



(12)发明专利

(10)授权公告号 CN 103646013 B

(45)授权公告日 2017.01.18

(21)申请号 201310662933.2

(22)申请日 2013.12.09

(65)同一申请的已公布的文献号  
申请公布号 CN 103646013 A

(43)申请公布日 2014.03.19

(73)专利权人 清华大学  
地址 100084 北京市海淀区100084信箱82  
分箱清华大学专利办公室

(72)发明人 周东华 宁超 陈茂银

(74)专利代理机构 北京聿宏知识产权代理有限公司 11372

代理人 吴大建 刘华联

(51)Int.Cl.

G06F 17/16(2006.01)

G06F 11/00(2006.01)

(56)对比文件

CN 102436524 A,2012.05.02,

KR 10-1331274 B1,2013.11.20,

EP 2034284 A2,2009.03.11,

CN 101458522 A,2009.06.17,

S. Joe Qin.Survey on data-driven industrial process monitoring and diagnosis.《Annual Reviews in Control》.2012,

李明.基于多元统计分析的故障诊断方法及其应用研究.《中国优秀硕士学位论文全文数据库(信息科技辑)》.2006,(第12期),

审查员 张俊

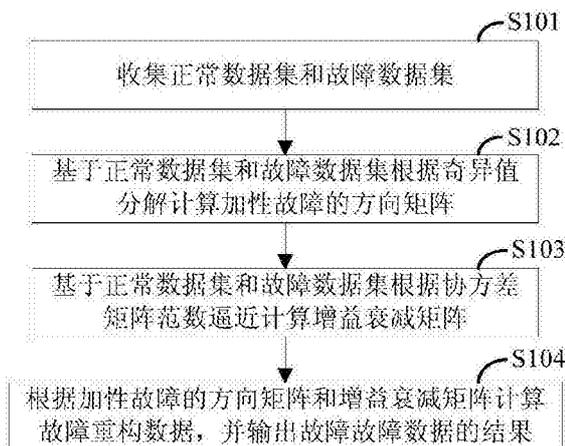
权利要求书2页 说明书8页 附图3页

(54)发明名称

一种基于协方差矩阵范数逼近的多重故障重构方法

(57)摘要

本发明公开了一种基于协方差矩阵范数逼近的多重故障重构方法,该方法包括:收集正常数据集和故障数据集;基于正常数据集和故障数据集采用奇异值分解计算加性故障的方向矩阵;基于正常数据集和故障数据集采用协方差矩阵范数逼近计算增益衰减矩阵;根据加性故障的方向矩阵和增益衰减矩阵计算故障重构数据,以用于设备故障的检测分析。该方法能够更为准确地提取加性故障的方向,有效减小故障重构误差,对故障的描述更为全面和准确,同时还能够获得增益衰减信息。



1. 一种基于协方差矩阵范数逼近的多重故障重构方法,其特征在于,所述方法包括:  
 收集正常数据集和故障数据集;  
 基于正常数据集和故障数据集采用奇异值分解计算加性故障的方向矩阵;  
 基于正常数据集和故障数据集采用协方差矩阵范数逼近计算增益衰减矩阵;  
 根据所述加性故障的方向矩阵和增益衰减矩阵计算故障重构数据,以用于设备故障的检测分析;

其中,所述计算加性故障的方向矩阵的步骤进一步包括:

采用预设窗口长度的滑动窗口分别对所述正常数据集和故障数据集进行滑动平均,构建相应的正常数据平均值矩阵和故障数据平均值矩阵;

确定所述正常数据平均值矩阵各元素的绝对值中的最大值;

将所述故障数据平均值矩阵中各元素的绝对值与所述正常数据平均值矩阵各元素的绝对值中的最大值进行比较,并根据比较结果对故障数据平均值矩阵中相应的元素进行重置,获得扰动去除数据矩阵;

对所述扰动去除数据矩阵进行奇异值分解,得到加性故障的方向矩阵。

2. 如权利要求1所述的方法,其特征在于,根据比较结果对故障数据平均值矩阵中相应的元素进行重置的步骤进一步包括:

$$D^T = [d_{ij}], \text{ 其中 } d_{ij} = \begin{cases} 0 & |z_{ij}| \leq \delta^* \\ z_{ij} & |z_{ij}| > \delta^* \end{cases}$$

其中, $D^T$ 表示扰动去除数据矩阵, $d_{ij}$ 表示矩阵 $D^T$ 中第*i*行第*j*列的元素, $z_{ij}$ 表示故障数据平均值矩阵中第*i*行第*j*列的元素, $\delta^*$ 表示正常数据平均值矩阵各元素的绝对值中的最大值。

3. 如权利要求1所述的方法,其特征在于,对所述扰动去除数据矩阵进行奇异值分解,得到加性故障的方向矩阵的步骤进一步包括:

采用 $D^T = U \Omega V^T$ 对扰动去除数据矩阵 $D^T$ 进行奇异值分解,得到酉矩阵 $U$ ,作为加性故障的方向矩阵。

4. 如权利要求1所述的方法,其特征在于,所述计算增益衰减矩阵步骤进一步包括:

基于正常数据集计算正常数据集的协方差矩阵的估计;

基于加性故障的方向矩阵,根据故障数据集和增益衰减矩阵构建基于故障数据集的协方差矩阵;

在指定范数意义下使基于故障数据集的协方差矩阵逼近正常数据集的协方差矩阵的估计,以求解基于故障数据集的协方差矩阵中的增益衰减矩阵。

5. 如权利要求4所述的方法,其特征在于,构建基于故障数据集的协方差矩阵步骤进一步包括:

$$S = J(E_i) \Sigma J(E_i)^T$$

其中,

$$J(E_i) = E_i^{-1} [I - \Xi_i (\tilde{C} E_i^{-1} \Xi_i)^+ \tilde{C} E_i^{-1}]$$

$$\Sigma = \frac{1}{N-1} \sum_{k=1}^N x(k) x^T(k)$$

S表示基于故障数据集的协方差矩阵,  $E_i$ 表示增益衰减矩阵,  $\Xi_i$ 表示加性故障的方向矩阵,  $\tilde{C}$ 表示对正常数据集建立主元分析模型时残差子空间的投影矩阵, N表示故障样本的个数,  $x(k)$ 表示第k个时刻的故障数据。

6. 如权利要求5所述的方法, 其特征在于, 所述指定范数包括Frobenius范数。

7. 如权利要求1所述的方法, 其特征在于, 根据所述加性故障的方向矩阵和增益衰减矩阵计算故障重构数据步骤进一步包括:

当所述加性故障的方向矩阵为零矩阵时,

根据下列公式计算所述故障重构数据:

$$x_i^*(k) = E_i^{-1}x(k)$$

当所述加性故障的方向矩阵不为零矩阵时,

基于加性故障的方向矩阵以及增益衰减矩阵, 采用平方预测误差最小计算加性故障的大小;

根据下列公式计算所述故障重构数据:

$$x_i^*(k) = E_i^{-1}[x(k) - \Xi_i f_i(k)]$$

其中,  $x_i^*(k)$ 表示第k个时刻的故障重构数据,  $x(k)$ 表示第k个时刻的故障数据,  $E_i$ 表示增益衰减矩阵,  $\Xi_i$ 表示加性故障的方向矩阵,  $f_i(k)$ 表示第k个时刻加性故障的大小。

8. 如权利要求7所述的方法, 其特征在于, 根据下列公式采用平方预测误差最小计算加性故障的大小:

$$f_i(k) = (\tilde{C}E_i^{-1}\Xi_i)^+ (\tilde{C}E_i^{-1}x(k))$$

$x(k)$ 表示第k个时刻的故障数据,  $\tilde{C}$ 表示对正常数据集建立主元分析模型时残差子空间的投影矩阵,  $E_i$ 表示增益衰减矩阵,  $\Xi_i$ 表示加性故障的方向矩阵,  $f_i(k)$ 表示第k个时刻加性故障的大小。

9. 如权利要求7所述的方法, 其特征在于, 根据下列公式采用平方预测误差最小计算加性故障的大小:

$$f_i(k) = (\tilde{C}\Xi_i)^+ (\tilde{C}x(k))$$

$x(k)$ 表示第k个时刻的故障数据,  $\tilde{C}$ 表示对正常数据集建立主元分析模型时残差子空间的投影矩阵,  $\Xi_i$ 表示加性故障的方向矩阵,  $f_i(k)$ 表示第k个时刻加性故障的大小。

## 一种基于协方差矩阵范数逼近的多重故障重构方法

### 技术领域

[0001] 本发明涉及故障检测与重构技术领域,具体地说,涉及一种基于协方差矩阵范数逼近的多重故障重构方法。

### 背景技术

[0002] 在自动控制领域中,传感器是信息获取的主要装置。当传感器出现性能蜕化、故障或失效时,将给后续的监测、控制、故障诊断等系统带来严重影响,产生误诊断、误报警等。

[0003] 为了避免传感器故障或失效带来的严重后果,需要对传感器的故障与失效进行甄别。最基本的甄别方法是人工定期校准的方法,这也就是目前普遍采用的“预防性”维护方法,即定期大修。该方法不但浪费人力、物力,而且不可避免的会造成维护不足或维护过剩问题。因此,传感器故障诊断技术应运而生。

[0004] 目前传感器故障诊断方法普遍采用故障重构方法,数据驱动的故障重构的目的是为了估计假若没有发生故障时真实的传感器的输出值。

[0005] 现有的故障重构方法采用的故障模型为 $x = x^* + \Xi_i f$ ,其中 $x$ 表示故障数据, $x^*$ 表示故障重构数据, $\Xi_i$ 表示加性故障的方向矩阵, $f$ 表示加性故障的大小。现有的故障重构方法利用滑动平均方法和奇异值分解方法获取加性故障的方向矩阵 $\Xi_i$ ,利用重构后的平方预期误差(Squared Prediction Error,简称为SPE)或综合指标 $\phi$ 最小作为优化目标来对故障大小 $f$ 进行估计,从而获得传感器的故障重构数据。

[0006] 现有的故障重构方法仅考虑了加性故障的情形,没有明确地考虑乘性故障以及加性故障和乘性故障多重故障的情形,因此导致对故障描述不够全面和准确。

[0007] 基于上述情况,亟需一种同时考虑加性故障和乘性故障的故障重构方法,以全面、准确的描述传感器故障。

### 发明内容

[0008] 为解决上述问题,本发明提供了一种基于协方差矩阵范数逼近的多重故障重构方法,所述方法包括:

[0009] 收集正常数据集和故障数据集;

[0010] 基于正常数据集和故障数据集采用奇异值分解计算加性故障的方向矩阵;

[0011] 基于正常数据集和故障数据集采用协方差矩阵范数逼近计算增益衰减矩阵;

[0012] 根据所述加性故障的方向矩阵和增益衰减矩阵计算故障重构数据,以用于设备故障的检测分析。

[0013] 根据本发明的一个实施例,计算所述加性故障的方向矩阵的步骤进一步包括:

[0014] 采用预设窗口长度的滑动窗口分别对所述正常数据集和故障数据集进行滑动平均,构建相应的正常数据平均值矩阵和故障数据平均值矩阵;

[0015] 确定所述正常数据平均值矩阵各元素的绝对值中的最大值;

[0016] 将所述故障数据平均值矩阵中各元素的绝对值与所述正常数据平均值矩阵各元

素的绝对值中的最大值进行比较,并根据比较结果对故障数据平均值矩阵中相应的元素进行重置,获得扰动去除数据矩阵;

[0017] 对所述扰动去除数据矩阵进行奇异值分解,得到加性故障的方向矩阵。

[0018] 根据本发明的一个实施例,根据比较结果对故障数据平均值矩阵中相应的元素进行重置的步骤进一步包括:

$$[0019] \quad D^T = [d_{ij}], \text{ 其中 } d_{ij} = \begin{cases} 0 & |z_{ij}| \leq \delta^* \\ z_{ij} & |z_{ij}| > \delta^* \end{cases}$$

[0020] 其中, $D^T$ 表示扰动去除数据矩阵, $d_{ij}$ 表示矩阵 $D^T$ 中第*i*行第*j*列的元素, $z_{ij}$ 表示故障数据平均值矩阵中第*i*行第*j*列的元素, $\delta^*$ 表示正常数据平均值矩阵各元素的绝对值中的最大值。

[0021] 根据本发明的一个实施例,对所述扰动去除数据矩阵进行奇异值分解,得到加性故障的方向矩阵的步骤进一步包括:

[0022] 采用 $D^T = U \Omega V^T$ 对扰动去除数据矩阵 $D^T$ 进行奇异值分解,得到酉矩阵 $U$ ,作为加性故障的方向矩阵。

[0023] 根据本发明的一个实施例,所述计算增益衰减矩阵步骤进一步包括:

[0024] 基于正常数据集计算正常数据集的协方差矩阵的估计;

[0025] 基于加性故障的方向矩阵,根据故障数据集和增益衰减矩阵构建基于故障数据集的协方差矩阵;

[0026] 在指定范数意义下使基于故障数据集的协方差矩阵逼近正常数据集的协方差矩阵的估计,以求解基于故障数据集的协方差矩阵中的增益衰减矩阵。

[0027] 根据本发明的一个实施例,构建基于故障数据集的协方差矩阵步骤进一步包括:

$$[0028] \quad S = J(E_i) \Sigma J(E_i)^T$$

[0029] 其中,

$$[0030] \quad J(E_i) = E_i^{-1} [I - \Xi_i (\tilde{C} E_i^{-1} \Xi_i)^+ \tilde{C} E_i^{-1}]$$

$$[0031] \quad \Sigma = \frac{1}{N-1} \sum_{k=1}^N x(k) x^T(k)$$

[0032]  $S$ 表示基于故障数据集的协方差矩阵, $E_i^{-1}$ 表示增益衰减矩阵 $E_i$ 的逆矩阵, $\Xi_i$ 表示加性故障的方向矩阵, $\tilde{C}$ 表示对正常数据集建立主元分析模型时残差子空间的投影矩阵, $N$ 表示故障样本的个数, $x^T(k)$ 表示第*k*个时刻的故障数据 $x(k)$ 的转置, $(\tilde{C} E_i^{-1} \Xi_i)^+$ 表示矩阵 $\tilde{C} E_i^{-1} \Xi_i$ 的广义逆矩阵。

[0033] 根据本发明的一个实施例,所述指定范数包括弗罗贝尼乌斯范数。

[0034] 根据本发明的一个实施例,根据所述加性故障的方向矩阵和增益衰减矩阵计算故障重构数据步骤进一步包括:

[0035] 当所述加性故障的方向矩阵为零矩阵时,

[0036] 根据下列公式计算所述故障重构数据:

$$[0037] \quad x_i^*(k) = E_i^{-1} x(k)$$

[0038] 当所述加性故障的方向矩阵不为零矩阵时，

[0039] 基于加性故障的方向矩阵以及增益衰减矩阵，采用平方预测误差最小计算加性故障的大小；

[0040] 根据下列公式计算所述故障重构数据：

$$[0041] \quad x_i^*(k) = E_i^{-1}[x(k) - \Xi_i f_i(k)]$$

[0042] 其中， $x_i^*(k)$ 表示第k个时刻的故障重构数据， $x(k)$ 表示第k个时刻的故障数据， $E_i^{-1}$ 表示增益衰减矩阵 $E_i$ 的逆矩阵， $\Xi_i$ 表示加性故障的方向矩阵， $f_i(k)$ 表示第k个时刻加性故障的大小。

[0043] 根据本发明的一个实施例，根据下列公式采用平方预测误差最小计算加性故障的大小：

$$[0044] \quad f_i(k) = (\tilde{C}E_i^{-1}\Xi_i)^+ (\tilde{C}E_i^{-1}x(k))$$

[0045]  $x(k)$ 表示第k个时刻的故障数据， $\tilde{C}$ 表示对正常数据集建立主元分析模型时残差子空间的投影矩阵， $E_i^{-1}$ 表示增益衰减矩阵 $E_i$ 的逆矩阵， $\Xi_i$ 表示加性故障的方向矩阵， $f_i(k)$ 表示第k个时刻加性故障的大小， $(\tilde{C}E_i^{-1}\Xi_i)^+$ 表示矩阵 $\tilde{C}E_i^{-1}\Xi_i$ 的广义逆矩阵。

[0046] 根据本发明的一个实施例，根据下列公式采用平方预测误差最小计算加性故障的大小：

$$[0047] \quad f_i(k) = (\tilde{C}\Xi_i)^+ (\tilde{C}x(k))$$

[0048]  $x(k)$ 表示第k个时刻的故障数据， $\tilde{C}$ 表示对正常数据集建立主元分析模型时残差子空间的投影矩阵， $\Xi_i$ 表示加性故障的方向矩阵， $f_i(k)$ 表示第k个时刻加性故障的大小， $(\tilde{C}\Xi_i)^+$ 表示矩阵 $\tilde{C}\Xi_i$ 的广义逆矩阵。

[0049] 本发明提供了一种基于协方差矩阵范数逼近的多重故障重构方法，其同时考虑加性故障和乘性故障的影响，提出了故障模型 $x = Ex^* + \Xi_i f$ ，其中 $E$ 表示增益衰减矩阵。该故障模型相比目前广泛使用的故障模型 $x = x^* + \Xi_i f$ ，对故障的描述更加全面、准确，能够保证较小的故障重构误差。本发明提供的故障重构方法考虑了乘性故障，由于乘性故障会导致数据的协方差矩阵的相应变化，因此通过重构后的协方差矩阵与正常数据的协方差矩阵范数逼近的思想，还可以获得增益衰减的信息。

[0050] 此外，现有加性故障提取方法因没有考虑滑动平均后故障重构数据的平均值微小扰动不是零，容易引起奇异值分解得到的加性故障的方向不准确的问题。本发明针对该问题，利用提取的正常数据平均值矩阵中各元素的绝对值的最大值来滤除上述干扰，提高了提取的加性故障方向的准确性。

[0051] 本发明的其它特征和优点将在随后的说明书中阐述，并且，部分地从说明书中变得显而易见，或者通过实施本发明而了解。本发明的目的和其他优点可通过在说明书、权利要求书以及附图中所特别指出的结构来实现和获得。

## 附图说明

[0052] 为了更清楚地说明本发明实施例或现有技术中的技术方案，下面将对实施例或现

有技术描述中所需要的附图做简单的介绍：

[0053] 图1是根据本发明一个实施例的故障重构方法的流程图；

[0054] 图2是根据本发明一个实施例的计算加性故障的方向矩阵的流程图；

[0055] 图3是根据本发明一个实施例的计算增益衰减矩阵的流程图；

[0056] 图4是根据本发明一个实施例的利用多重故障重构方法和现有故障重构方法对已知的乘性故障进行重构的重构误差对比图；

[0057] 图5是根据本发明一个实施例的利用多重故障重构方法和现有故障重构方法对已知的加性故障进行重构的重构误差对比图；

[0058] 图6是根据本发明一个实施例的利用多重故障重构方法和现有故障重构方法对已知的多重故障进行重构的重构误差对比图。

### 具体实施方式

[0059] 以下将结合附图及实施例来详细说明本发明的实施方式,借此对本发明如何应用技术手段来解决技术问题,并达成技术效果的实现过程能充分理解并据以实施。需要说明的是,只要不构成冲突,本发明中的各个实施例以及各实施例中的各个特征可以相互结合,所形成的技术方案均在本发明的保护范围之内。

[0060] 针对现有故障重构方法仅考虑加性故障而造成对故障描述不够全面和准确的问题,本实施例中采用同时考虑加性故障和乘性故障的方法进行故障重构,并构建出相应的多重故障模型,以提高故障描述的全面性和准确性。图1示出了本实施例中故障重构方法的流程图。

[0061] 本实施例中,以传感器为对象进行分析,通过本发明提供的故障重构方法得到传感器的故障重构数据。

[0062] 如图1所示,首先在步骤S101中收集正常数据集和故障数据集。本实施例中,正常数据集为传感器没有发生故障时输出的数据,故障数据为传感器工作性能降低或彻底失效时输出的数据。

[0063] 随后在步骤S102中,基于步骤S101中收集到的正常数据集和故障数据集,采用奇异值分解计算加性故障的方向矩阵。

[0064] 现有加性故障的方向提取方法中没有考虑滑动平均后得到的数据的微小扰动不是零的情况,容易造成的奇异值分解后加性故障的方向不准确。本发明针对现有加性故障的方向提取方法的缺陷,在对故障数据进行滑动平均时,还采集正常数据并进行同样的滑动平均,根据二者滑动平均后的数据来去除故障数据滑动平均后的微小扰动,从而得到更为准确的加性故障方向,其具体实现过程如图2所示。

[0065] 如图2所示,本实施例中,首先在步骤S201中采用预设窗口长度的滑动窗口对正常数据集进行滑动平均,利用滑动平均后的数据构建正常数据平均值矩阵。

[0066] 为了消除微小扰动的影响,本实施例中,在步骤S202中确定正常数据平均值矩阵各元素的绝对值中的最大值 $\delta^*$ 。需要说明的是,在根据本发明的其它实施例中,为了消除微小扰动的影响,还可以取其他合理值,本发明不限于此。

[0067] 随后在步骤S203中,采用与步骤S201中相同的滑动窗口对故障数据集进行滑动平均,利用滑动平均后的数据构建故障数据平均值矩阵 $Z^T$ 。其中,故障数据平均值矩阵 $Z^T$ 中的

第*i*行第*j*列上的元素用 $z_{ij}$ 表示。

[0068] 在步骤S204中,将步骤S203中构建得到的故障数据平均值矩阵 $Z^T$ 中的各元素的绝对值与正常数据平均值矩阵各元素的绝对值中的最大值 $\delta^*$ 进行比较,并在步骤S205中根据步骤S204中的比较结果对故障数据平均值矩阵 $Z^T$ 中的相应元素进行重置,获得扰动去除数据矩阵 $D^T$ 。

[0069] 本实施例中,根据下列公式对故障数据平均值矩阵 $Z^T$ 中的相应元素进行重置:

$$[0070] \quad D^T = [d_{ij}], \text{ 其中 } d_{ij} = \begin{cases} 0 & |z_{ij}| \leq \delta^* \\ z_{ij} & |z_{ij}| > \delta^* \end{cases} \quad (1)$$

[0071] 其中, $z_{ij}$ 表示故障数据平均值矩阵 $Z^T$ 中的第*i*行第*j*列上的元素, $d_{ij}$ 表示扰动去除数据矩阵 $D^T$ 中的第*i*行第*j*列上的元素, $\delta^*$ 表示正常数据平均值矩阵各元素的绝对值中的最大值。

[0072] 需要说明的是,本实施例中阐述的利用正常数据平均值矩阵各元素的绝对值中的最大值来去除微小扰动并不是用于对本发明所提供的故障重构方法的限定,在根据本发明的其它实施例中,还可以采用其他合理值来去除扰动。

[0073] 本实施例中,采用奇异值分解的方法计算加性故障的方向矩阵。如图2所示,在步骤S206中,对步骤S205中获得的扰动去除数据矩阵 $D^T$ 利用公式 $D^T = U \Omega V^T$ 进行奇异值分解,并将分解得到的酉矩阵 $U$ 作为加性故障的方向矩阵 $E_i$ 。

[0074] 再次如图1所示,得到加性故障的方向矩阵 $E_i$ 后,在步骤S103中基于正常数据集和故障数据集采用协方差矩阵范数逼近计算增益衰减矩阵。

[0075] 图3示出了基于正常数据集和故障数据集根据协方差矩阵范数逼近计算增益衰减矩阵的流程图。

[0076] 如图3所示,本实施中,首先在步骤S301中基于正常数据集计算正常数据集的协方差矩阵的估计 $\Sigma_*$ 。

[0077] 随后在步骤S302中,基于加性故障的方向矩阵 $E_i$ ,根据故障数据集和增益衰减矩阵 $E_i$ 构建基于故障数据集的协方差矩阵 $S$ 。

[0078] 本实施例中,当加性故障的方向矩阵 $E_i$ 为零时,故障样本 $x(k)$ 可以用下列公式表示:

$$[0079] \quad x(k) = E_i x^*(k) \quad (2)$$

[0080] 其中, $x(k)$ 表示第*k*个时刻的故障数据, $x^*(k)$ 表示第*k*个时刻的故障重构数据。

[0081] 基于故障数据集的协方差矩阵 $S$ 则可以表示为:

$$[0082] \quad \begin{aligned} S &= \frac{1}{N-1} \sum_{k=1}^N x^*(k) x^{*T}(k) = \frac{1}{N-1} \sum_{k=1}^N (E_i^{-1} x(k)) (E_i^{-1} x(k))^T \\ &= E_i^{-1} \left[ \frac{1}{N-1} \sum_{k=1}^N x(k) x^T(k) \right] E_i^{-1} \\ &= E_i^{-1} \Sigma E_i^{-1} \end{aligned} \quad (3)$$

$$[0083] \quad \Sigma = \frac{1}{N-1} \sum_{i=1}^N x(i) x^T(i) \quad (4)$$

[0084] 公式(3)和公式(4)中,N表示故障样本的个数, $E_i^{-1}$ 表示增益衰减矩阵 $E_i$ 的逆矩阵, $x^T(k)$ 表示第k个时刻的故障数据 $x(k)$ 的转置。

[0085] 本实施例中,当加性故障的方向矩阵 $\Xi_i$ 不为零时,故障样本 $x(k)$ 可以用下列公式表示:

$$[0086] \quad x(k) = E_i x^*(k) + \Xi_i f_i(k) \quad (5)$$

[0087] 其中, $f_i(k)$ 表示第k个时刻加性故障的大小,本实施例中,根据下列公式采用平方预测误差(Squared Prediction Error,简称为SPE)最小来计算加性故障的大小:

$$[0088] \quad f_i(k) = \arg \min SPE(x(k)) = (\tilde{C}E_i^{-1}\Xi_i)^+ (\tilde{C}E_i^{-1}x(k)) \quad (6)$$

[0089] 其中, $x(k)$ 表示第k个时刻的故障数据, $\tilde{C}$ 表示对正常数据集建立主元分析(Principal Component Analysis,简称为PCA)模型时残差子空间的投影矩阵, $E_i^{-1}$ 表示增益衰减矩阵 $E_i$ 的逆矩阵, $\Xi_i$ 表示加性故障的方向矩阵, $f_i(k)$ 表示第k个时刻加性故障的大小, $(\tilde{C}E_i^{-1}\Xi_i)^+$ 表示矩阵 $\tilde{C}E_i^{-1}\Xi_i$ 的广义逆矩阵。

[0090] 需要说明的是,在根据本发明的其它实施例中,第k个时刻加性故障的大小 $f_i(k)$ 还可以采用其他合理方法计算得到,例如加性故障的大小 $f_i(k)$ 还可以根据下列公式基于SPE最小计算得到:

$$[0091] \quad f_i(k) = (\tilde{C}\Xi_i)^+ (\tilde{C}x(k)) \quad (7)$$

[0092] 其中, $x(k)$ 表示第k个时刻的故障数据, $\tilde{C}$ 表示对正常数据集建立PCA模型时残差子空间的投影矩阵, $\Xi_i$ 表示加性故障的方向矩阵, $f_i(k)$ 表示第k个时刻加性故障的大小, $(\tilde{C}\Xi_i)^+$ 表示矩阵 $\tilde{C}\Xi_i$ 的广义逆矩阵。

[0093] 本实施例中,根据公式(5)和公式(6)可以将故障重构数据 $x^*(k)$ 表示为:

$$[0094] \quad x^*(k) = E_i^{-1}[x(k) - \Xi_i f_i(k)] = E_i^{-1}[I - \Xi_i (\tilde{C}E_i^{-1}\Xi_i)^+ \tilde{C}E_i^{-1}]x(k) \quad (8)$$

[0095] 此时,基于故障数据集的协方差矩阵S则可以表示为:

$$[0096] \quad S = \frac{1}{N-1} \sum_{k=1}^N x^*(k)x^{*T}(k) = J(E_i)\Sigma J(E_i)^T \quad (9)$$

$$[0097] \quad \text{其中, } J(E_i) = E_i^{-1}[I - \Xi_i (\tilde{C}E_i^{-1}\Xi_i)^+ \tilde{C}E_i^{-1}] \quad (10)$$

[0098] 如图3所示,在指定范数意义下,在步骤S303中使基于故障数据集的协方差矩阵S逼近正常数据集的协方差矩阵的估计 $\Sigma_*$ ,求解基于故障数据集的协方差矩阵S中的增益衰减矩阵 $E_i$ 。本实施例中,使基于故障数据集的协方差矩阵S在弗罗贝尼乌斯范数(Frobenius范数,简称为F范数)意义下逼近正常数据集的协方差矩阵的估计 $\Sigma_*$ ,但本发明不限于此。

[0099] 当加性故障的方向矩阵 $\Xi_i$ 为零时,基于故障数据集的协方差矩阵S在Frobenius范数意义下逼近正常数据集的协方差矩阵的估计 $\Sigma_*$ 可以用求解下列优化问题来表示:

$$[0100] \quad \min tr[(E_i^{-1}\Sigma E_i^{-1} - \Sigma_*)^T (E_i^{-1}\Sigma E_i^{-1} - \Sigma_*)] \quad (11)$$

[0101] 当加性故障的方向矩阵 $\Xi_i$ 不为零时,基于故障数据集的协方差矩阵S在Frobenius范数意义下逼近正常数据集的协方差矩阵的估计 $\Sigma_*$ 可以用求解下列优化问题来表示:

$$[0102] \quad \min tr[(J(E_i)\Sigma J(E_i)^T - \Sigma_*)^T (J(E_i)\Sigma J(E_i)^T - \Sigma_*)] \quad (12)$$

[0103] 根据公式(11)和公式(12)可以分别求得当加性故障的方向矩阵为零和不为零时的增益衰减矩阵 $E_i$ 。

[0104] 再次如图1所示,在步骤S104中根据加性故障的方向矩阵和增益衰减矩阵计算故障重归数据,并输出故障重构数据的结果,以用于设备故障的检测分析。

[0105] 本实施例中,当加性故障的方向矩阵 $\Xi_i$ 为零时,根据下列公式计算故障重构数据:

$$[0106] \quad x^*(k) = E_i^{-1}x(k) \quad (13)$$

[0107] 当加性故障的方向矩阵 $\Xi_i$ 不为零时,根据下列公式计算故障重构数据:

$$[0108] \quad x^*(k) = E_i^{-1}[x(k) - \Xi_i f_i(k)] \quad (14)$$

[0109] 当得到故障重构数据的计算方法后,本实施例中,采用数值算例 $x = Gt + e$ 对本发明提供的故障重构方法进行验证。数值算例 $x = Gt + e$ 中, $x \in \mathbb{R}^5$ 表示传感器的测量值; $t \in \mathbb{R}^2$ 表示两个独立的数据源,其均值为0,方差为1; $e \in \mathbb{R}^5$ 表示相互独立的标准差为0.1的高斯白噪声。本实施例中,矩阵G的取值为:

$$[0110] \quad G = \begin{bmatrix} -0.1670 & -0.1352 \\ -0.5671 & -0.3695 \\ -0.1608 & -0.1019 \\ 0.7574 & -0.0563 \\ -0.2258 & -0.9119 \end{bmatrix}$$

[0111] 现有故障重构方法只考虑了加性故障,本实施例中,分别采用本发明提供的考虑多性故障的故障重构方法和现有故障重构方法对已知的不同类型的故障进行故障重构,根据重构误差比较两种方法的效果,进而阐明本发明的优点。本实施例中,重构误差表示为采用不同故障模型计算得到的故障重构数据 $x^*$ 与已知的故障重构数据 $x_0^*$ 的之差的欧氏范数,但本发明不限于此。

[0112] 本实施例中,已知的故障数据均由五个传感器采集的数据构成,但本发明不限于此。

[0113] 已知一传感器故障,该故障中第2个传感器的输出数据发生衰减而其它传感器正常,其中第二个传感器的衰减系数为0.2,分别采用本发明提供的考虑多性故障的故障重构方法和现有故障重构方法对该传感器故障进行故障重构。图4示出了两种故障重构方法的对比图,从图中可以明显看出,本发明提供的故障重构方法产生的重构误差明显小于现有的故障重构方法产生的重构误差。

[0114] 现已知一传感器故障,该故障中第5个传感器发生了大小为8的偏差,分别采用本发明提供的考虑多性故障的故障重构方法和现有故障重构方法对该传感器故障进行故障重构。图5示出了两种故障重构方法的重构误差对比图,从图中可以看出,因为该传感器故障只包含了加性故障,本发明提供的故障重构方法产生的重构误差与采用现有的故障重构方法产生的故障误差大小相近。

[0115] 现已知一传感器故障,该故障中第2个传感器的输出数据发生了衰减,其衰减系数为0.6,第4个传感器发生了大小为6的偏差,其他传感器正常,分别采用本发明提供的故障重构方法和现有故障重构方法对该传感器故障进行故障重构。图6示出了两种故障重构方

法的对比图,从图中也可以明显看出,现有故障重构方法并没有考虑乘性故障的影响,而本来明提供的故障重构方法考虑了乘性故障在内的多重故障,本发明提供的故障重构方法产生的故障误差明显小于采用现有的只考虑加性故障的故障重构方法产生的故障误差。

[0116] 由上可知,本发明提供的故障重构方法同时考虑加性故障和乘性故障,采用故障模型 $x = Ex^* + \Xi_i f$ 计算故障重构数据。相比广泛应用的传统的故障重构方法中使用的故障模型 $x = x^* + \Xi_i f$ ,本发明提供的故障重构方法对故障的描述更为全面和准确,能够有效减小故障重构误差。此外,由于乘性故障会导致数据的协方差矩阵的相应变化,因此通过重构后的协方差矩阵与正常数据的协方差矩阵范数逼近,还可以获得增益衰减信息。

[0117] 虽然本发明所揭露的实施方式如上,但所述的内容只是为了便于理解本发明而采用的实施方式,并非用以限定本发明。任何本发明所属技术领域的技术人员,在不脱离本发明所揭露的精神和范围的前提下,可以在实施的形式上及细节上作任何的修改与变化,但本发明的专利保护范围,仍须以所附的权利要求书所界定的范围为准。

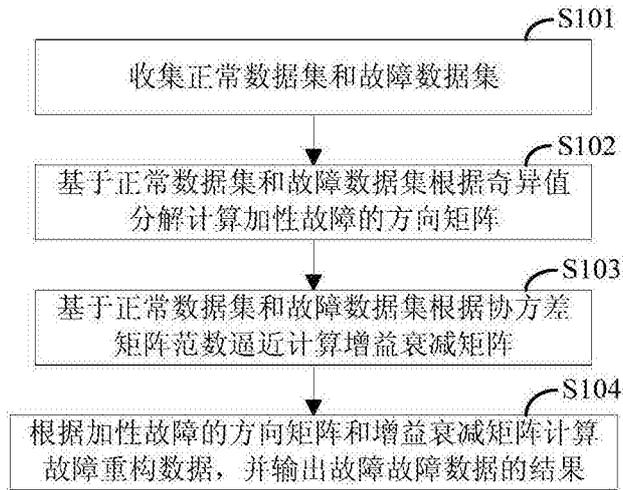


图1

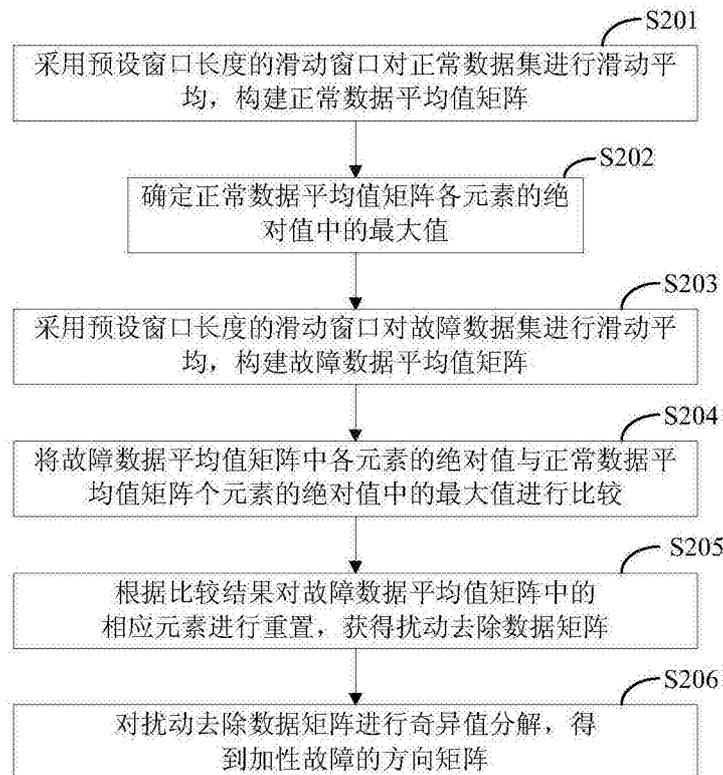


图2

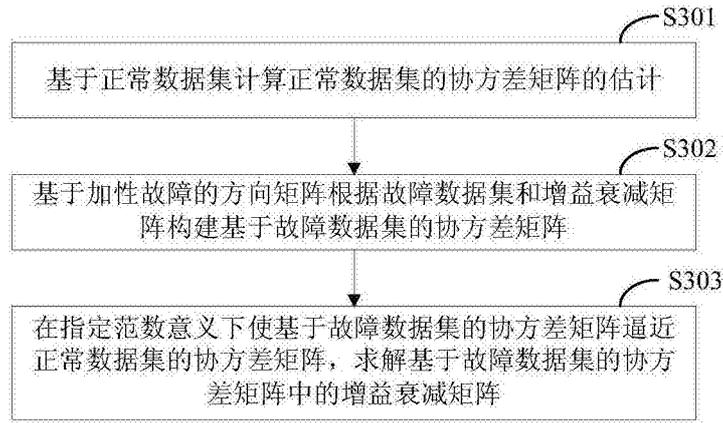


图3

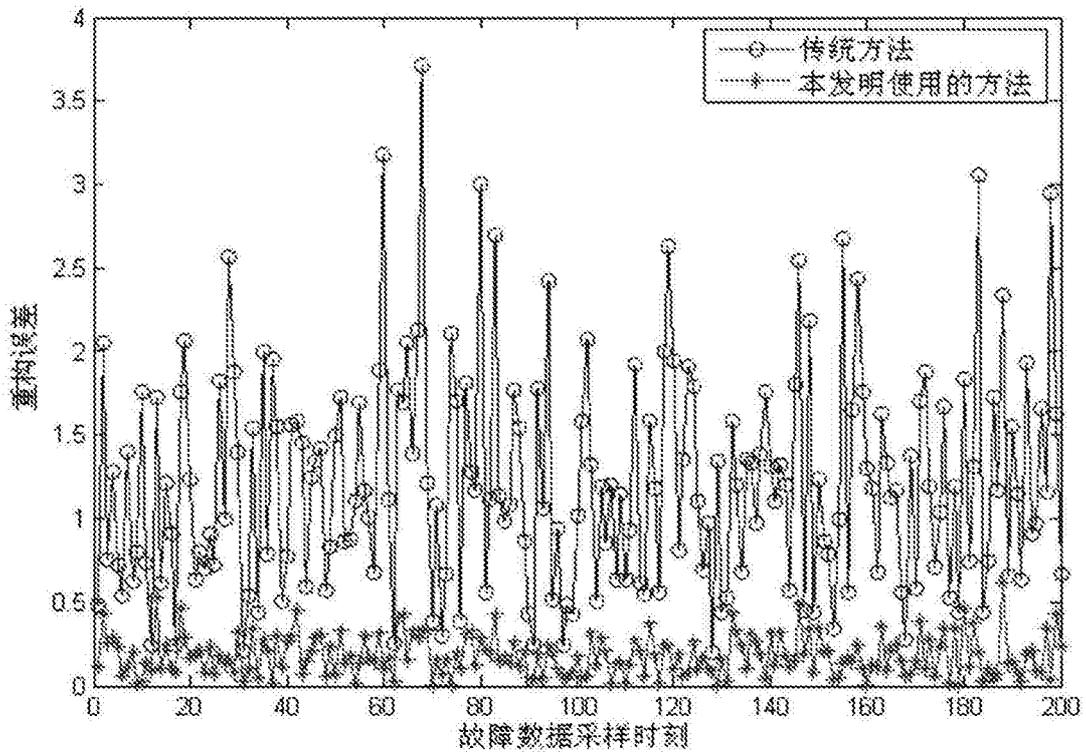


图4

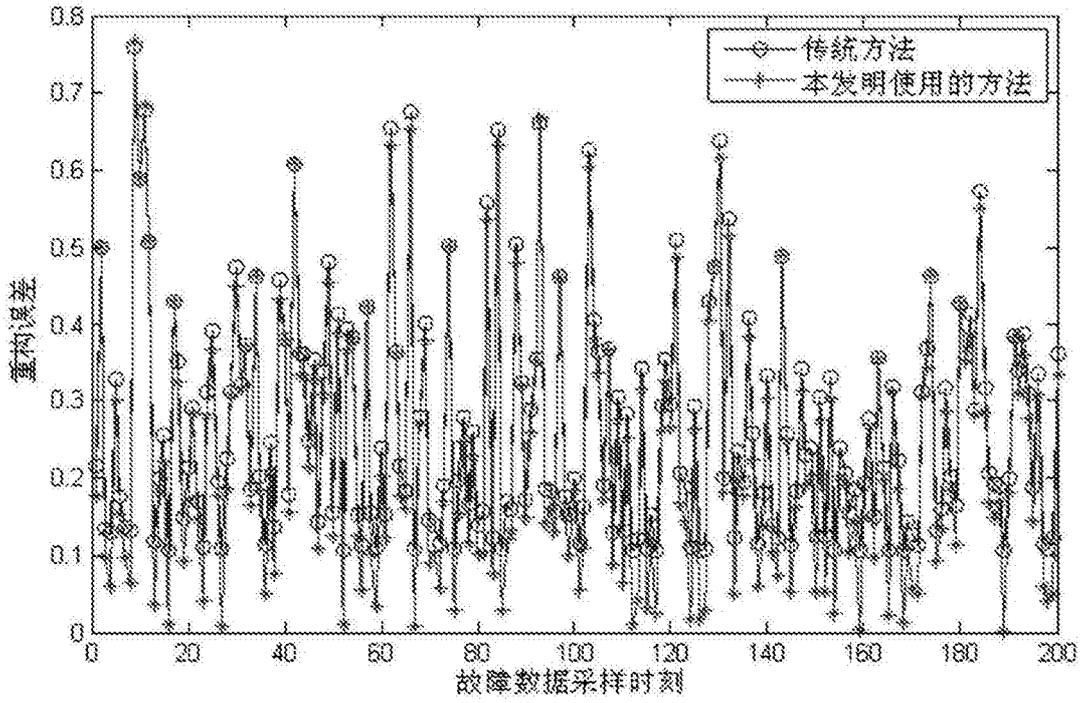


图5

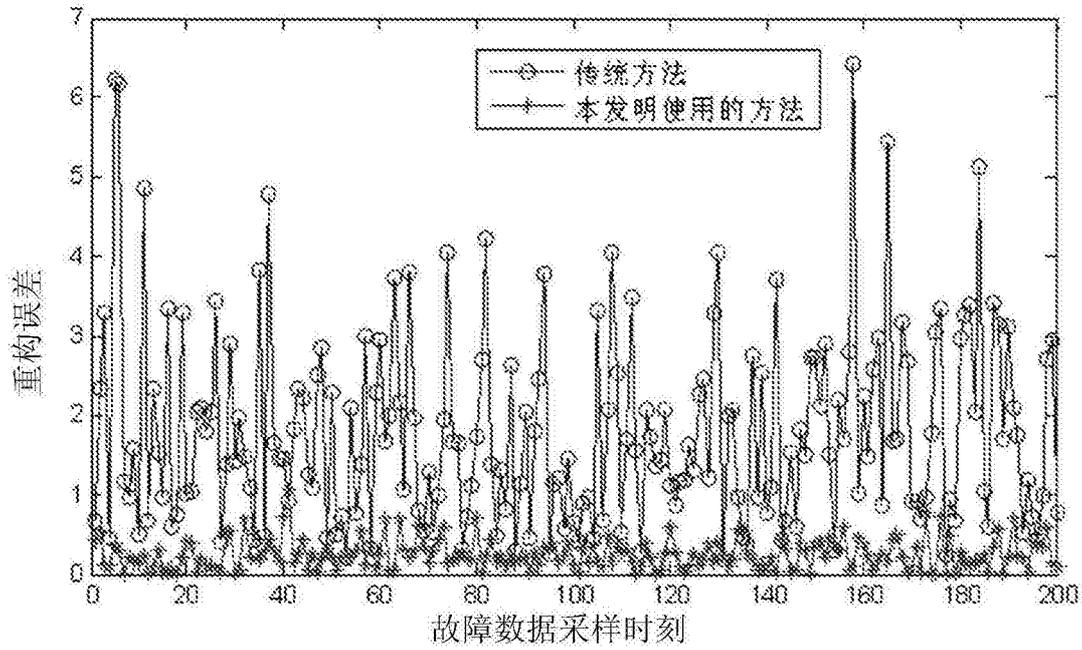


图6