



(12)发明专利

(10)授权公告号 CN 105129109 B

(45)授权公告日 2017.05.17

(21)申请号 201510642046.8

(22)申请日 2015.09.30

(65)同一申请的已公布的文献号  
申请公布号 CN 105129109 A

(43)申请公布日 2015.12.09

(73)专利权人 北京航空航天大学  
地址 100191 北京市海淀区学院路37号

(72)发明人 刘红梅 李连峰 吕琛 周博  
王轩 王亚杰

(74)专利代理机构 北京科迪生专利代理有限责  
任公司 11251  
代理人 成金玉 孟卜娟

(51)Int.Cl.  
G01M 13/00(2006.01)  
B64F 5/60(2017.01)

(56)对比文件

CN 102606557 A,2012.07.25,说明书摘要,  
说明书第34-97段,附图第1-12幅.

CN 104850889 A,2015.08.19,全文.

CN 104036493 A,2014.09.10,全文.

CN 104390776 A,2015.03.04,全文.

CN 104914851 A,2015.09.16,全文.

WO 2010/046111 A3,2010.07.29,全文.

李兆飞,柴毅,李华峰.多重分形的振动信号  
故障特征提取方法.《数据采集与处理》.2013,第  
28卷(第1期),

审查员 王平

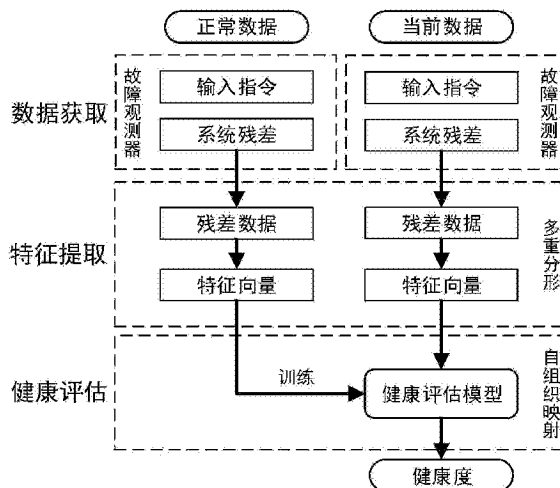
权利要求书1页 说明书9页 附图5页

(54)发明名称

一种基于多重分形理论和自组织映射网络的  
飞机副翼作动器系统健康评估方法

(57)摘要

本发明公开了一种基于多重分形理论和自  
组织映射网络的飞机副翼作动器系统健康评估  
方法,首先通过对飞机副翼作动器系统建立的故  
障观测器得到残差数据,然后通过多重分形去  
趋势波动分析方法对残差信号进行系统健康信  
息的深度挖掘,接着将得到的广义Hurst指数输  
入到SOM网络中,对飞机副翼作动器系统的健  
康状况进行评估。结合副翼作动器常见的四  
种典型的故障模式的仿真数据来验证本方法  
的有效性,实验结果表明该方法能够有效的评  
估出副翼作动器系统的健康状态。



1. 一种基于多重分形理论和自组织映射网络的飞机副翼作动器系统健康评估方法,其特征在于实现步骤如下:

第一步,利用GRNN神经网络构建飞机副翼作动器系统的故障观测器,并获取残差信号;

第二步,利用多重分形去趋势波动分析方法提取残差信号的广义Hurst指数特征向量作为表征副翼作动器健康状态的退化特征向量;

第三步,利用正常状态下残差信号的广义Hurst指数特征向量构建SOM健康评估模型;

第四步,将当前状态的广义Hurst指数特征向量输入至第三步训练好的健康评估模型中,实现飞机副翼作动器系统的健康评估。

2. 根据权利要求1所述的基于多重分形理论和自组织映射网络的飞机副翼作动器系统健康评估方法,其特征在于:所述第一步利用GRNN神经网络构建飞机副翼作动器系统的故障观测器,并获取残差信号的具体过程如下:

(11) 将输入指令输送到副翼作动器系统以获取系统实际输出;

(12) 将输入指令输送到故障观测器以获取观测器输出;

(13) 由副翼作动器的系统输出和故障观测器的输出得到残差信号。

3. 根据权利要求1所述的基于多重分形理论和自组织映射网络的飞机副翼作动器系统健康评估方法,其特征在于:所述第二步,利用多重分形去趋势波动分析方法提取残差信号的广义Hurst指数特征向量作为表征副翼作动器健康状态的退化特征向量的具体过程如下:

1) 将副翼作动器残差信号通过支集计算,子序列划分和多项式拟合方法得到 $q$ 阶波动函数,通过对每个子序列进行 $m$ 阶的多项式拟合,可以有效去除每个子序列中存在的趋势,从而有利于辨识局部分形特征;

2) 为了确定副翼作动器残差信号波动函数的标度性,对每一个 $q$ 分析 $\log(F_q(s))$ 和 $\log(s)$ 之间的关系,波动函数的平均值 $F_q(s)$ 和尺度 $s$ 之间存在幂律关系,由 $q$ 阶波动函数得到广义Hurst指数特征向量。

4. 根据权利要求1所述的基于多重分形理论和自组织映射网络的飞机副翼作动器系统健康评估方法,其特征在于:所述第三步,利用正常状态下残差信号的广义Hurst指数特征向量构建SOM健康评估模型,所述第四步,将当前状态的广义Hurst指数特征向量输入至第三步训练好的健康评估模型中,实现飞机副翼作动器系统的健康评估,具体过程如下:

1) 根据第二步所提取的广义Hurst指数特征向量的维数,确定SOM评估模型的输入层节点数;

2) 利用正常状态下副翼作动器残差信号的广义Hurst指数特征向量,通过无监督训练方法,确定SOM评估模型正常状态特征空间,获得副翼作动器的健康基线;

3) 利用当前状态下副翼作动器残差信号的广义Hurst指数特征向量,计算当前运行状态广义Hurst指数特征向量空间与正常状态特征空间的偏移度实现健康评估。

## 一种基于多重分形理论和自组织映射网络的飞机副翼作动器系统健康评估方法

### 技术领域

[0001] 本发明涉及一种基于多重分形理论和自组织映射网络的飞机副翼作动器系统健康评估方法。

### 背景技术

[0002] 随着科学技术的发展,飞机的液压作动系统越来越复杂,自动化水平越来越高,飞机运行中发生的任何故障或失效不仅会造成重大的经济损失,而且很可能导致机毁人亡。通过对飞机运行状况进行检测,对故障发展趋势进行早期诊断,找出故障原因,采取措施避免设备的突然损坏。因此故障检测可用于及时发现系统是否存在故障,在发生故障后及时改变任务或为事后维修提供支持。而在故障诊断与健康领域,除了故障检测这一范畴,健康评估具有更实用的指导意义。一般认为事物乃至复杂系统从完好到故障需要经历三个大阶段,即“健康-亚健康-故障”。在故障诊断与健康领域受到越来越多专家学者重视的今天,如何能对系统的健康状态进行评估已经成为一个研究热点。准确地评估系统当前的健康状态,不仅有助于提升对系统的了解和根据系统状态制定适宜的任务,更重要的是,利用系统的健康评估结果可以执行相应的预防性维修,从而使系统尽可能的转向健康状态。此外,系统健康状态的评定对于人力人员、备件使用等维修保障资源及相应的维修保障决策的制定都具有非常大的支持作用。目前对于飞机副翼作动器系统的健康评估方面的研究较少。目前,常用的系统健康状态评估方法是在故障特征识别的基础上对当前状态进行评估。这种方法通过对提取的特征向量进行模式识别,根据特征向量匹配系统的健康状态实现健康评估。因此,它极度依赖历史数据和故障数据,需要保存不同故障程度的数据和其对应的特征向量。对飞机副翼作动器系统而言,一方面因其具有重要作用必须要评估其健康状态,另一方面其故障数据又很难获取,因此基于特征识别的方法在实际应用中受到了一定的限制。由于飞机副翼作动器系统结构紧凑、中间难以加装任何传感器,通常只有作动器系统输入端的指令信号与输出端的位移信号较容易获取;另外,作动器系统属于精密反馈控制系统,即使系统发生故障,其输出位移信号也因存在反馈修正环节使得输出信号包含的故障信息少之又少。因此,评估其健康状态受到了限制。

### 发明内容

[0003] 本发明技术解决问题:克服现有技术的不足,提供一种基于多重分形理论和自组织映射网络的副翼作动器系统健康评估方法,解决副翼作动器系统的健康评估这一问题。

[0004] 本发明技术解决方案:一种基于多重分形理论和自组织映射网络的飞机副翼作动器系统健康评估方法,实现步骤如下:

[0005] 第一步,由飞机副翼作动器系统在输入指令作用下的系统输出和故障观测器的输出构造残差信号;

[0006] 第二步,利用多重分形理论对所述残差信号进行特征提取,获取表征飞机副翼作

动器系统健康状态的特征向量；

[0007] 第三步,将获得的特征向量输入由自组织映射网络(SOM)构成的健康评估模型进行训练;

[0008] 第四步,将第二步,获取的特征向量并输入至第三步训练好的健康评估模型中,得到飞机副翼作动器系统当前状态下的健康度。

[0009] 所述第一步将飞机副翼作动器系统正常工作时获取的输入指令和输出输送至故障观测器获取残差信号的具体过程如下:

[0010] (11) 将输入指令输送到副翼作动器系统以获取系统实际输出;

[0011] (12) 将输入指令输送到故障观测器以获取观测器输出;

[0012] (13) 由副翼作动器的系统输出和故障观测器的输出得到残差信号。

[0013] 所述第二步,利用多重分形理论对所述残差信号进行特征提取,获取表征飞机副翼作动器系统健康状态的特征向量的具体过程如下:

[0014] (21) 由残差信号通过“支集”计算、子序列划分和多项式拟合方法得到 $q$ 阶波动函数。通过对每个子序列进行 $m$ 阶的多项式拟合,可以有效去除每个子序列中存在的趋势,从而有利于辨识局部分形特征;所述支集为依照残差信号时间序列定义的一种绝对值时间序列;

[0015] (22) 为了确定波动函数的标度性,对每一个 $q$ 分析 $\log(F_q(s))$ 和 $\log(s)$ 之间的关系,波动函数的平均值 $F_q(s)$ 和尺度 $s$ 之间存在幂律关系。因此由 $q$ 阶波动函数得到广义Hurst指数,其即为特征向量。

[0016] 所述第三步,将获得的特征向量输入由自组织映射网络(SOM)构成的健康评估模型进行训练的具体过程如下:

[0017] (31) 设定变量和初始化。将残差信号作为输入样本,输入样本直接与输入层相连并一一对应,起初权值会采用较小的随机值,之后需要对输入向量和权值进行基于欧几里得范数的归一化处理;

[0018] (32) 将样本与权值向量做内积,其内积值可作为判别函数的值,获得最大判别函数值的输出神经元赢得竞争。接下来对SOM网络进行权值、学习率和拓补领域的迭代更新。

[0019] 所述第四步,将获得的实时特征向量输入由自组织映射网络(SOM)构成的健康评估模型进行健康状态评估的具体过程如下:

[0020] (41) SOM网络经过训练后会产生与其相匹配的一个最佳匹配单元(BMU),训练完成后SOM网络会保存该最佳匹配单元的相关参数。在这里我们计算实时特征数据与最佳匹配单元(BMU)之间的距离,即最小量化误差MQE。最小量化误差(MQE)可定量得出实时数据与正常数据的偏离状况,即作动器系统当前运行状态与正常状态分别对应的特征空间的偏移度;

[0021] (42) 由于MQE表示的是运行状态与正常状态对应特征空间的偏移度,其直观上并没有反映出系统的健康程度。因此,尚需要进一步将MQE转化为可以表征健康状态的量值(0~1)。通过一定的归一化方法,将所得MQE转化为健康度(CV值)。CV值在0到1之间,此时的CV值就能表征作动器系统当前的健康状态,CV值接近于1表明作动器系统健康状态良好,CV值的下降表明作动器系统健康状态处于退化阶段。

[0022] 本发明与现有技术相比的优点在于:

[0023] (1) 一般的残差特征提取采用时域分析和频域分析,对于非线性、非平稳的作动器系统,这两种方法均有一定的局限性。基于分形理论对残差信号进行Hurst指数的提取并计算当前状态的特征向量偏移度,可以实现作动器系统准确的健康状态的评估。

[0024] (2) SOM网络具有无教师、自组织、自学习的特点。此外,该网络的另一个特点是其内部的所有神经元相互连接,其内部的神经元各自具有不同的分工。与其它网络不同的是,自组织特征映射网络在学习数据特征的同时也在对数据的拓扑结构进行学习,类似于大脑神经的特征映射过程。因此,可以实现健康状态的有效评估。

[0025] (3) 基于多重分形的作动器健康评估方法利用多重分形去趋势波动分析对残差信号的广义Hurst指数进行提取,利用不同尺度下的Hurst指数表征作动器系统的健康状态,并将广义Hurst指数作为基于SOM网络的健康评估模型的输入。通过实例分析结果可知,基于多重分形的特征提取方法提取的残差广义Hurst指数具有更好的稳定性,在表征系统健康状态方面具有更大的优势,得到的健康度曲线也更加平滑、稳定,具有更好的指导意义。

## 附图说明

[0026] 图1为本发明方法实现流程图;

[0027] 图2为SOM网络结构图;

[0028] 图3为本发明中SOM健康评估流程图;

[0029] 图4为本发明中电子放大器突变退化时广义Hurst指数散点图;

[0030] 图5为传感器突变退化时广义Hurst指数散点图;

[0031] 图6为作动筒内泄漏时广义Hurst指数散点图;

[0032] 图7为正常状态健康度曲线;

[0033] 图8为电子放大器性能突变退化下健康度曲线;

[0034] 图9电子放大器性能缓变退化下健康度曲线;

[0035] 图10为传感器性能突变退化下健康度曲线;

[0036] 图11为作动筒内泄漏退化健康度曲线。

## 具体实施方式

[0037] 如图1所示,本发明基于多重分形理论和自组织映射(SOM)的作动器系统健康评估基本流程:首先,将系统正常工作时获取的输入指令和系统输出输送至故障观测器获取残差信号;然后,利用多重分形理论对残差信号进行特征提取,获取可以表征系统健康状态的特征向量;接下来,将获得的系统正常工作时的特征向量用于健康评估模型的训练;最后,获取系统当前状态下的特征向量并输入至训练好的健康评估模型中,得到系统当前状态下的健康度。

[0038] 1. 基于多重分形理论的作动器系统误差信号特征提取

[0039] 在旋转机械等其它设备的故障诊断领域,频域分析和时域分析是两大常用的特征提取技术。频域分析通常包括快速傅里叶变换、小波变化和短时傅里叶变换等。时域分析通常包括计算信号的最大值、有效值和峭度等时域特征。由于作动器系统残差信号是系统实际输出和观测器估计输出量的差值,属于缓变信号的范畴。而频域分析更多的是针对快变信号,因此,频域分析难以运用到作动器系统残差信号的特征提取。相对而言,时域分析具

有更大的普适性,其特征提取技术对于缓变信号也同样适用。但是,作动器系统本身的复杂性、非线性特性以及非平稳特性决定了其残差信号的时域特征的不稳定。仅仅通过时域特征分析作动器系统的健康状态势必会造成评估结果较大的波动。

[0040] 分形理论最先由曼德勃罗提出,他在宇宙学领域中碰到了一些杂乱无章、破碎不堪的统计分布现象,这些现象不能用直线、平面或是三维立体来描述,经典的欧式几何难以适用。同时,他也发现:在大自然中普遍存在着这种外表上看似杂乱无章的现象,如河流、海岸线的分布和天空中云朵的分布等等。这些现象虽然不能直观地从形状和结构上找出规律,但其自身所具有的复杂性和不规则性却存在一定的内在规律。

[0041] 按观测尺度划分,分形又可以分为单重分形和多重分形。通常存在的单重分形仅从一个尺度对时间序列进行描述,由于尺度的单一,可能会出现某一尺度下不同的序列其分形特性一致的情况,从而造成混淆。而多重分形,也称多尺度分形,用来从不同的尺度去描述事物的局部分形特性,这种方法可以从更全面、普遍的角度描述时间序列的分形特性。通常的多重分形方法存在一定的局限性,如分析的时间序列必须为平稳时间序列,否则可能会得到错误的结果。相比而言,多重分形去趋势波动分析将去趋势波动分析和多重分形相结合,可以有效减少干扰趋势,有利于挖掘非平稳时间序列内的多重分形特性。多重分形去趋势波动分析具体包括:

[0042] 步骤1:对于时间序列 $x_k$ ,其长度为 $N$ 。则‘支集’ $Y(i)$ 定义为:

$$[0043] \quad Y(i) \equiv \sum_{k=1}^i |x_k - \langle x \rangle|, \quad i=1, \dots, N \quad (1)$$

$$[0044] \quad \langle x \rangle = \frac{1}{N} \sum_{k=1}^N x_k \quad (2)$$

[0045] 式(1)和(2)中, $x_k$ 为时间序列, $\langle x \rangle$ 为序列均值, $N$ 为时间序列长度, $Y(i)$ 为‘支集’。

[0046] 步骤2:将序列 $Y(i)$ 分为 $m$ 个具有等长度 $s$ 的不重叠子序列,其中 $m = \text{int}(N/s)$ 。通常 $N$ 不是子序列长度 $s$ 的整数倍。为了充分利用数据,将序列 $Y(i)$ 从后向前重新排列后仍然分为 $m$ 个具有等长度 $s$ 的不重叠子序列。这样,共得到 $2m$ 个子序列。

[0047] 步骤3:利用最小二乘算法对每个子序列的多项式趋势进行拟合,每个子序列的方差用 $F^2(s, v)$ 表示:

[0048] 当 $v=1, \dots, m$ ,

$$[0049] \quad F^2(s, v) \equiv \frac{1}{s} \sum_{i=1}^s \{Y[(v-1)s+i] - y_v(i)\}^2 \quad (3)$$

[0050] 当 $v=m+1, \dots, 2m$ ,

$$[0051] \quad F^2(s, v) \equiv \frac{1}{s} \sum_{i=1}^s \{Y[N-(v-m)s+i] - y_v(i)\}^2 \quad (4)$$

[0052] 上式中, $s$ 为子序列长度, $Y[(v-1)s+i]$ 和 $Y[N-(v-m)s+i]$ 分别表示顺序第 $v$ 个( $1, 2, \dots, m$ )支集和逆序第 $v$ ( $m+1, m+2, \dots, 2m$ )个支集, $y_v(i)$ 是子序列 $v$ 的拟合多项式,拟合多项式反映了趋势去除的程度。

[0053] 步骤4: $q$ 阶波动函数定义为:

$$[0054] \quad F_q(s) = \left\{ \frac{1}{2m} \sum_{v=1}^{2m} [F^2(s, v)]^{\frac{q}{2}} \right\}^{\frac{1}{q}} \quad (5)$$

[0055] 式中,  $F_q(s)$  为波动函数,  $2m$  为总子序列数,  $q$  为阶数,  $F^2(s, v)$  为子序列方差。

[0056] 对于不同子序列长度  $s$ , 重复步骤2-步骤4以得到  $F_q(s)$  对于  $q$  和  $s$  的函数。通过对每个子序列进行  $m$  阶的多项式拟合, 可以有效去除每个子序列中存在的趋势, 从而有利于辨识局部分形特征。

[0057] 步骤5: 为了确定波动函数的标度性, 对每一个  $q$  分析  $\log(F_q(s))$  和  $\log(s)$  之间的关系, 波动函数的平均值  $F_q(s)$  和尺度  $s$  之间存在以下幂律关系:

$$[0058] \quad F_q(s) \sim s^{H(q)} \quad (6)$$

[0059] 其中,  $s$  为序列长度,  $F_q(s)$  为  $q$  阶波动函数的平均值,  $H(q)$  就是广义Hurst指数, 又称长相关系数, 用于表征过去时间序列对现在和将来的时间序列的影响。

[0060] 对于作动器系统, 过去处于的正常状态并不能保证当前仍处于正常状态。但由于不可自我修复, 作动器系统的故障状态会一直持续下去。基于这点, 过去的正常状态和故障状态的时间序列对现在和未来时间序列的影响是不同的, 其Hurst指数也不同, 因此Hurst指数可以用于表征作动器系统的健康状态。对于具有多重分形特性的时间序列, 广义Hurst指数依赖于尺度  $q$ , 不同尺度  $q$  对应的广义Hurst指数不同。由于大多数单重分形是在一些极限环境下得到的, 如计算机的反复迭代, 而多重分形则广泛存在于自然界中, 因此, 多重分形能够从更宽泛、更普遍的角度去描述副翼作动器系统残差信号的分形特性。

[0061] 2. 基于自组织映射(SOM)的作动器系统健康评估

[0062] 2.1 自组织映射(SOM)网络概述

[0063] 自组织映射网络具有无监督、自组织、自学习的特点。与其它网络不同, 类似于大脑神经的特征映射过程, 自组织特征映射网络在学习数据特征的同时也在对数据的拓扑结构进行学习。对于一个特定的输入, 网络内的神经元会以区域为单位进行相互竞争, 同时, 区域内部也会存在相互竞争, 竞争实力的强弱取决于预定的判断函数, 判别函数值最大的神经元获胜。获胜的神经元的位置会决定神经元兴奋区域的空间位置, 并会影响领域内的神经元。离获胜神经元越远, 这种影响会越小。这样, 经过区域化的权值更新, 即离获胜神经元近的神经元权值更新, 离获胜神经元远的神经元权值不更新, 这使得在集合上相近的神经元相互之间更加相似。

[0064] SOM网络结构如图2所示, 通常分上下两层, 上层一般称作竞争层, 下层可以接收输入向量, 因此被称为输入层。输入层由一维的神经元组成, 设神经元的个数为  $m$ , 竞争层则由二维神经元阵列组成, 设该层共有  $a \times b$  个神经元, 输入层与竞争层各神经元之间实现全连接。

[0065] SOM网络的训练步骤如下:

[0066] (1) 设定变量。  $x = [x_1, x_2, \dots, x_m]$  为输入样本, 输入样本直接与输入层相连并一一对应, 每个样本的维数为  $m$ , 则输入层的维数为  $m$ 。其中, 输入节点与输出神经元之间的权值向量用  $\omega$  表示,  $\omega_i(k) = [\omega_{i1}(k), \omega_{i2}(k), \dots, \omega_{in}(k)]$  为第  $i$  个输入节点与输出神经元之间的权值向量。

[0067] (2) 初始化。一开始, 权值会采用较小的随机值, 之后需要对输入向量和权值进行

基于欧几里得范数的归一化处理:

$$[0068] \quad x' = \frac{x}{\|x\|} \quad (7)$$

$$[0069] \quad \omega_i'(k) = \frac{\omega_i(k)}{\|\omega_i(k)\|} \quad (8)$$

[0070] 其中,  $x = [x_1, x_2, \dots, x_m]$  为输入样本,  $\omega_i(k) = [\omega_{i1}(k), \omega_{i2}(k), \dots, \omega_{in}(k)]$  为第  $i$  个输入节点与输出神经元之间的权值向量,  $\|\cdot\|$  代表计算向量的欧几里得范数,  $x'$  和  $\omega_i'(k)$  为经归一化处理后的输入数据和权值。

[0071] (3) 将随机抽取的样本输入网络。将样本与权值向量做内积, 其内积值可作为判别函数的值, 获得最大判别函数值的输出神经元赢得竞争。由于样本向量与权值均已归一化, 因此, 求内积值最大可转化为求欧氏距离最小:

$$[0072] \quad D = \|x - \omega\| \quad (9)$$

[0073] 式中,  $x$  为样本向量,  $\omega$  为权值,  $D$  为样本向量和权值之间的欧氏距离。

[0074] (4) 对领域内的神经元进行权值更新。

$$[0075] \quad \omega(k+1) = \omega(k) + \eta(x - \omega(k)) \quad (10)$$

[0076] 式中,  $\omega(k+1)$  和  $\omega(k)$  分别表示第  $k+1$  次和  $k$  次的权值,  $\eta$  为学习率。

[0077] 确定神经元拓扑领域时, 可以使用不同的距离函数。

[0078] (5) 学习速率  $\eta$  及拓扑领域的更新。

[0079] 转到第三步并进行反复迭代, 直到达到预定的最大迭代次数。

## [0080] 2.2 基于自组织映射 (SOM) 网络的健康评估模型

[0081] 如图3所示, 首先利用正常数据对SOM网络进行训练, 对于正常情况下的特征数据  $X_{\text{normal}}$ , SOM网络经过训练会产生与其相匹配的一个最佳匹配单元 (BMU), 训练完成后SOM网络会保存该最佳匹配单元的相关参数。然后输入实时特征数据, SOM网络会计算所输入的实时特征数据  $X$  与保存好的BMU之间的距离, 即最小量化误差 (MQE)。这里, 最小量化误差 (MQE) 可定量得出实时数据与正常数据的偏离状况, 即作动器系统当前运行状态与正常状态分别对应的特征空间的偏移度。

$$[0082] \quad MQE = \|D - m_{\text{BMU}}\| \quad (11)$$

[0083] 其中,  $D$  为输入的测试样本向量,  $m_{\text{BMU}}$  为最佳匹配单元BMU的权重, MQE为最小量化误差。

[0084] 由于MQE表示的是运行状态与正常状态对应特征空间的偏移度, 其直观上并没有反映出系统的健康程度, 因此需要进一步将MQE转化为可以表征健康状态的度量值。健康度 (CV) 概念用以表示系统健康等级。健康度越大表明系统处于良好状态的可能性越大, 健康度越低表明系统很有可能处于性能退化中或是已发生故障。通过MQE可以得到CV值:

$$[0085] \quad CV = 1 - a \tan \frac{\sqrt{MQE/b}}{\pi/2} \quad (12)$$

[0086] 式中, MQE为最小量化误差,  $a \times b$  为竞争层神经元的阵列尺寸。

[0087] CV值在0到1之间, 可以用来表征作动器系统当前的健康状态, CV值接近于1表明作动器系统健康状态良好, CV值的下降表明作动器系统健康状态发生退化。

## [0088] 3. 应用实例



[0089] 为验证基于多重分形理论和自组织映射网络的作动器系统健康评估方法的有效性,结合副翼作动器常见的四种典型的故障模式的仿真数据来验证本方法的有效性,实验结果表明该方法能够有效的评估出副翼作动器系统的健康状态。

[0090] 利用正常数据和不同故障模式的退化数据对作动器系统的健康评估案例进行分析。首先,需要在作动器系统处于正常情况下运行模型并采集模型的输出,其采集频率为1000Hz,采集时间为24s。之后,获取不同故障模式下的性能退化数据,鉴于健康评估的对象是亚健康状态的副翼作动器系统,此时的作动器系统状态偏差量应小于故障时的状态偏差,因此,此时不同故障模式注入的故障程度较轻,如表1所示,共考虑电子放大器突变故障、电子放大器缓变故障、传感器恒增益性能退化和作动筒内泄漏共4种性能退化形式。

[0091] 表1副翼作动器故障注入

[0092]

序号	故障部件	故障类型	故障注入 对应参数	正常值	故障值	注入时间
1	电子放大器	突变退化	$K$	900	800	12 s
					700	18 s
2	电子放大器	缓变退化	$K$	900	$900 \cdot \exp(-0.04 \times (t-t_s))$	12 s
3	传感器	恒增益	$K_s$	1	0.999	12 s
					0.995	18 s
4	作动筒	内泄漏	直径间隙	0.02 mm	0.1 mm	12 s
					0.2 mm	18 s

[0093] 基于GRNN神经网络的故障观测器获取作动器系统正常情况下的残差和性能退化时的残差之后,本发明利用多重分形去趋势波动分析对获取的残差信号进行特征提取。由正常情况、电子放大器突变退化、电子放大器缓变退化、传感器恒增益性能退化和作动筒内泄漏5组数据共得到5组残差,每组残差包括24000个数据点,为保证其精度以每2000个残差数据点作为一个样本,每个样本进行一次分析。由于 $q > 0$ 时主要反映受大波动的影响, $q < 0$ 时主要反映受小波动的影响,尺度 $q$ 通常以0为对称中心进行取值,且一般选取三个以上的尺度,因此本文选取尺度为 $[-2, -1, 0, 1, 2]$ 。子序列拟合多项式的阶数设为3。由于尺度 $q$ 的维数为5,得到的广义Hurst指数 $H(q)$ 的维数同样也是5。这样,每个样本得到的特征向量 $\omega$ 为:

$$[0094] \quad \omega = H(q) = \begin{pmatrix} H(q=-2) \\ \vdots \\ H(q=2) \end{pmatrix} \quad (13)$$

[0095] 式中, $H(q=-2) \cdots H(q=2)$ 为 $q=-2, -1, 0, 1, 2$ 的Hurst指数, $q$ 为阶数。

[0096] 为验证基于多重分形去趋势波动分析得到的残差信号广义Hurst指数向量是否适

用于表征作动器系统的健康状态,本节对正常情况下的残差信号进行多重分形去趋势波动分析,同时对不同退化模式、不同退化程度的数据进行多重分形去趋势波动分析,并将结果进行对比。为了使结果可视化,对于得到的特征向量 $\omega$ ,仅提取 $H(q)$ 在 $-2,0,2$ 三个尺度的值,并将 $H(q=-2),H(q=0),H(q=2)$ 分别作为坐标轴的 $x,y,z$ 轴进行散点图的绘制。电子放大器突变退化、传感器恒增益性能退化和作动筒内泄漏对应的广义Hurst指数 $H(q)$ 散点图分别见图4~图6。由图4~图6分析可知,系统处于正常状态时,通过多重分形去趋势波动分析,其故障观测器残差的广义Hurst指数保持相对稳定,在散点图内处于一定的特征空间 $\tau$ 内。当系统发生性能退化时,其故障观测器残差的广义Hurst指数所处的特征空间会发生明显的改变。此时,对应的广义Hurst指数处于一个新的特征空间 $\tau_1$ 内,且同样退化程度对应的广义Hurst指数都处于这一空间。如果性能继续退化,其故障观测器残差的广义Hurst指数所处的特征空间会继续发生偏移,对应的广义Hurst指数所处的特征空间为 $\tau_2$ ,同样的,同处于该退化程度的广义Hurst指数都处于这一空间内。由于性能退化程度加深,退化特征空间 $\tau_2$ 与 $\tau$ 的距离要大于退化特征空间 $\tau_1$ 与 $\tau$ 的距离,也就意味着,性能退化越严重,其广义Hurst指数所处的特征空间与正常特征空间 $\tau$ 的距离越远。因此,多重分形分析中的广义Hurst指数能够用来表征副翼作动器系统的健康状态。

[0097] 接下来,将得到的广义Hurst指数与SOM网络结合进行作动器系统的健康评估。将特征向量 $\omega = H(q)$ 作为SOM网络的输入,设置训练次数为100,初始健康度为0.99。选取系统正常状态下的12组 $\omega$ 向量作为SOM神经网络的输入进行训练,保存训练好的神经网络。将待测试的作动器系统的广义Hurst指数样本作为SOM神经网络的输入,计算输出量与BMU(最佳匹配单元)之间的距离即最小量化误差(MQE),并计算对应的CV值,以表征此时此刻系统的健康度。设定最低健康度阈值为0.4,即健康度低于0.4时需要进行相应的维修计划,实施相应的维修保障工作。正常情况、电子放大器突变退化、电子放大器缓变退化、传感器恒增益性能退化和作动筒内泄漏的健康度曲线分别见图7~图11。分析图7~图11所示的健康度曲线可知,系统处于正常情况时,其健康度保持相对稳定,处于1附近。当系统发生突变性能退化时,其健康度会迅速发生明显的降低。当系统发生缓变性能退化时,作动器系统的健康度会由原本的健康度缓慢降低。此外,作动器系统的退化程度越严重,其健康度越低。无论是电子放大器突变退化、电子放大器缓变退化、传感器恒增益性能退化或是作动筒内泄漏,上述结论均适用。

[0098] 由以上分析可以得出结论:

[0099] (1) 利用多重分形分析提取作动器系统残差信号中的广义Hurst指数能够用来表征作动器系统的健康状态;

[0100] (2) 进一步利用SOM网络作为系统健康评估模型,通过计算当前状态与正常状态下的特征向量之间的重叠度可以得到系统的健康度(CV)曲线;

[0101] (3) 得到的健康度曲线可以有效反映出作动器系统的健康状况。

[0102] 通过故障观测器获取的系统残差是系统当前状态与正常状态的偏差,其中包含了作动器系统大量的状态信息和故障信息,因此本发明选取系统残差作为作动器系统性能退化评估的待评估量,使用多重分形理论进行特征提取,最后应用自组织映射网络(SOM)进行系统的健康状态评估。若直接利用原始数据训练和测试健康评估模型,模型的鲁棒性差,不能准确评价系统状态,所以需要对该系统残差进行数据预处理和特征提取,起到平滑数据

和突出特征的作用。

[0103] 提供以上实施例仅仅是为了描述本发明的目的,而并非要限制本发明的范围。本发明的范围由所附权利要求限定。不脱离本发明的精神和原理而做出的各种等同替换和修改,均应涵盖在本发明的范围之内。

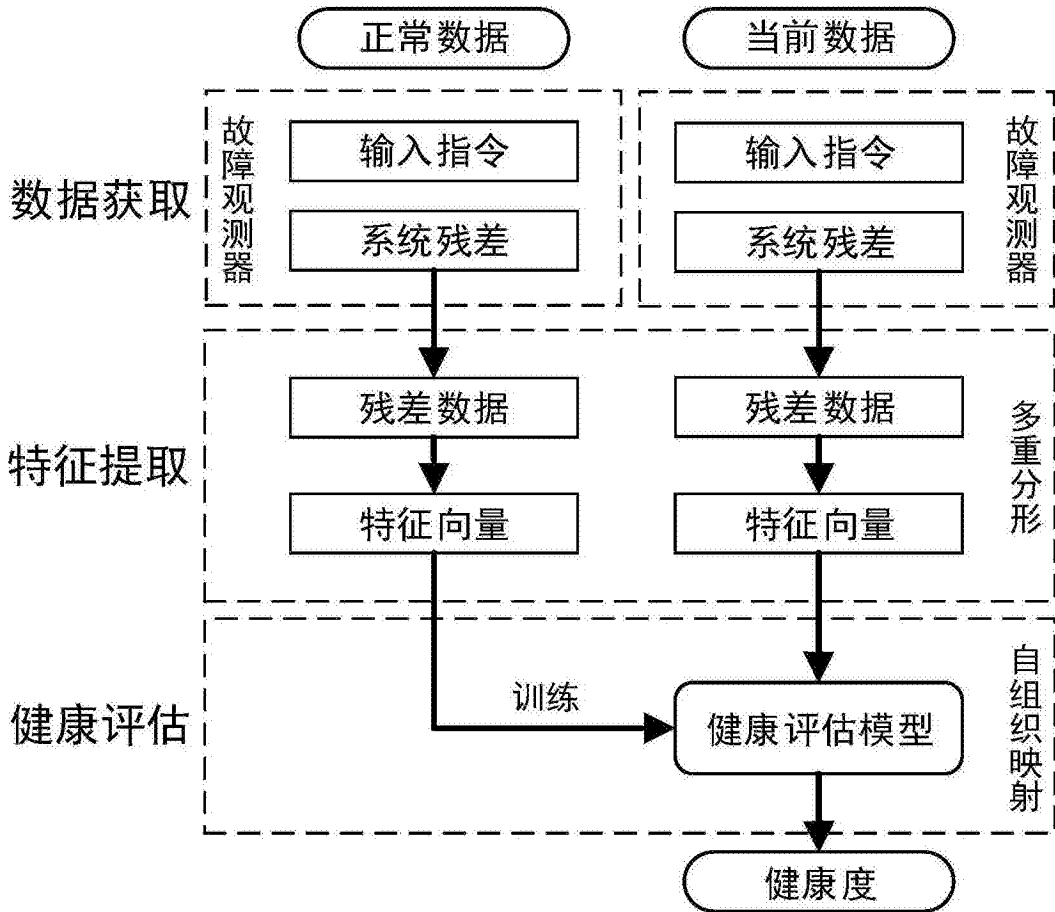


图1




图2

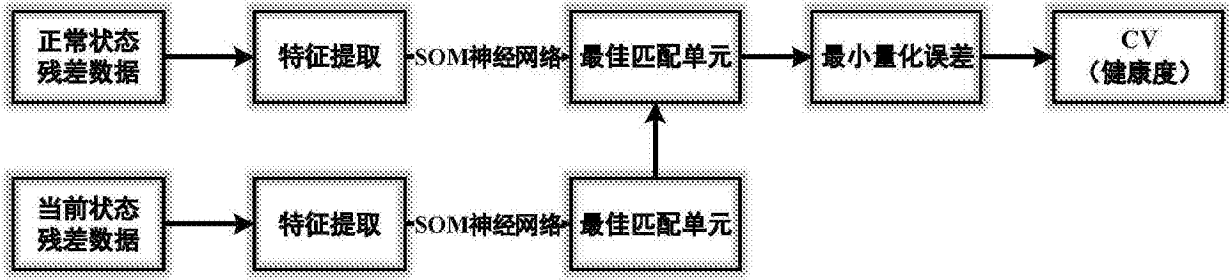


图3




图4




图5




图6




图7




图8




图9




图10




图11