. Credit assigned CMAC and its application to online learning robust controllers [J]. *IEEE Transactions on Systems Man and Cybernetics Part B: Cybernetics A Publication of the IEEE Systems Man and Cybernetics Society*, 2003, 33(2): 202.
- [10] ZHU Daqi, KONG Min. Fault-tolerant control of nonlinear system based on balanced learning CMAC neural network [J]. *Control Theory & Applications*, 2008, 25(1): 81 – 86.  
(朱大奇, 孔敏. 基于平衡学习的CMAC神经网络非线性滑模容错控制 [J]. 控制理论与应用, 2008, 25(1): 81 – 86.)
- [11] LIU Q, ZHU D Q, YANG S X. Unmanned underwater vehicles fault identification and fault-tolerant control method based on FCA-CMAC neural networks, applied on an actuated vehicle [J]. *Journal of Intelligent & Robotics Systems*, 2012, 66(4): 463 – 475.
- [12] ZHU Daqi, CHEN Chuyao, YAN Mingzhong. Fast sensor fault diagnosis method based on CA-CMAC [J]. *Acta Electronica Sinica*, 2008, 36(8): 1646 – 1650.  
(朱大奇, 陈楚瑶, 颜明重. 基于CA-CMAC的快速传感器故障诊断方法 [J]. 电子学报, 2008, 36(8): 1646 – 1650.)
- [13] CHEN Chuyao, ZHU Daqi. Sensor fault diagnosis method based on neural network principal component analysis [J]. *Systems Engineering and Electronics*, 2010, 32(7): 1549 – 1552.  
(陈楚瑶, 朱大奇. 神经网络主元分析的传感器故障诊断方法 [J]. 系统工程与电子技术, 2010, 32(7): 1549 – 1552.)
- [14] ALBUS J S. A new approach to manipulator control: the cerebellar model articulation controller (CMAC) [J]. *Transactions of the Asme Journal of Dynamic Systems*, 1975, 97(3): 220 – 227.
- [15] WANG Yuan, HU Shousong, QI Junwei. Self-Organizing fuzzy CMAC neural network and its nonlinear system identification [J]. *Acta Aeronautica Et Astronautica Sinica*, 2001, 22(6): 556 – 558.  
(王源, 胡寿松, 齐俊伟. 自组织模糊CMAC神经网络及其非线性系统辨识 [J]. 航空学报, 2001, 22(6): 556 – 558.)
- [16] ZHU Daqi, SUN Bing. Information fusion fault diagnosis method for unmanned underwater vehicle thrusters [J]. *Iet Electrical Systems in Transportation*, 2013, 3(4): 102 – 111.
- [17] ALBUS J S. Data storage in cerebellar model articulation controller(CMAC) [J]. *Transactions of the Asme Journal of Dynamic Systems*, 1975, 97(3): 228 – 233.
- [18] GUO Shenghui, ZHU Fanglai. Actuator fault detection based on interval observers [J]. *Control and Decision*, 2016, 31(6): 1118 – 1122.  
(郭胜辉, 朱芳来. 基于区间观测器的执行器故障检测 [J]. 控制与决策, 2016, 31(6): 1118 – 1122.)
- [19] HUANG Xiaobin, LIU Jizhen, NIU Yuguang. Application of PCA-based fault detection in thermal boiler processes [J]. *Power Engineering*, 2004, 24(4): 542 – 547.  
(黄孝彬, 刘吉臻, 牛玉广. 主元分析方法在火电厂锅炉过程检测中的应用 [J]. 动力工程学报, 2004, 24(4): 542 – 547.)
- [20] HARKAT M F, DJELEL S, DOGHMANE N, et al. Sensor fault detection, isolation and reconstruction using nonlinear principal component analysis [J]. *International Journal of Automation & Computing*, 2007, 4(2): 149 – 155.
- [21] SHEN Yanxia, YANG Xiongfei, ZHAO Zhipu. Sensor fault diagnosis for wind turbine system [J]. *Control Theory & Application*, 2017, 34(3): 321 – 328.  
(沈艳霞, 杨雄飞, 赵芝璞. 风力发电系统传感器故障诊断 [J]. 控制理论与应用, 2017, 34(3): 321 – 328.)

#### 作者简介:

**程学龙** (1993–), 男, 硕士研究生, 研究方向为深海载人潜水器故障诊断与容错控制智能信息处理与水下机器人, E-mail: 1206533767@qq.com;

**朱大奇** (1964–), 男, 教授, 博士生导师, 研究方向为水下机器人智能信息处理与容错控制, E-mail: zdq367@aliyun.com;

**孙兵** (1987–), 男, 讲师, 硕士生导师, 研究方向为水下机器人路径规划与跟踪控制, E-mail: hmsunbing@163.com;

**陈云赛** (1987–), 男, 高级工程师, 研究方向为深海载人潜水器应用与海试, E-mail: cys@ndsc.org.cn.