

基于PNN网络的余度作动器智能故障诊断*

夏立群*, 王可

中国一航西安飞行自动控制研究所, 陕西 西安 710065

摘 要: 提出了一种基于概率神经网络(PNN)的余度作动器故障诊断方法, 分析了传统阀芯位置监控器的设计思想及设计缺陷, 构建了基于PNN网络的阀芯位置监控器, 最后完成了基于PNN网络的作动器仿真实验。实验结果表明, 基于PNN的阀芯位置监控器具有较强的故障诊断能力, 有效地提高了作动器两通道工作时识别阀芯位置监控器的故障准确率, 可以成为作动器智能故障诊断与健康管理的重要方法之一。

关键词: 作动器; 阀芯位移监控器; 智能故障诊断; 概率神经网络

中图分类号: TP183 **文献标识码:** A **文章编号:** 1007-5453 (2014) 01-73-6

余度作动器是电传飞行控制系统的重要部件, 具有结构复杂、较强的不确定性及固有的非线性因素多等特点, 难以用数学模型精确描述。目前, 故障诊断方法通常分为三类: 基于解析模型的方法、基于信号处理的方法及基于知识的方法。其中, 基于知识的故障诊断方法, 不需要建立对象的数学模型, 利用人工智能技术及专家经验, 能够快速准确诊断系统故障。由于作动器故障的多样性、突发性、成因的复杂性, 以及进行故障诊断时所需要的知识对领域专家实践经验和诊断策略的依赖, 使研究智能化的余度作动器故障诊断技术成为当前的趋势。采用基于知识的故障诊断方法, 形成的智能故障诊断技术已经在电液技术的多个领域得到应用。

文献[1]在充分分析液压泵球头松动故障机理的基础上, 对振动信号和压力信号进行小波消噪处理, 有效提取球头松动的故障特征。将不同类型特征参数进行特征层融合, 利用主成分分析和改进算法的BP神经网络实现液压泵球头松动故障诊断。文献[2]基于柱塞泵的脉动分析模型, 以泵出口处的压力信号作为分析信号, 提出了一种基于小波变换的柱塞泵故障诊断方法。本文以电传飞行控制系统的余度作

动器主控阀阀芯位移为研究对象, 依据由其位置监控器、指令信号等工况信息, 提出了一种基于概率神经网络(PNN, Probabilistic Neural Network)的作动器智能故障诊断方法。

1 阀芯位置监控器

1.1 主控阀阀芯位置监控原理

主控阀是电传余度作动器的关键组件。余度作动器通常采用主控阀阀芯分配双液压系统的流量, 控制双腔串联作动筒运动, 同时安装在主控阀阀芯上的多余度线位移传感器(LVDT)将反馈阀芯位置信号, 形成余度作动器内回路闭环控制。主控阀阀芯一旦卡死, 将使余度作动器失去控制, 导致飞机失控, 产生灾难性后果。因此, 为了满足飞行安全需要, 国内外的大多数电传余度作动器都采用了主控阀阀芯位置监控技术。

主控阀阀芯位置是作动器伺服系统中电子、电气和液压机械的交汇点(见图1), 伺服回路中的故障均能在这里反映并被放大。因此, 在作动系统中增加主控阀阀芯位置监控器, 即可对伺服回路中各个组件的故障进行监测。同时, 由于

收稿日期: 2013-12-20; 录用日期: 2014-01-08

基金项目: 航空科学基金(20070218003)

*通讯作者。 Tel.: 13759999350 E-mail: fcd@facri.com

引用格式: XIA Liqun, WANG Ke. Redundant actuator intelligent fault diagnosis based on PNN[J]. Aeronautical Science & Technology, 2014, 25(1): 73-78. 夏立群, 王可. 基于PNN网络的余度作动器智能故障诊断[J]. 航空科学技术, 2014, 25(1): 73-78.

主控阀阀芯位置的输出超前于作动器位移,当系统出现故障,在造成大的输出偏差之前,主控阀阀芯位置监控器能及时切断故障通道,减小故障瞬态。




图1 作动器控制系统图

Fig.1 Control system diagram of actuator

图2为一种典型的作动器主控阀阀芯位置监控器工作原理图。首先建立主控阀阀芯运动模型,采用内回路的理论增益及速度限幅与位置限幅模拟主控阀阀芯运动特性,建立主控阀阀芯运动模型,即主控阀模型;主控阀模型接受来自作动器系统内回路的指令信号,等效输出阀芯运动位置,将主控阀模型输出的阀芯位移与实际主控阀阀芯LVDT(linear variable differential transducer,线位移传感器)的输出进行比较,构成主控阀阀芯位置监控器的输出。




图2 典型的阀芯位置监控器

Fig.2 Typical spool displacement monitor

一旦伺服回路出现故障(通常为指令故障、主控阀LVDT故障、作动筒LVDT故障等),主控阀阀芯将在正常通道与故障通道综合作用下产生位移,利用阀芯位置监控器可以对故障通道进行判定。

1.2 主控阀阀芯位置监控存在的问题

对于四余度系统,当作动器以四通道或三通道工作时,主控阀位置监控器可以满足使用要求;但是当两通道工作时,由于正常通道与故障通道综合作用于主控阀,主控阀位置监控器的检测率和虚警率都无法满足使用要求。例如,正常通道内回路指令为5V,故障通道内回路指令为-5V,这时由于磁通综合的作用,使得主控阀处于0V指令输入的位置,正常通道与故障通道的监控器将同时报故。因此,目前的通

道故障逻辑通常是在第三次故障时,同时切除两个工作通道,这样带来了余度等级下降过快的问题,影响了磁通综合三余度电传作动器在工程中的应用。

传统主控阀阀芯位置监控器,将主控阀模型输出的阀芯位移与实际主控阀阀芯LVDT输出进行比较,产生阀芯位置监控器的输出。当监控器的输出超出门限,判定监控器故障报故。由于门限规定为硬性常数,无法根据作动器的各种不确定因素变化。当两通道工作时,由于故障通道与正常通道对监控器输出的影响权重相同,使得阀芯位置监控器漏检率与虚警率都很高。

表1为某型作动器的阀芯位置监控器两通道工作的情况,表中:

- 1) COM为指令幅值;
- 2) FS为本通道故障状态(1为正常、2为指令故障、3为MCV_LVDT故障、4为RAM_LVDT故障);
- 3) MCV_M为监控器输出;
- 4) ST为检测正确状态(T为正确、F为漏检、FA为误报)。

由表1统计得到,正常通道的虚警率为50%,故障通道的漏检率为48.3%。这种监控器无法满足作动器故障判断的要求。因此,目前作动器的余度管理大都采用当作动器第三次故障发生时,同时切除剩余两个通道的故障逻辑,这也是作动器需要采用电气四余度的一个重要原因。另一方面,这种传统的阀芯位置监控器,无法判定故障的类型、确定故障的种类,不具备故障诊断的功能。

为解决这一问题,本文采用基于贝叶斯决策理论,并经过大量测试样本训练过的概率神经网络,提高两通道工作时主控阀位置监控器的检测率、降低虚警率。

2 PNN在作动器故障诊断中的应用

2.1 概率神经网络原理

自1989年D. F. Spech博士首先提出后,PNN网络得到了较快的发展。PNN网络是一种基于贝叶斯最小风险准则的前馈型神经网络,它是径向基网络的一种变化形式,同时融入了贝叶斯决策理论。目前,PNN网络已广泛应用于各种设备故障诊断中,取得了大量令人满意的应用成果^[3-5]。

1) PNN网络机理

Bayes 最小平均条件风险准则:设有 ω_i ($i=1,2,\dots,c$)个模式集合,每类的先验概率为 $P(\omega_i)$,对于任一随机矢量 $x \in R_d$,每类的类条件概率为 $P(\omega_i/x)$, L_{ji} 为 ω_i 分类到 ω_j 所担的平均风险。可以对未知模式 x 做如下判决:

表1 阀芯位置监控器两通道工作的情况

Table 1 Two channels working conditions of spool position monitor

COM	F_S	MCV_M	ST	F_S	MCV_M	ST
0.5	1	2.731	T	2	4.169	T
-0.5	1	2.731	T	2	4.169	T
1	1	5.785	FA	2	7.908	T
-1	1	5.785	FA	2	7.908	T
1.5	1	6.361	FA	2	7.908	T
-1.5	1	6.361	FA	2	7.908	T
2	1	6.361	FA	2	7.908	T
-2	1	6.361	FA	2	7.908	T
3	1	6.361	FA	2	7.908	T
-3	1	6.361	FA	2	7.908	T
4	1	6.361	FA	2	7.908	T
-4	1	6.361	FA	2	7.908	T
5	1	6.361	FA	2	7.908	T
-5	1	6.361	FA	2	7.908	T
6	1	6.361	FA	2	7.908	T
-6	1	6.361	FA	2	7.908	T
7	1	6.361	FA	2	7.908	T
-7	1	6.361	FA	2	7.908	T
10	1	6.361	FA	2	7.908	T
-10	1	6.361	FA	2	7.908	T
COM	F_S	MCV_M	ST	F_S	MCV_M	ST
0.5	1	7.431	FA	3	0	F
-0.5	1	2.713	T	3	5.518	T
1	1	7.46	FA	3	3.675	F
-1	1	2.185	T	3	7.287	T
1.5	1	7.718	FA	3	8.009	T
-1.5	1	0.7806	T	3	7.731	T
2	1	4.802	FA	3	11.6	T
-2	1	0.4999	T	3	4.402	T
3	1	0.4	T	3	16	T
-3	1	0.4	T	3	0	F
4	1	0.4	T	3	16	T
-4	1	0.4	T	3	0	F
5	1	0.4	T	3	16	T
-5	1	0.4	T	3	0	F
6	1	0.4	T	3	16	T
-6	1	0.4	T	3	0	F
7	1	0.4	T	3	16	T
-7	1	0.4	T	3	0	F
10	1	0.4	T	3	16	T
-10	1	0.4	T	3	0	F
COM	F_S	MCV_M	ST	F_S	MCV_M	ST
0.5	1	6.9	FA	4	8	T
-0.5	1	14.17	FA	4	2.829	F
1	1	8	FA	4	8	T
-1	1	12.49	FA	4	0.06722	F
1.5	1	8	FA	4	8	T
-1.5	1	8.491	FA	4	0.4	F
2	1	8	FA	4	8	T
-2	1	4.802	FA	4	0.4	F
4	1	8	FA	4	8	T
-4	1	0.4	T	4	0.4	F
4	1	8	FA	4	8	T
-4	1	0.4	T	4	0.4	F
5	1	8	FA	4	8	T
-5	1	0.4	T	4	0.4	F
6	1	8	FA	4	8	T
-6	1	0.4	T	4	0.4	F
7	1	8	FA	4	8	T
-7	1	0.4	T	4	0.4	F
10	1	4.952	FA	4	4.048	F
-10	1	0.4	T	4	0.4	F

$$\forall j \neq i = 1, 2, \dots, c. \quad (1)$$

若有 $r_i(x) < r_j(x)$ 则 $x \in \omega_i$

$$\text{式中, } r_j(x) = \sum_{i=1}^c L_{ji} p(x|\omega_i) P(\omega_i), \quad j=1, 2, \dots, c.$$

在故障诊断问题中,利用Bayes最小平均条件风险准则可以使得故障检测错误率最小的。在具体应用中,由于故障模式的概率密度函数 $P(\omega_i/x)$ 是未知的,在这种情况下,只能根据现有的故障特征样本求其统计值,即对 $P(x/\omega_i)$ 进行估计。1962年,Parzen提出了一种从已知随机样本中估计概率密度函数的方法。由Parzen方法得到Parzen窗函数密度估计方法是最一般形式的密度估计方法,对多峰混和情况也适用,只要样本足够多,总可以保证收敛于任何复杂的未知密度。

Parzen窗函数概率密度估计法:设模式 ω_i 有 N_i 个模式样本 $x_j(i)$ ($i=1, 2, \dots, c; j=1, 2, \dots, N_i$), Parzen窗函数取高斯核,则对于模式 ω_i 来说, Parzen窗函数的类条件概率密度估计可写为:

$$\hat{p}_{N_i}(x/\omega_i) = \frac{1}{(2\pi)^{d/2} \sigma^d N_i} \sum_{j=1}^{N_i} \exp[-(x - x_j^{(i)})^T (x - x_j^{(i)}) / 2\sigma^2] \quad (2)$$

式中, σ 为Parzen窗的窗宽度。

PNN网络就是基于Bayes最小平均条件风险准则的神经网络。它采用径向基网络的结构形式,利用Parzen窗函数替代径向基函数,实现贝叶斯决策方法。

2) PNN结构

PNN结构如图3所示,主要包括3层:输入层、模式层和类别层。输入层接受输入向量并进行规格化,模式层对输入向量和权值向量的点积进行非线性处理,类别层根据求和层




图3 PNN结构图
Fig.3 Structure of PNN

的输出进行分类决策^[6]。假设要实现一个Parzen估计,共有n个d 维的样本,都是随机地从c个类别中选取的。在这种情况下,输入层由d 个输入单元构成,每一个输入单元都与n 个模式单元相连。而每一个模式单元都与类别层中c个类别中相应的一个类别单元相连。

(3) PNN的训练

PNN的训练过程如下:

首先,训练样本集中的每一个样本x都被归一化为单位长度,即

然后,对输入层至模式层的权值进行初始化:

$w_k x_k$,其中 $k=1,2,\cdots,n$ 。

w_k 为所有输入单元至k个模式层单元的连接权值。这样,就得到了如下网络:输入层单元与模式层单元之间是完全连通的,而模式层单元到类别层单元之间是稀疏连接的。

PNN 的分类过程如下^[7]:首先将归一化测试样本x提供给输入节点,每一个模式层单元都计算内积,得到“网络激励”(net activation) $s=w_k^T x$ 并产生s的一个非线性函数。每一个类别层单元则把与它相连接的模式层单元的结果进行相加。非线性函数为 $e^{(s-1)/\sigma^2}$,其中s是由用户设置的一个参数,表示有效的高斯窗的宽度。窗宽度可以事先人为确定或根据样本特性来自适应选择。如果令窗宽度s为常数,那么窗函数为:

$$e^{-(xw_k)^T(x-w_k)/2\sigma^2} = e^{(-x^T x + w_k^T w_k - 2x^T w_k)/2\sigma^2} = e^{(s-1)/\sigma^2} \quad (3)$$

其中,使用了归一化条件: $x^T x = w_k^T w_k = 1$ 。

这样,每一个模式层单元就向与它连接的那个类别层单元贡献了一个信号,这个信号的强度等于以当前训练样本为中心的高斯函数产生这个测试样本点的概率。对这些

局部估计值求和就得到判别函数g(x),也就是概率密度函数Parzen 窗的估计结果。通过maxgi(x)运算就可以得到测试点期望值的类别。值得指出的是,当有n个d 维的样本进行训练时,图3中输入层至模式层连接权值个数为 $n \times d$ 个。

在诊断过程中,新的训练样本很容易加入到已经训练好的PNN中,还可以自适应修改模式层与类别层的单元数。如果新的样本不是新的类别,只需增加相应个数的模式层的单元,按照上述方法对输入层与模式层新增加的权值进行赋值即可。如果新的样本属于新的类别,只需在上述基础上再增加相应的类别层单元,而新增加的单元只需与新的样本对应的模式层单元相连。同样如果发现样本数据中有多余的或错误的数据也很容易将其删除。只需删除该样本对应的模式层单元即可。

2.2 PNN作动器故障诊断模型

本文提出的基于PNN的阀芯位置监控器可以充分利用作动器已有的各种信号资源作为PNN神经网络的输入。考虑到信号资源与故障类型的关系,选取的输入参量分别为:指令幅值(COM)、主控阀线位移传感器输出(MCV_LVDT)、作动器线位移传感器输出(RAM_LVDT)及传统监控器的输出(MCV_M)。构建的PNN作动器故障诊断模型输入层具有4个单元对应4个输入参量,类别层具有4个单元对应4种故障类型。

表2为作动器故障数据(由于训练样本数量较大,对四种故障类型仅分别列出一组样本值),将其作为训练样本对PNN网络进行训练,训练后的PNN网络可以对作动器的故障进行在线监控,同时还可以根据新获得的数据对网络再进行网络训练。该方法的优点在于:

表2 训练样本(部分)
Table 2 Training samples (in part)

征兆集																					故障集
COM	0.5	-0.5	1	-1	1.5	-1.5	2	-2	3	-3	4	-4	5	-5	6	-6	7	-7	10	-10	1 正常
MCV_L	-0.2301	0.2301	-0.4335	0.4335	0.1816	-0.1816	3.188	-3.188	8.4	-8.4	8.4	-8.4	8.4	-8.4	8.4	-8.4	8.4	-8.4	8.4	-8.4	
RAM_L	0.5119	-0.5119	1.039	-1.039	1.56	-1.56	1.964	-1.964	2.1	-2.1	2.1	-2.1	2.1	-2.1	2.1	-2.1	2.1	-2.1	2.1	-2.1	
MCV_M	0.0124	0.0124	0.1359	0.1359	0.04746	0.04746	0.4097	0.4097	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	0.4	
COM	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2 指令故障
MCV_L	-0.1699	0.1699	1.639	-1.639	1.639	-1.639	1.639	-1.639	1.639	-1.639	1.639	-1.639	1.639	-1.639	1.639	-1.639	1.639	-1.639	1.639	-1.639	
RAM_L	0.3148	-0.3148	0.4991	-0.4991	0.4991	-0.4991	0.4991	-0.4991	0.4991	-0.4991	0.4991	-0.4991	0.4991	-0.4991	0.4991	-0.4991	0.4991	-0.4991	0.4991	-0.4991	
MCV_M	4.169	4.169	7.908	7.908	7.908	7.908	7.908	7.908	7.908	7.908	7.908	7.908	7.908	7.908	7.908	7.908	7.908	7.908	7.908	7.908	
COM	0.5	-0.5	1	-1	1.5	-1.5	2	-2	3	-3	4	-4	5	-5	6	-6	7	-7	10	-10	3 MCV_ LVDT 故障
MCV_L	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	8	
RAM_L	0.3191	-1.251	0.9207	-1.959	1.533	-2.1	1.959	-2.1	2.1	-2.1	2.1	-2.1	2.1	-2.1	2.1	-2.1	2.1	-2.1	2.1	-2.1	
MCV_M	5.518	0	7.287	3.675	7.731	8.009	4.402	11.6	0	16	0	16	0	16	0	16	0	16	0	16	
COM	0.5	-0.5	1	-1	1.5	-1.5	2	-2	3	-3	4	-4	5	-5	6	-6	7	-7	10	-10	4 RAM_ LVDT 故障
MCV_L	0	-5.171	0	-8.067	0	-8.4	0	-8.4	0	-8.4	0	-8.4	0	-8.4	0	-8.4	0	-8.4	3.048	-8.4	
RAM_L	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	10	
MCV_M	8	2.829	8	0.06722	8	0.4	8	0.4	8	0.4	8	0.4	8	0.4	8	0.4	8	0.4	3.048	0.4	

- 1) PNN网络总收敛于Bayes优化解,稳定性高;
- 2) 网络训练速度快,不存在陷入局部最优的问题;
- 3) 网络样本的追加能力强,可以容忍个别错误的样本;
- 4) 可以提高故障识别率,同时定位故障类别。

利用MATLAB的神经网络工具箱可以对基于PNN的阀芯位置监控器进行仿真^[8-9]。采用如下程序可以建立基于PNN的阀芯位置监控器。

```
P=[P1;P2; P4; P4; P5; P6; P7; P8; P9; P10; P11; P12; P14;
P14; P15]
Tc=[T1;T2; T4; T4; T5; T6; T7; T8; T9; T10; T11; T12; T14;
T14; T15]
T=ind2vec(Tc)
Net=newpnn(P,T,0.1);
Y=sim(net,P)
Yc=vec2ind(Y)
```

3 诊断实例分析

K=[0.8	1.555	0.4984	7.823,	-0.8	-1.555	-0.4984	7.823,
2.5	1.639	0.4991	7.908,	-2.5	-1.639	-0.4991	7.908,
8	1.639	0.4991	7.908,	-8	-1.639	-0.4991	7.908,
0	1.555	0.4984	3.216,	0	-1.555	-0.4984	3.216,
0	1.639	0.4994	6.361,	0	-1.639	-0.4994	6.361,
0	1.639	0.4991	6.361,	0	-1.639	-0.4991	6.361,
0.8	-1.11	0.6689	2.595,	-0.8	-1.038	-1.705	7.148,
2.5	7.637	2.1	0.4515,	-2.5	-8.4	-2.1	1.214,
8	8.4	2.1	0.4,	-8	-8.4	-2.1	0.4,
0.8	8	0.6689	6.515,	-0.8	8	-1.705	1.89,
2.5	8	2.1	0.8142,	-2.5	8	-2.1	1.519,
8	8	2.1	0,	-8	8	-2.1	16,
0.8	6.972	1.937	13.08,	-0.8	0	0	8,
2.5	8.4	2.1	1.214,	-2.5	0	0	8,
8	8.4	2.1	0.4,	-8	0	0	8,
0.8	6.972	-10	1.029,	-0.8	0	-10	8,
2.5	8.4	-10	0.4,	-2.5	0	-10	8,
8	8.4	-10	0,	-8	0	-10	8];

仿真结果表明,在利用300组数据进行训练中,调整SPREAD的值,使PNN网络的故障识别准确率不断提高,最终达到100%。

PNN经过训练之后,即可使用如下新样本(共36组)进行故障诊断:

```
KK=K'/20;
Y=sim(net,KK)
Kc=vec2ind(YY)
```

经统计计算,基于PNN的阀芯位置监控器的故障识别漏检率

为5.4%,虚警率为3.9%,故障识别准确率较传统方法显著提高。进一步将这36组数据重新进行训练,训练后故障识别准确率达100%。

4 结论

(1) 采用概率神经网络建立描述作动器主控阀阀芯位置模型,可用于航空作动器故障的诊断研究,为作动器故障诊断提供了新的方法和手段。

(2) 仿真实验证明,基于PNN的阀芯位置监控器体现了PNN网络具有较强的故障诊断能力。随着故障知识的不断积累,该网络还可以通过学习不断地提高诊断的精度,有效提高了两通道工作时的故障识别准确率,可以成为未来作动器智能故障诊断与健康管理的的重要方法之一。



参考文献

[1] 王少萍,苑中魁,杨光琴. 液压泵信息融合故障诊断[J]. 中国机械工程,2005,16(4):327-331.
WANG Shaoping, YUAN Zhongkui, YANG Guangqin. Study on fault diagnosis of data fusion in hydraulic pump [J]. China Mechanical Engineering, 2005, 16(4):327-331. (in Chinese)

[2] 杨铁林,高英杰,孔祥东. 基于小波变换的柱塞泵故障诊断方法[J]. 机械工程学报,2005,41(2):112-116.
YANG Tielin, GAO Yingjie, KONG Xiangdong. Investagtion onwavelet-based method of fault diagnosis for a piston pump [J]. Chinese Journal of Mechanical Engineering, 2005, 41(2):112-116. (in Chinese)

[3] Raghu P P, Yegnanarayana B. Supervised texture classification using a probabilistic neural network and constraint satisfaction model [J]. IEEE Trans. On Neural Networks, 1998, 9 (3):516-522.

[4] 张建华,侯国莲,孙晓刚,袁桂丽. 采用概率神经网络的汽轮机故障诊断方法[J]. 动力工程,2005,25(10):398-701.
ZHANG Jianhua, HOU Guolian, SUN Xiaogang, YUAN Guili. Research on turbo-generator fault diagnosis using probabilistic neural network [J]. Journal of Power Engineering, 2005, 25(10):398-701. (in Chinese)

[5] 虞和济,陈长征,张省等. 基于神经网络的智能诊断[M]. 北京:冶金工业出版社,2000
YU Heji, CHEN Changzheng, ZHANG Sheng. Intelligent fault diagnosis system based on neural network[M]. Beijing:

- Publishing House of Metallurgy Industry, 2000. (in Chinese)
- [6] 荣蓉. 一类基于概率神经网络的语音识别模型[J]. 山东理工大学学报(自然科学版), 2005, 19(3): 49-52.
- RONG Rong. Speech recognition using probabilistic neural network [J]. Journal of Shandong University of Technology(Natural Science Edition), 2005, 19(3): 49-52. (in Chinese)
- [7] 孙晓刚, 张建华, 侯国莲, 金慰刚. 基于概率神经网络的凝汽器故障诊断研究[J]. 现代电力, 2005, 22(3): 58-61.
- SUN Xiaogang, ZHANG Jianhua, HOU Guolian, JIN Weigang. Condenser fault diagnosis using probabilistic neural networks [J]. Modern Electric Power, 2005, 22(3): 58-61. (in Chinese)
- [8] Richard Johnsonbaugh. 离散数学[M]. 北京: 人民邮电出版社, 2003.
- Richard Johnsonbaugh. Discrete Mathematics[M]. Beijing: Publishing House of People's Posts and Telecommunications, 2003. (in Chinese)
- [9] 飞思科技产品研发中心. 神经网络理论与MATLAB7实现[M]. 北京: 电子工业出版社, 2005.
- Fecit Science and Technology Products Research Center. Neural Networks Theory and MATLAB7 Application[M]. Beijing: Publishing House of Electronics Industry, 2005. (in Chinese)

作者简介

夏立群(1968—)男, 博士, 研究员。研究方向为电液伺服作动器研究。

Tel: 13759999350

E-mail: fcd@facri.com

王可(1978—)女, 博士, 高级工程师, 研究方向为航空作动器设计、健康管理。

E-mail: ocean_ke@163.com

Redundant Actuator Intelligent Fault Diagnosis Based on PNN

XIA Liquan*, WANG Ke

AVIC I Xi'an Flight Automatic Control Research Institute, Xi'an 710065, China

Abstract: A method is presented for actuator fault diagnosis based on probabilistic neural network (PNN). The design scheme and defect of traditional spool displacement monitor are analyzed, and spool displacement monitor based on PNN is constructed. Finally, simulations are made, the results show that spool displacement monitor based on PNN has advanced ability for actuator fault diagnosis and significantly improves the accuracy of spool displacement monitor in dual work condition. It can become an important method for actuator fault diagnosis and health management.

Key Words: Actuator; spool displacement monitor; fault diagnosis; PNN

Received: 2013-10-08; Accepted: 2013-11-08

Foundation item: Aeronautical Science Foundation of China(20070218003)

* Corresponding author. Tel.: 13759999350 E-mail: fcd@facri.com