



(12) 发明专利

(10) 授权公告号 CN 114112390 B

(45) 授权公告日 2024.03.22

(21) 申请号 202111396695.6

CN 110987436 A, 2020.04.10

(22) 申请日 2021.11.23

CN 111475774 A, 2020.07.31

(65) 同一申请的已公布的文献号

CN 112529025 A, 2021.03.19

申请公布号 CN 114112390 A

CN 113051092 A, 2021.06.29

(43) 申请公布日 2022.03.01

US 2014067327 A1, 2014.03.06

(73) 专利权人 哈尔滨工程大学

US 2015095003 A1, 2015.04.02

地址 150001 黑龙江省哈尔滨市南岗区南通大街145号哈尔滨工程大学科技处知识产权办公室

WO 2021128510 A1, 2021.07.01

张妍. 基于数据的轨道车辆门系统的健康评估与预测. CNKI 硕士电子期刊. 2020, 全文.

(72) 发明人 张晓侠 胡旭晟 邢晓冬

毕小龙; 王洪跃; 司风琪; 徐治皋. 基于核主元分析的传感器故障检测. 动力工程. 2007, (04), 全文.

(51) Int. Cl.

审查员 喻婷

G01M 13/04 (2019.01)

(56) 对比文件

KR 101811962 B1, 2017.12.22

CN 110738274 A, 2020.01.31

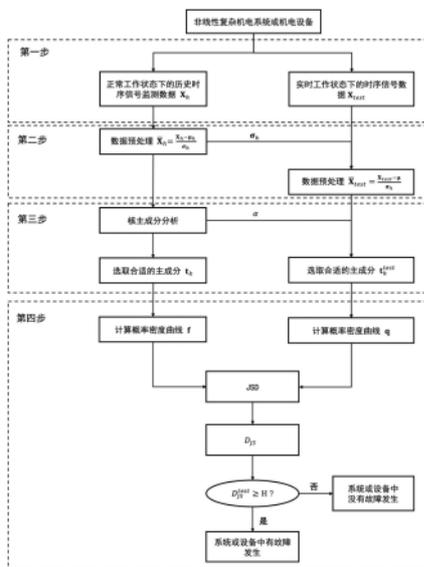
权利要求书2页 说明书6页 附图3页

(54) 发明名称

一种非线性复杂系统早期故障诊断方法

(57) 摘要

本发明提供一种非线性复杂系统早期故障诊断方法,包括:采集非线性复杂机电系统或机电设备在正常工作状态下的历史时序信号数据和实时工况下的实时时序监测数据;对获得的历史检测数据和实时数据进行数据预处理,获得预处理后的机电系统或机电设备的健康状态相关数据集 \bar{X}_h 以及系统或设备实时工况下的状态相关数据集 \bar{X}_{test} ;使用核主成分分析将预处理后的数据集投影到高纬度线性空间上,得到转换到新的映射空间上的数据集,通过选取合适的主成分提取故障特征;利用Jensen-Shannon散度对投影后的实时数据的概率密度分布与投影后的健康状况下的历史监测数据的概率密度分布的差异性进行计算,并与预先设定的故障阈值进行对比,完成故障诊断。



1. 一种非线性复杂系统早期故障诊断方法,其特征在于,步骤如下:

步骤1:采集非线性复杂机电系统或机电设备在正常工作状态下的历史时序信号数据和实时工况下的实时时序监测数据;

步骤2:对步骤1获得的历史检测数据和实时数据进行数据预处理,获得预处理后的机电系统或机电设备的健康状态相关数据集 $\bar{\mathbf{X}}_h$ 以及机电系统或机电设备实时工况下的状态相关数据集 $\bar{\mathbf{X}}_{test}$;

步骤21:对步骤1获得的历史监测数据进行去中心化和标准化处理,去中心化即将数据集中的每个变量对应的观测值减去该变量的样本平均值 μ_h ;标准化即将数据集中的去中心化后的每个变量对应的观测值再除以该变量的样本的标准差 σ_h ;

步骤22:对步骤1获得的实时监测数据进行去中心化和标准化处理,将数据集中每个变量对应的观测值监测该变量的样本平均值 μ ,再除以该变量对应的正常工况下采集的历史监测数据样本的标准差 σ_h ;

步骤3:使用核主成分分析将步骤2预处理后的数据集投影到高纬度线性空间上,得到转换到新的映射空间上的数据集,通过选取合适的主成分提取故障特征;

步骤31:将步骤2中获得的预处理后的历史监测数据集使用核主成分分析投影到一个新的高纬度线性空间内,在该步骤当中通过公式

$$\rho\alpha = \frac{1}{n}\bar{\mathbf{K}}\alpha$$

式中 $\bar{\mathbf{K}} = \mathbf{K} - \mathbf{1}_n\mathbf{K} - \mathbf{K}\mathbf{1}_n + \mathbf{1}_n\mathbf{K}\mathbf{1}_n$, n 为所选择的数据样本长度,式中 $\mathbf{1}_n$ 为:

$$\mathbf{1}_n = \frac{1}{n} \begin{bmatrix} 1 & \cdots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \cdots & 1 \end{bmatrix}$$

\mathbf{K} 按照如下公式计算

$$\mathbf{K} = \begin{bmatrix} \mathcal{K}(\bar{\mathbf{x}}_h^1, \bar{\mathbf{x}}_h^1) & \cdots & \mathcal{K}(\bar{\mathbf{x}}_h^1, \bar{\mathbf{x}}_h^n) \\ \vdots & \ddots & \vdots \\ \mathcal{K}(\bar{\mathbf{x}}_h^n, \bar{\mathbf{x}}_h^1) & \cdots & \mathcal{K}(\bar{\mathbf{x}}_h^n, \bar{\mathbf{x}}_h^n) \end{bmatrix}$$

其中: \mathcal{K} 为已知选定的核函数,得到特征值 ρ 和特征向量矩阵 α ;基于获得的特征值选取主成分的个数,根据得到的特征向量矩阵,计算转换到新的空间内的数据集;

步骤32:基于步骤31中获得的特征向量矩阵,将步骤22中获得的预处理后的实时检测数据投影到同一个维度空间,并获得转换后的新的数据集;

步骤4:利用Jensen-Shannon散度对投影后的实时数据的概率密度分布与投影后的健康状况下的历史监测数据的概率密度分布的差异性进行计算,并与预先设定的故障阈值进行对比,完成故障诊断。

2. 根据权利要求1所述的一种非线性复杂系统早期故障诊断方法,其特征在于,步骤1具体包括:

步骤11:采集非线性复杂机电系统或机电设备在正常工作状态下的时序信号数据,即获得系统健康状态下的历史监测数据 X_h ;

步骤12:采集非线性复杂机电系统或机电设备在实时工况下的实时时序信号数据 X_{test} ,

采集的数据长度与历史监测数据的长度保持一致。

3. 根据权利要求1或2所述的一种非线性复杂系统早期故障诊断方法,其特征在於,步骤4具体为:

步骤41:对步骤3中获得的转换后的历史监测数据集和实时监测数据集进行主成分的选择,基于转换后的历史监测数据集选择出的主成分标记为 t_k ,基于转换后的实时监测数据集选择出的主成分标记为 t_k^{test} ;

步骤42:对于步骤41中所选择的主成分,运用数值模拟的方式来近似计算所选主成分的概率密度曲线,记主成分 t_k 的概率密度曲线为 f ,主成分 t_k^{test} 的概率密度曲线为 q ;

步骤43:运用Jensen-Shannon散度计算两个主成分的概率密度分布的差异性 D_{JS} ,并与预先设定的故障阈值 H 进行对比,若 $D_{JS} \geq H$,则判定为机电系统或机电设备中有故障发生;若 $D_{JS} < H$,则判定为机电系统或机电设备中没有故障发生。

一种非线性复杂系统早期故障诊断方法

技术领域

[0001] 本发明专利涉及故障诊断领域,提出了一种针对多变量非线性复杂机电系统或机电设备进行健康状态监测和早期故障诊断的方法,该方法是一种数据驱动方法,采用核主成分分析实现数据降维和故障特征的提取,采用Jensen-Shannon散度来进行故障状态的判断。

背景技术

[0002] 随着科技的进步,工业系统的发展正趋于大型化、集成化、高速化以及自动化,在提高了生产率的同时也增加了对系统安全性的要求。故障诊断对于确保工业系统的安全,保证系统的生产力以及对于制定具有经济效益的维护策略都具有十分重要的作用。

[0003] 系统故障按照发生、发展的进程进行分类可将其为突发性故障、瞬时性故障和渐发性故障。突发性故障往往会引起信号的明显变化,如阶跃或脉冲变化,因此很容易被检测到。间歇性故障是指设备或系统中不定期发生或会突然出现和消失的故障,正是由于它的这一特点它很难被检测和定位。渐发性故障的发展是一个渐进的过程,故障幅值随时间逐渐递增,发生故障的概率与时间有关,因此渐发性故障可以进行监控和预测。渐发性故障在发生的初期,其故障特征不明显且发展进程缓慢。我们把发生在渐发性故障早期阶段的故障称为早期故障。早期故障的特点是难以检测且它的故障特征容易被外界噪声等扰动所掩盖。但是,早期故障诊断在预防性维护以及最小化维护成本方面都起着关键作用,如果它的严重性被低估,对系统的安全来说是十分危险的。

[0004] 故障诊断方法可以分为基于模型的方法和基于数据的方法。基于模型的方法依赖于对系统行为的理论推导,其性能取决于数学模型的准确性,容易因操作条件的不确定性以及环境变化等因素而降低。近年来,技术的发展为数据的大量存储提供了可能。数据可以很好地描述系统的状态,基于这些历史过程数据可以用于系统状态的诊断。基于数据的方法可以被看做是一种黑箱方法,它不依赖于任何系统模型或先验知识,直接从记录的大量的过程数据提取必要的过程信息,因此基于数据的故障诊断方法呈现出巨大的应用前景。

[0005] 在对于线性的复杂系统的故障诊断中,主成分分析因其在降维和特征提取方面的优势而得到广泛关注。主成分分析是基于原始变量的线性组合,使用主成分分析可以将原始的高纬度变量转换到一个较低维度的特征空间,并将最大的原始信息保存在主成分空间中。然而,对于非线性的多变量复杂系统,传统的适用于线性系统的降维方法并不是最合适的解决方案。

[0006] 早期故障相比于其他故障类型具有故障特征不明显、发展进程缓慢的特点,早期故障的发生不会引起数据的参数特征比如均值、方差等发生明显的变化,传统的基于检测数据参数特征变化的方法例如霍特林 T^2 ,平方预测误差、累积和、多变量累积和等的检测性能很难达到理想的效果。因此需要寻找一种新的数据驱动方法提高对早期故障的诊断能力。

发明内容

[0007] 本发明的目的是为了为了更好地实现非线性复杂系统的早期故障诊断问题,本发明提出了一种基于核主成分分析和Jensen-shannon散度的故障诊断方法。核主成分分析是主成分分析的扩展情况,适用于非线性情况下的数据降维以及特征提取。核主成分分析通过采用内核操作将非线性系统的样本数据映射到一个更高维度的特征空间,在这个特征空间内样本数据可以看做线性可分,从而可在这一空间内进行降维操作和故障特征的提取。早期故障不会引起数据的参数发生显著的变化,更倾向于引起数据的概率分布上的变化。Jensen-Shannon散度是一种信息熵运算,在检测概率分布之间的差异性上表现出良好的性能,因此本发明采用Jensen-Shannon散度来进行系统故障状态的判定。

[0008] 本发明的目的是这样实现的:步骤如下:

[0009] 步骤1:采集非线性复杂机电系统或机电设备在正常工作状态下的历史时序信号数据和实时工况下的实时时序监测数据;

[0010] 步骤2:对步骤1获得的历史检测数据和实时数据进行数据预处理,获得预处理后的机电系统或机电设备的健康状态相关数据集 $\bar{\mathbf{X}}_h$ 以及系统或设备实时工况下的状态相关数据集 $\bar{\mathbf{X}}_{test}$;

[0011] 步骤3:使用核主成分分析将步骤2预处理后的数据集投影到高纬度线性空间上,得到转换到新的映射空间上的数据集,通过选取合适的主成分提取故障特征;

[0012] 步骤4:利用Jensen-Shannon散度对投影后的实时数据的概率密度分布与投影后的健康状况下的历史监测数据的概率密度分布的差异性进行计算,并与预先设定的故障阈值进行对比,完成故障诊断。

[0013] 进一步地,步骤1具体包括:

[0014] 步骤11:采集非线性复杂机电系统或机电设备在正常工作状态下的时序信号数据,即获得系统健康状态下的历史监测数据 \mathbf{x}_h ;

[0015] 步骤12:采集非线性复杂机电系统或机电设备在实时工况下的实时时序信号数据 \mathbf{x}_{test} ,采集的数据长度与历史监测数据的长度保持一致。

[0016] 进一步地,步骤2具体为:

[0017] 步骤21:对步骤1获得的历史监测数据进行去中心化和标准化处理,去中心化即将数据集中的每个变量对应的观测值减去该变量的样本平均值 μ_h ;标准化即将数据集中的去中心化后的每个变量对应的观测值再除以该变量的样本的标准差 σ_h ;

[0018] 步骤22:对步骤1获得的实时监测数据进行去中心化和标准化处理,将数据集中每个变量对应的观测值减去该变量的样本平均值 μ ,再除以该变量对应的正常工况下采集的历史监测数据样本的标准差 σ_h 。

[0019] 进一步地,步骤3具体为:

[0020] 步骤31:将步骤2中获得的预处理后的历史监测数据集使用核主成分分析投影到一个新的高纬度线性空间内,在该步骤当中通过公式

$$[0021] \quad \rho\alpha = \frac{1}{n} \bar{\mathbf{K}}\alpha$$

[0022] 式中 $\bar{\mathbf{K}} = \mathbf{K} - \mathbf{1}_n\mathbf{K} - \mathbf{K}\mathbf{1}_n + \mathbf{1}_n\mathbf{K}\mathbf{1}_n$, n 为所选择的数据样本长度,式中 $\mathbf{1}_n$ 为:

$$[0023] \quad \mathbf{1}_n = \frac{1}{n} \begin{bmatrix} 1 & \cdots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \cdots & 1 \end{bmatrix}$$

[0024] K按照如下公式计算

$$[0025] \quad \mathbf{K} = \begin{bmatrix} \mathcal{K}(\bar{\mathbf{x}}_h^1, \bar{\mathbf{x}}_h^1) & \cdots & \mathcal{K}(\bar{\mathbf{x}}_h^1, \bar{\mathbf{x}}_h^n) \\ \vdots & \ddots & \vdots \\ \mathcal{K}(\bar{\mathbf{x}}_h^n, \bar{\mathbf{x}}_h^1) & \cdots & \mathcal{K}(\bar{\mathbf{x}}_h^n, \bar{\mathbf{x}}_h^n) \end{bmatrix}$$

[0026] 其中： \mathcal{K} 为已知选定的核函数，得到特征值 ρ 和特征向量矩阵 α ；基于获得的特征值选取主成分的个数，根据得到的特征向量矩阵，计算转换到新的空间内的数据集；

[0027] 步骤32：基于步骤31中获得的特征向量矩阵，将步骤22中获得的预处理后的实时检测数据投影到同一个维度空间，并获得转换后的新的数据集。

[0028] 进一步地，步骤4具体为：

[0029] 步骤41：对步骤3中获得的转换后的历史监测数据集和实时监测数据集进行主成分的选择，基于转换后的历史监测数据集选择出的主成分标记为 t_k ，基于转换后的实时监测数据集选择出的主成分标记为 t_k^{test} ；

[0030] 步骤42：对于步骤41中所选择的主成分，运用数值模拟的方式来近似计算所选主成分的的概率密度曲线，记主成分 t_k 的概率密度曲线为 f ，主成分 t_k^{test} 的概率密度曲线为 q ；

[0031] 步骤43：运用Jensen-Shannon散度计算两个主成分的概率密度分布的差异性 D_{JS} ，并与预先设定的故障阈值 H 进行对比，若 $D_{JS} \geq H$ ，则判定为系统或设备中有故障发生；若 $D_{JS} < H$ ，则判定为系统或设备中没有故障发生。

[0032] 与现有技术相比，本发明的有益效果是：1. 适用于多变量非线性复杂系统，通过使用核主成分分析进行数据降维，降低了由于原始数据维度过多所引起的运算负担。2. 采用信息熵的方法对于发生早期故障的系统数据进行概率密度分布差异性的判别，相对于传统的基于数据参数性变化的方法来说，极大的提升了检测能力。3. 在数据采集过程中，通过采用划窗的形式，能够有效地确定早期故障发生的初始时间。4. 计算得到的Jensen-Shannon散度值与故障幅值存在函数关系，通过寻找散度值与故障幅值的关系函数，能够预测故障幅值，为预测故障的严重程度以及剩余寿命预测等提供建议。

附图说明

[0033] 图1为本发明实施例的一种基于核主成分分析和Jensen-Shannon散度的非线性复杂系统早期故障诊断方法的流程框图；

[0034] 图2为本发明实施例中采用滑窗方法进行实时信号数据采集的示意图；

[0035] 图3为本发明实施例中故障阈值计算的流程框图。

具体实施方式

[0036] 下面结合附图与具体实施方式对本发明作进一步详细描述。

[0037] 本发明提供了一种基于核主成分分析和Jensen-Shannon散度的非线性复杂系统的早期故障诊断方法，其具体操作流程如图1所示，包括以下步骤：

[0038] 步骤1：采集非线性复杂机电系统或机电设备在正常工作状态下的历史时序信号数据

X_h 和实时工况下的实时时序监测数据 X_{test} ,其中 $X_h = [x_h^1 \cdots x_h^n]^T$, $X_{test} = [x_{test}^1 \cdots x_{test}^n]^T$, $x_h^k = [x_h^{k1} \cdots x_h^{km}]$, $x_{test}^k = [x_{test}^{k1} \cdots x_{test}^{km}]$, $k = 1, 2, \cdots, n$, n 为采样的样本数据长度, m 为数据中变量的个数;

[0039] 步骤1中采集的信号数据长度要根据实际情况进行选取,方法的检测灵敏度与数据采集长度成反比,检测耗费时间与数据采集长度成正比,在本实例中所选择的数据长度为连续的1000个样本数据。

[0040] 步骤1中采集的实时工况下的实时时序监测数据的数据长度要与选取的历史监测数据的长度保持一致。

[0041] 步骤1中所述的实时工况下的系统在线监测,按照如图2所示的滑窗方法进行实时时序监测数据的选取,从而有效地确定故障发生的时间点。历史数据选取的长度为 n ,选取的实时检测数据长度同样为 n ,第一组实时监测数据标记为 X_{test}^1 ,第2组实时监测数据标记为 X_{test}^2 ,第二组监测数据的起点位置为第一组监测数据的起点位置向后移动 n_0 个数据点,第 k 组实时监测数据为整个数据样本的起点位置向后移动 $(k-1) * n_0$,在本实例中选择的取样间隔为100;

[0042] 步骤1中采集的数据长度应结合实际需要进行选取,采集的数据长度越长,该故障诊断方法对于早期故障检测的准确度越高,但是随着采集的数据长度的增大,同时也造成检测出故障需要的时间增长。

[0043] 步骤2:对步骤1获得的历史检测数据和实时数据进行数据预处理,获得预处理后的机电系统或机电设备的健康状态相关数据集 \bar{X}_h 以及系统或设备实时工况下的状态相关数据集 \bar{X}_{test} 。

[0044] 步骤21:对步骤1获得的历史监测数据进行去中心化和标准化处理,去中心化即将数据集中的每个变量对应的观测值减去该变量的样本平均值 μ_h ;标准化即将数据集中的去中心化后的每个变量对应的观测值再除以该变量的样本的标准差 σ_h 。

[0045] 步骤22:对步骤1获得的实时监测数据进行去中心化和标准化处理,将数据集中每个变量对应的观测值监测该变量的样本平均值 μ ,再除以该变量对应的正常工况下采集的历史监测数据样本的标准差 σ_h 。

[0046] 步骤3:使用核主成分分析将步骤2预处理后的数据集投影到高纬度线性空间上,得到转换到新的映射空间上的数据集,通过选取合适的主成分提取故障特征。

[0047] 步骤31:将步骤2中获得的预处理后的历史监测数据集使用核主成分分析投影到一个新的高纬度线性空间内,在该步骤当中通过公式

$$[0048] \quad \rho\alpha = \frac{1}{n}\bar{K}\alpha \quad (1)$$

[0049] 式中 $\bar{K} = K - \mathbf{1}_n K - K \mathbf{1}_n + \mathbf{1}_n K \mathbf{1}_n$, n 为所选择的数据样本长度,式中 $\mathbf{1}_n$ 为:

$$[0050] \quad \mathbf{1}_n = \frac{1}{n} \begin{bmatrix} 1 & \cdots & 1 \\ \vdots & \ddots & \vdots \\ 1 & \cdots & 1 \end{bmatrix}$$

[0051] K 按照如下公式计算

$$[0052] \quad \mathbf{K} = \begin{bmatrix} \mathcal{K}(\bar{\mathbf{x}}_h^1, \bar{\mathbf{x}}_h^1) & \cdots & \mathcal{K}(\bar{\mathbf{x}}_h^1, \bar{\mathbf{x}}_h^n) \\ \vdots & \ddots & \vdots \\ \mathcal{K}(\bar{\mathbf{x}}_h^n, \bar{\mathbf{x}}_h^1) & \cdots & \mathcal{K}(\bar{\mathbf{x}}_h^n, \bar{\mathbf{x}}_h^n) \end{bmatrix} \quad (2)$$

[0053] 其中 \mathcal{K} 为已知选定的核函数,在本发明实施例中选择的是高斯核函数。求解公式(1)得到特征值 ρ 和特征向量矩阵 α 。根据得到的特征向量矩阵,计算转换到新的空间内的数据集,得到的第 k 个主成分的第 q 个值为 $t^{qk} = \sum_{i=1}^n \alpha^{ik} \bar{\mathbf{K}}^{qi}$;

[0054] 步骤32:基于步骤31中获得的特征向量矩阵,将步骤22中获得的预处理后的实时检测数据投影到同一个维度空间,并获得转换后的新的数据集,得到第 k 个主成分第 q 个值为 $t_{test}^{qk} = \sum_{i=1}^n \alpha^{ik} \bar{\mathbf{K}}^{test}(\bar{\mathbf{x}}_{test}^q, \bar{\mathbf{x}}_h^i)$, $\bar{\mathbf{K}}^{test} = \mathbf{K}^{test} - \mathbf{1}^{test} \mathbf{K} - \mathbf{K}^{test} \mathbf{1}_n + \mathbf{1}^{test} \mathbf{K} \mathbf{1}_n$,其中 $\mathbf{1}^{test} = \frac{1}{n} [1 \quad \cdots \quad 1] \in R^{1 \times n}$, $\mathbf{K}^{test} = \mathcal{K}(\bar{\mathbf{x}}_{test}^q, \bar{\mathbf{x}}_h^j), j = [1, \dots, n]$;

[0055] 步骤4:利用Jensen-Shannon散度对投影后的实时数据的概率密度分布与投影后的健康状况下的历史监测数据的概率密度分布的差异性进行计算,并与预先设定的故障阈值进行对比,从而完成故障诊断。

[0056] 步骤41:对步骤3中获得的转换后的历史监测数据集和实时监测数据集进行主成分的选择,基于转换后的历史监测数据集选择出的主成分标记为 t_k ,基于转换后的实时监测数据集选择出的主成分标记为 t_k^{test} ;

[0057] 步骤41中所述的主成分按照累积贡献率不小于百分之八十的主成分作为分析样本。

[0058] 步骤42:对于步骤41中所选择的主成分,运用数值模拟的方式来近似计算所选主成分的的概率密度曲线,记主成分 t_k 的概率密度曲线为 f ,主成分 t_k^{test} 的概率密度曲线为 q 。

[0059] 步骤42中所示的概率密度曲线的近似计算,在当前实施例中采用Matlab软件中的核密度估计(ksdensity)工具进行近似计算,ksdensity工具的精确度所选参数的影响,在本实施例中选取的核函数是正态核函数,带宽选择为10倍的系统默认带宽。

[0060] 步骤43:运用Jensen-Shannon散度计算两个主成分的概率密度分布的差异性 D_{JS} ,并与预先设定的故障阈值 H 进行对比,若 $D_{JS} \geq H$,则判定为系统或设备中有故障发生;若 $D_{JS} < H$,则判定为系统或设备中没有故障发生。

[0061] 对于步骤41中选择的主成分的个数多于1个的情况下,则需要逐一对选取的各个主成分做重复步骤42和步骤43操作,例如当选择的主成分个数是2,则需要选取 t_1 和 t_1^{test} 重复步骤42和步骤43;再选取 t_2 和 t_2^{test} 重复步骤42和步骤43,综合基于两个主成分数据的故障诊断结果进行系统有无故障的判断。

[0062] 步骤43中所述的故障阈值的计算流程图如图3所示,具体操作步骤如下:

[0063] 步骤431:采集非线性复杂机电系统或机电设备在正常工作状态下的历史时序信号数据,并对历史监测数据进行去中心化和标准化;

[0064] 步骤432:采集非线性复杂机电系统或机电设备在正常工作状态下的实时时序监测数据;

[0065] 步骤433:对步骤432获得的实时监测数据进行去中心化和标准化处理,将数据集

中每个变量对应的观测值监测该变量的样本平均值,再除以该变量对应的正常工况下采集的历史监测数据样本的标准差;

[0066] 步骤434:使用核主成分分析将步骤432预处理后的数据集投影到高纬度线性空间上,得到转换到新的映射空间上的数据集,并利用相同的特征矩阵,将步骤433中预处理后的数据集投影到相同的映射空间上,根据特征值矩阵,选取总贡献率不少于百分之八十的主成分作为分析数据,进行数据降维和提取故障特征;

[0067] 步骤435:利用Jensen-Shannon散度对投影后的实时数据的概率密度分布与投影后的健康状况下的历史监测数据的概率密度分布的差异性进行计算,获得Jensen-Shannon散度值;

[0068] 步骤436:重复步骤432-435,获得足够数量的Jensen-Shannon散度值,给定置信度,运用假设检验的方法来计算故障阈值,在本发明实例中,计算的Jensen-Shannon散度的值为500个,给定的置信度为0.05.

[0069] 以上实施例仅对本发明的设计思路以及优选实施方式进行说明,其目的在于使本领域内的技术人员能够了解本发明的内容和实施方式并据以实施,本发明的保护范围不限于上述实施例,凡依据本发明所揭示的原理、设计思路等所做的变化、变形或改进,均在本发明的保护范围之内。

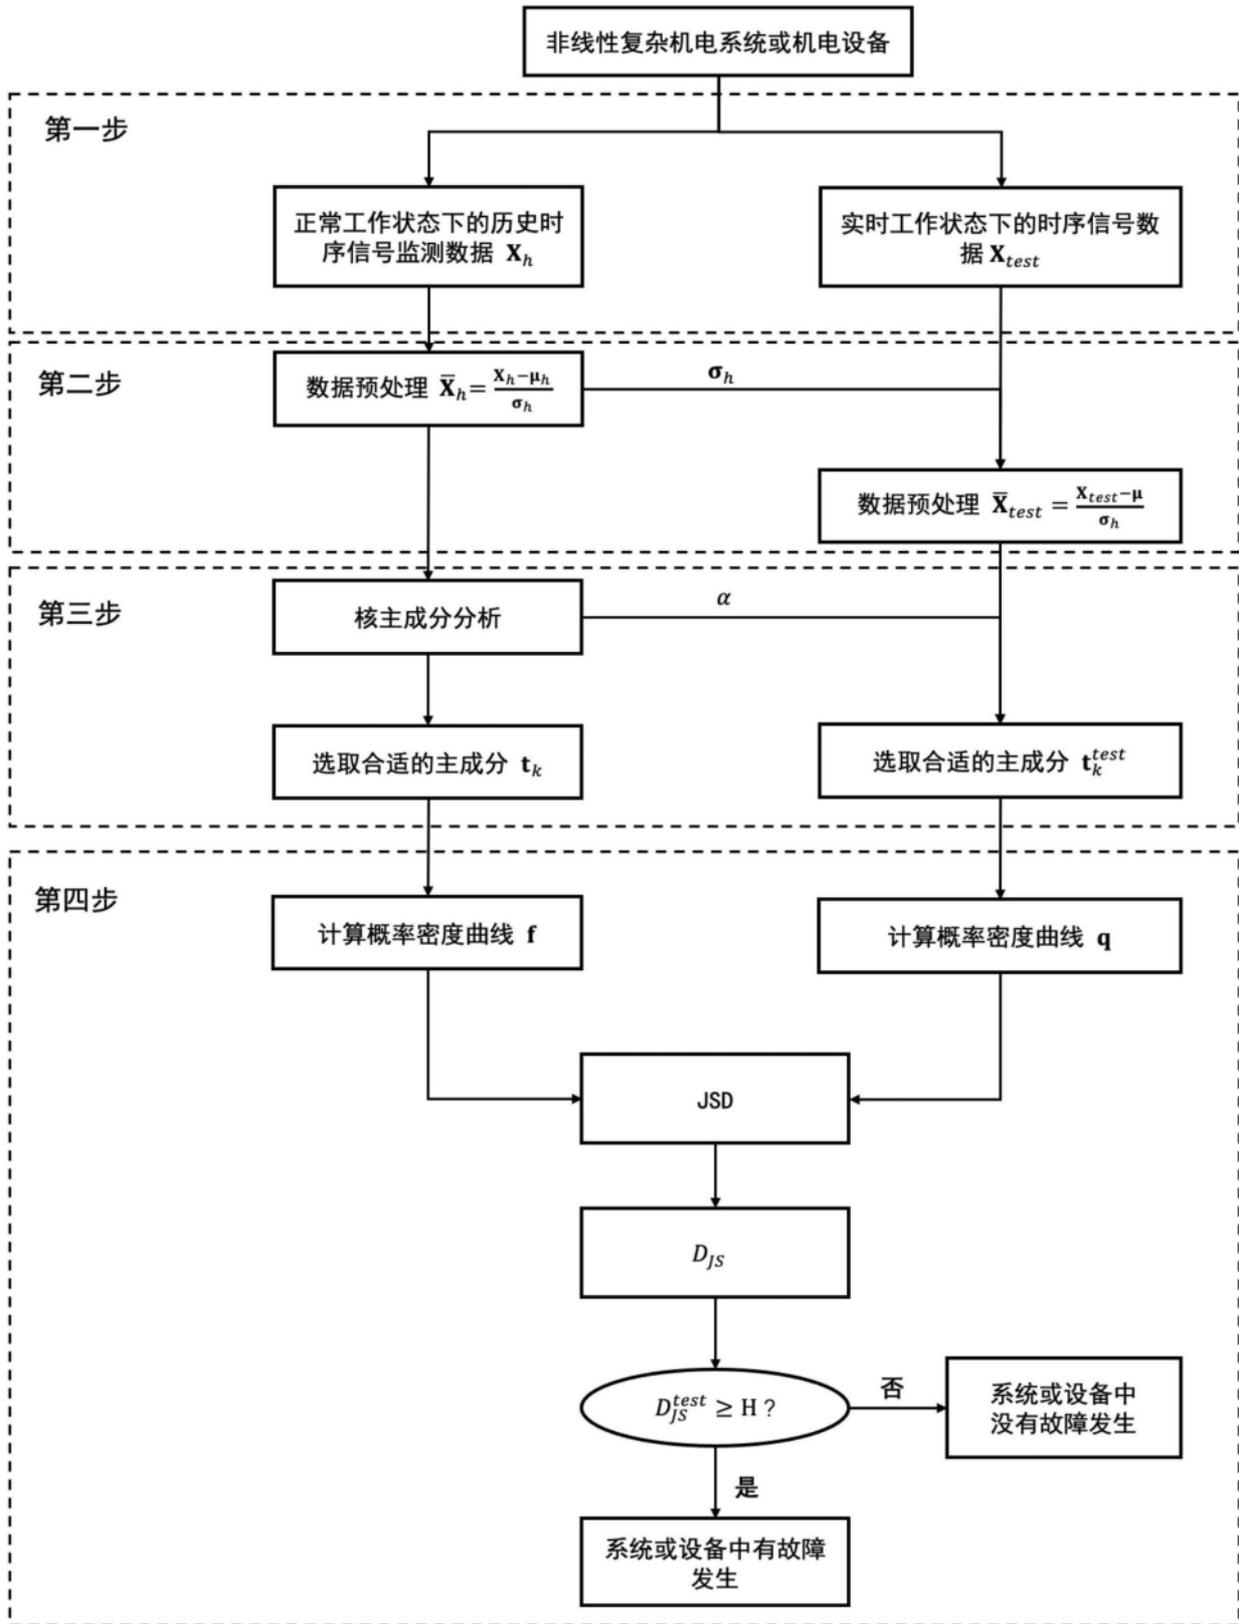


图1

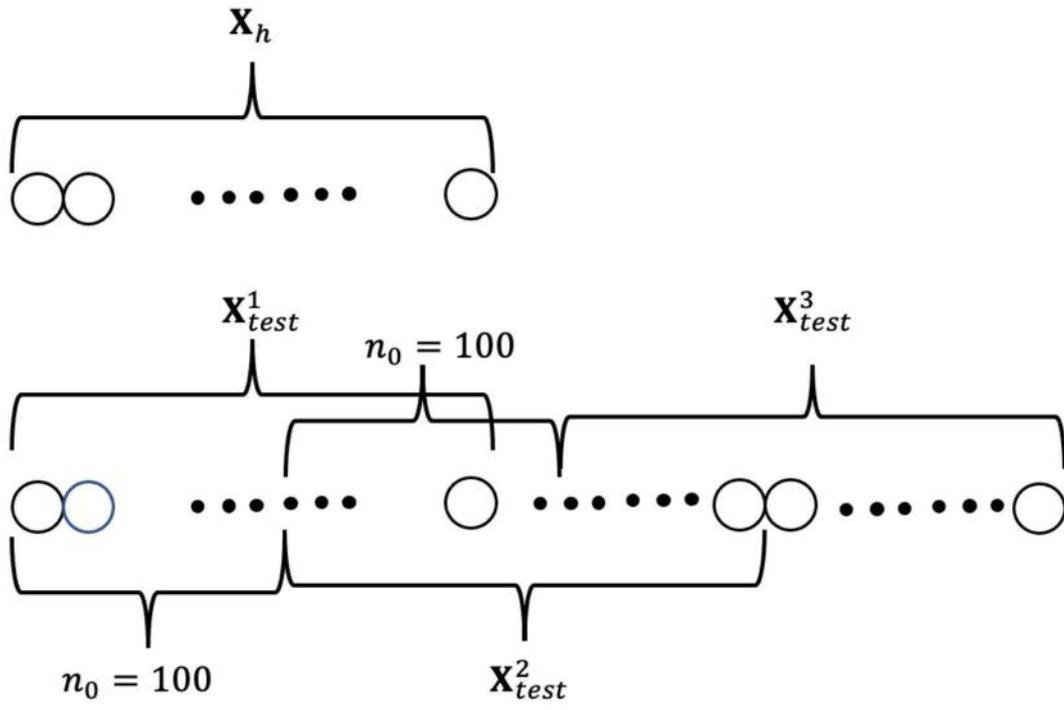


图2

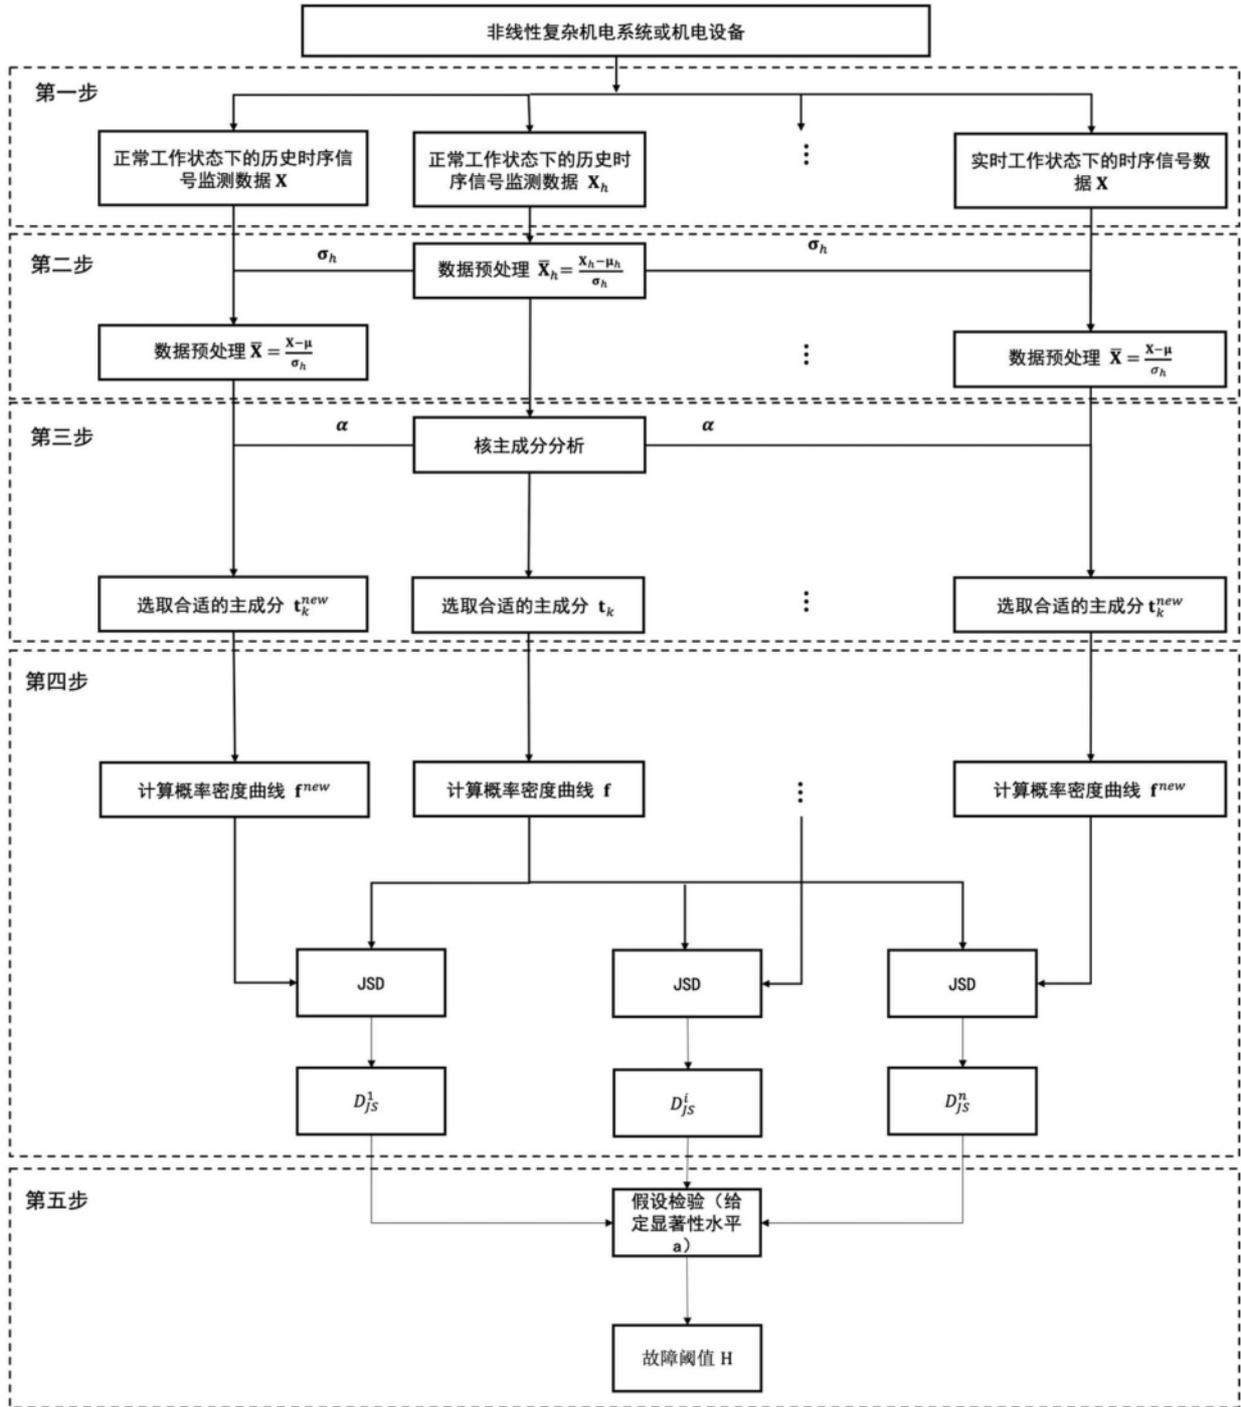


图3