



(12)发明专利

(10)授权公告号 CN 105973594 B

(45)授权公告日 2018.05.29

(21)申请号 201610259840.9

(22)申请日 2016.04.25

(65)同一申请的已公布的文献号

申请公布号 CN 105973594 A

(43)申请公布日 2016.09.28

(73)专利权人 西北工业大学

地址 710072 陕西省西安市友谊西路127号

(72)发明人 姜洪开 邵海东 张雪莉 王福安

(74)专利代理机构 西北工业大学专利中心

61204

代理人 陈星

(51)Int.Cl.

G01M 13/04(2006.01)

G06K 9/00(2006.01)

G06K 9/62(2006.01)

(56)对比文件

CN 104616033 A, 2015.05.13,

WO 2016033247 A2, 2016.03.03,

CN 105043766 A, 2015.11.11,

CN 105424364 A, 2016.03.23,

孙志远 等.深度学习研究与进展.《计算机

(54)发明名称

一种基于连续深度置信网络的滚动轴承故障预测方法

(57)摘要

本发明提出一种基于连续深度置信网络的滚动轴承故障预测方法,该方法首先提取滚动轴承振动信号的时域特征量,然后利用局部线性嵌入方法融合所提取的时域特征信息,从而定义一个新的综合监测指标用于更好地定量地评估轴承的性能退化;逐层训练连续受限玻尔兹曼机进而构造连续深度置信网络预测模型;采用遗传算法来优化连续深度置信网络的结构,进一步提升预测精度。该预测方法结果可靠,实时性好,简单易行,适用于滚动轴承故障预测。

科学》.2016,第43卷(第2期),第1-8页。

乔俊飞 等.一种连续型深度信念网的设计与应用.《自动化学报》.2015,第41卷(第12期),第2138-2146页。

H. Chen 等.Continuous restricted Boltzmann machine with an implementable training algorithm.《IEE Proc.-Vis. Image Signal Process.》.2003,第150卷(第3期),第153-158页。

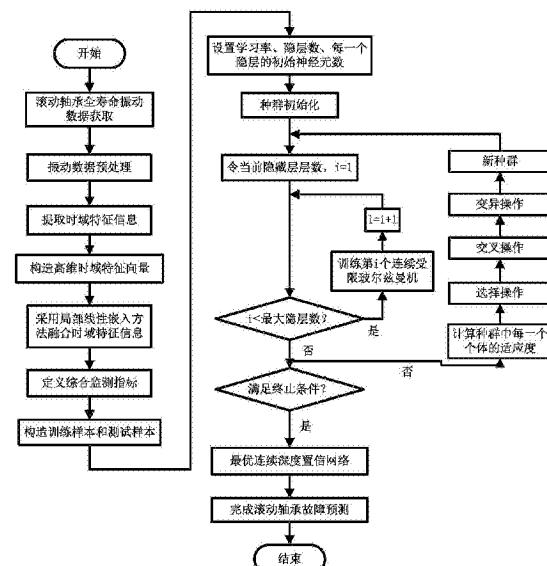
Haidong Shao 等.Rolling bearing fault diagnosis using an optimization deep belief network.《Measurement Science and Technology》.2015,(第26期),第1-16页。

Prasanna Tamilselvan 等.Failure-diagnosis-using-deep-belief-learning-based-health-state-classification.《Reliability Engineering and System Safety》.2013,(第115期),第124-135页。

姚培 等.局部保形映射和AdaBoost方法在滚动轴承故障诊断中的应用.《振动与冲击》.2013,第32卷(第5期),第144-148页。

审查员 崔金

权利要求书2页 说明书8页 附图4页



1. 一种基于连续深度置信网络的滚动轴承故障预测方法,其特征在于:包括以下步骤:

步骤1:提取滚动轴承振动信号的多个时域统计特征量,并采用提取的时域统计特征量构造一个多维非线性特征向量;利用局部线性嵌入方法对多维非线性特征向量进行融合,得到映射矩阵,取映射矩阵特征值中,按从小到大排序的第2个特征值对应的特征向量作为综合监测指标;

步骤1的具体过程为:

步骤1.1:采集滚动轴承振动加速度信号,提取振动加速度信号的6个时域统计特征量,分别为均方根值、峰峰值、峭度、脉冲指标、裕度指标和波形指标,组成一个6维特征向量;每个6维特征向量为一个样本点;

步骤1.2:计算每一个样本点 x_i 的近邻点, $x_i \in R^D, D=6, i=1, 2, \dots, N, N$ 为样本点个数:将相对于样本点 x_i 欧式距离最近的K个样本点定义为样本点 x_i 的K个近邻点;

步骤1.3:根据每个样本点的近邻点计算出局部重建权值矩阵W,使样本点的重建误差最小:

定义成本函数 $\epsilon(W)$ 为:

$$\min \epsilon(W) = \sum_{i=1}^N \left| \mathbf{x}_i - \sum_{j=1}^K \mathbf{w}_{ij} \mathbf{x}_j \right|^2$$

式中 $w_{ij}, j=1, 2, \dots, K$ 为第j个近邻点 x_j 到第i个样本点 x_i 之间的权重,且满足 $\sum_{j=1}^K w_{ij} = 1$;

步骤1.4:根据得到的局部重建权值矩阵W,计算6维特征向量的低维表示Y,得到将所有6维原始空间上的观测样本点映射到内部全局坐标的低维向量 $y_i, y_i \in R^d, d$ 为本征维度;映射条件满足如下关系:

$$\min \epsilon(Y) = \sum_{i=1}^N \left| \mathbf{y}_i - \sum_{j=1}^K \mathbf{w}_{ij} \mathbf{y}_j \right|^2 = \text{tr}(Y^T M Y)$$

且满足条件

$$\begin{cases} \sum_{i=1}^N \mathbf{y}_i = \mathbf{0} \\ \frac{1}{N} \sum_{i=1}^N \mathbf{y}_i^T \mathbf{y}_i = \mathbf{I} \\ \mathbf{M} = (\mathbf{I} - \mathbf{W})^T (\mathbf{I} - \mathbf{W}) \end{cases}$$

其中 $\epsilon(Y)$ 为损失函数值, y_i 是 x_i 在低维空间上的输出向量, y_j 是 y_i 的近邻点, $\text{tr}(\cdot)$ 为矩阵求迹运算符, I 为 $N \times N$ 的单位矩阵, M 为稀疏对称半正定的映射矩阵;

步骤1.5:计算映射矩阵M的特征值,取映射矩阵特征值中,按从小到大排序的第2个特征值对应的特征向量作为综合监测指标;

步骤2:采集滚动轴承正常工作阶段的综合监测指标值作为训练样本,逐层训练连续受限玻尔兹曼机,进而构造连续深度置信网络模型;

步骤3:采用连续深度置信网络模型预测滚动轴承未来的工作状态。

2. 根据权利要求1所述一种基于连续深度置信网络的滚动轴承故障预测方法,其特征在于:K取12。

3. 根据权利要求1所述一种基于连续深度置信网络的滚动轴承故障预测方法,其特征

在于：步骤2中，采用连续受限玻尔兹曼机逐层构造连续深度置信网络模型过程为：

步骤2.1：连续受限玻尔兹曼机由可视层和隐含层组成，可视层接受输入的综合监测指标值；连续受限玻尔兹曼机的可视层中通过添加零均值的高斯噪声引入连续随机单元；取 h_t 为隐单元t的状态， v_p 表示输入的可视单元p的状态，有：

$$h_t = \varphi_t \left(\sum_p \omega_{pt} v_p + \sigma \cdot N_t(0,1) \right)$$

$$\varphi_t(x) = \theta_L + (\theta_H - \theta_L) \cdot \frac{1}{1 + \exp(-a_t x)}$$

其中 $N_t(0,1)$ 表示零均值、单位方差的高斯随机变量，常数 σ 和 $N_t(0,1)$ 共同产生了一个噪声输入分量 $n_t = \sigma \cdot N_t(0,1)$ ， σ 取 $0.2 \sim 0.5$ ； ω_{pt} 为连续受限玻尔兹曼机模型中可视单元p与隐单元t之间的连接权值； $\varphi_t(x)$ 是渐近线在 θ_L 和 θ_H 处的Sigmoid函数，其中 $\theta_L = 0, \theta_H = 1$ ，参数 a_t 为噪声控制变量，控制Sigmoid曲线的斜率；

采用一步重构的最小化对比散度算法训练连续受限玻尔兹曼机，模型的权值 ω_{pt} 和噪声控制参数 a_t 的更新公式为：

$$\Delta \omega_{pt} = \eta_\omega (\langle v_{ph} h_t \rangle - \langle v'_{ph} h'_t \rangle)$$

$$\Delta a_t = \frac{\eta_a}{a_t^2} (\langle h_t^2 \rangle - \langle h_t'^2 \rangle)$$

式中 h_t' 为隐单元t的一步重构状态， $\langle \cdot \rangle$ 为训练数据的期望， η_ω 和 η_a 为学习率，取值为 $0.01 \sim 0.5$ ；

步骤2.2：重复步骤2.1操作3次，依次得到3个连续受限玻尔兹曼机模型，逐层堆叠连续受限玻尔兹曼机模型构建连续深度置信网络模型：第一个连续受限玻尔兹曼机模型的输入为综合监测指标值，第二个连续受限玻尔兹曼机模型的输入为第一个连续受限玻尔兹曼机模型的输出，第三个连续受限玻尔兹曼机模型的输入为第二个连续受限玻尔兹曼机模型的输出。

4. 根据权利要求3所述一种基于连续深度置信网络的滚动轴承故障预测方法，其特征在于：采用遗传算法优化连续深度置信网络模型结构：待优化的模型参数有3个，分别为3个隐含层的神经元数 l_1, l_2 和 l_3 ，具体的优化过程包括以下步骤：

步骤2.3.1：给定一组 l_1, l_2 和 l_3 的初始值，根据试验任务设置种群规模 N_1 、最大迭代次数 T_1 、交叉概率 p_c 和变异概率 p_m ，种群中的每一个个体表示一种网络结构；

步骤2.3.2：提供一组训练样本给连续深度置信网络的可视层，训练连续深度置信网络模型，用测试样本检验模型预测性能，计算预测误差，预测误差的指标为均方根误差；所述训练样本为滚动轴承正常工作阶段的综合监测指标值，所述测试样本为滚动轴承微弱故障阶段和完全失效阶段的综合监测指标值；

步骤2.3.3：以均方根误差作为目标函数，根据目标函数确定遗传算法的适应度函数，计算每个个体的适应度；

步骤2.3.4：对当前种群进行遗传操作，产生新的种群，遗传操作包括选择、交叉和变异；

步骤2.3.5：判断遗传算法是否达到最大迭代次数，若满足，则结束优化，若不满足，返回步骤2.3.2。

一种基于连续深度置信网络的滚动轴承故障预测方法

技术领域

[0001] 本发明属机械设备健康监测领域,具体为一种基于连续深度置信网络的滚动轴承故障预测方法。

背景技术

[0002] 滚动轴承是旋转机械中应用最为广泛的机械零件,也是最易损坏的元件之一。滚动轴承在运转过程中可能会由于各种原因引起损坏,如装配不当、润滑不良、水分和异物侵入、腐蚀和过载等都可能会导致滚动轴承过早损坏。即使在安装、润滑和使用维护都正常的情况下,经过一段时间运转,滚动轴承也会出现疲劳剥落和磨损而不能正常工作。因此滚动轴承故障预测非常重要,它不仅能够保证设备安全运行、预防重大事故、提高经济效益,还可以为制定合理有效的检修计划提供可靠的依据,是预测与健康管理领域的一个重要研究方向。

[0003] 目前,滚动轴承故障预测的常用方法主要有三类:基于模型的预测方法、基于知识的预测方法、基于数据驱动的预测方法。然而,由于实际机械设备所处环境复杂,载荷形态多样,设备服役的动力学规律很难获得,因而建立准确的数学模型来描述机械重大装备部件和整机的故障演化规律存在较大的困难,因此基于模型的预测方法的实际应用范围和效果十分受限。知识库的不完备导致基于知识的预测方法自适应学习能力明显不足,因此其更适合于定性推理而非定量计算。基于数据驱动的预测方法以采集的数据为基础,不需要或只需要少量的对象系统的先验知识,通过各种数据分析方法挖掘其中隐含信息进行评估,是目前应用比较广泛的预测方法。其典型代表是:神经网络和支持向量机。

[0004] 神经网络和支持向量机等虽然已在故障预测领域得到了一定的应用,但是这些方法仍存在一些明显不足之处。神经网络容易陷入局部极小值,且其收敛速度过慢;支持向量机更适用于小样本的学习而不适合大规模样本的学习,且其核函数及参数的选择缺乏相应的理论。更重要的在于,这些传统模型本质上都是浅层机器学习模型,通常包含不超过一层的非线性特征变换,当给定有限数量的样本和计算单元时,浅层结构模型难以有效地表示复杂非线性函数。而轴承故障的演化规律是一个变化异常复杂的非线性、非平稳时间序列,故用神经网络等传统的浅层预测方法难以在信息贫乏和不确定性条件下对如此复杂的时间序列做出准确有效的预测。特别是当处理有噪声数据时,浅层预测模型容易把噪声数据记录下来而发生过拟合。这些都揭示了浅层网络的局限性,也激发了人们探寻深度网络在非线性非平稳振动信号表达中的应用前景。

[0005] 深度学习理论是在传统人工神经网络的基础上提出的,它的实质是通过构建具有多隐层的机器学习模型和逐层特征变换,来学习众多复杂数据中更有用特征,发现其内在演变的规律和模式,从而最终提升预测的准确性。深度置信网络是一个主流的深度学习模型,它通过学习一种深层非线性网络结构,以发现输入数据的分布式特征表示,除此之外,它还具备了从少数样本集中学习本质特征的强大能力,这些优良性能是传统的浅层模型远远无法比拟的。连续深度置信网络模型是对传统深度置信网络的改进和提升,它能更好地

建模滚动轴承振动数据,优化连续深度置信网络模型的结构能进一步提升预测精度,有效完成滚动轴承的故障预测。

发明内容

[0006] 为解决现有技术存在的问题,本发明提出一种基于连续深度置信网络的滚动轴承故障预测方法:首先提取滚动轴承振动信号的时域特征量,然后利用局部线性嵌入方法融合所提取的时域特征信息,得到一个新的综合监测指标用于更好地定量地评估轴承的性能退化;将滚动轴承正常工作阶段的综合监测指标值作为训练样本,逐层训练连续受限玻尔兹曼机进而构造连续深度置信网络预测模型,采用遗传算法来优化连续深度置信网络的结构,进一步提升预测精度。该方法预测精度高,简单可靠,适用于滚动轴承故障预测。

[0007] 本发明的技术方案为:

[0008] 所述一种基于连续深度置信网络的滚动轴承故障预测方法,其特征在于:包括以下步骤:

[0009] 步骤1:提取滚动轴承振动信号的多个时域统计特征量,并采用提取的时域统计特征量构造一个多维非线性特征向量;利用局部线性嵌入方法对多维非线性特征向量进行融合,得到映射矩阵,取映射矩阵特征值中,按从小到大排序的第2个特征值对应的特征向量作为综合监测指标;

[0010] 步骤2:采集滚动轴承正常工作阶段的综合监测指标值作为训练样本,逐层训练连续受限玻尔兹曼机,进而构造连续深度置信网络模型;

[0011] 步骤3:采用连续深度置信网络模型预测滚动轴承未来的工作状态。

[0012] 进一步的优选方案,所述一种基于连续深度置信网络的滚动轴承故障预测方法,其特征在于:步骤1的具体过程为:

[0013] 步骤1.1:采集滚动轴承振动加速度信号,提取振动加速度信号的6个时域统计特征量,分别为均方根值、峰峰值、峭度、脉冲指标、裕度指标和波形指标,组成一个6维特征向量;每个6维特征向量为一个样本点;

[0014] 步骤1.2:计算每一个样本点 x_i 的近邻点, $x_i \in R^D, D=6, i=1, 2, \dots, N, N$ 为样本点个数;将相对于样本点 x_i 欧式距离最近的K个样本点定义为样本点 x_i 的K个近邻点;

[0015] 步骤1.3:根据每个样本点的近邻点计算出局部重建权值矩阵W,使样本点的重建误差最小:

[0016] 定义成本函数 $\epsilon(W)$ 为:

$$[0017] \min \epsilon(W) = \sum_{i=1}^N \left| x_i - \sum_{j=1}^K w_{ij} x_j \right|^2$$

[0018] 式中 $w_{ij}, j=1, 2, \dots, K$ 为第j个近邻点 x_j 到第i个样本点 x_i 之间的权重,且满足 $\sum_{j=1}^K w_{ij} = 1$;

[0019] 步骤1.4:根据得到的局部重建权值矩阵W,计算6维特征向量的低维表示Y,得到将所有6维原始空间上的观测样本点映射到内部全局坐标的低维向量 $y_i, y_i \in R^d, d$ 为本征维度;映射条件满足如下关系:

$$[0020] \min \epsilon(Y) = \sum_{i=1}^N \left| y_i - \sum_{j=1}^K w_{ij} y_j \right|^2 = \text{tr}(Y^T M Y)$$

[0021] 且满足条件

$$\begin{aligned} [0022] \quad & \left\{ \begin{array}{l} \sum_{i=1}^N \mathbf{y}_i = \mathbf{0} \\ \frac{1}{N} \sum_{i=1}^N \mathbf{y}_i^T \mathbf{y}_i = \mathbf{I} \\ \mathbf{M} = (\mathbf{I} - \mathbf{W})^T (\mathbf{I} - \mathbf{W}) \end{array} \right. \end{aligned}$$

[0023] 其中 $\varepsilon(Y)$ 为损失函数值, y_i 是 x_i 在低维空间上的输出向量, y_j 是 y_i 的近邻点, $\text{tr}(\cdot)$ 为矩阵求迹运算符, I 为 $N \times N$ 的单位矩阵, M 为稀疏对称半正定的映射矩阵;

[0024] 步骤1.5: 计算映射矩阵 M 的特征值, 取映射矩阵特征值中, 按从小到大排序的第2个特征值对应的特征向量作为综合监测指标。

[0025] 进一步的优选方案, 所述一种基于连续深度置信网络的滚动轴承故障预测方法, 其特征在于: K 取 12。

[0026] 进一步的优选方案, 所述一种基于连续深度置信网络的滚动轴承故障预测方法, 其特征在于: 步骤2中, 采用连续受限玻尔兹曼机逐层构造连续深度置信网络模型过程为:

[0027] 步骤2.1: 连续受限玻尔兹曼机由可视层和隐含层组成, 可视层接受输入的综合监测指标值; 连续受限玻尔兹曼机的可视层中通过添加零均值的高斯噪声引入连续随机单元; 取 h_t 为隐单元 t 的状态, v_p 表示输入的可视单元 p 的状态, 有:

$$[0028] \quad h_t = \varphi_t \left(\sum_p \omega_{pt} v_p + \sigma \cdot N_t(0, 1) \right)$$

$$[0029] \quad \varphi_t(x) = \theta_L + (\theta_H - \theta_L) \cdot \frac{1}{1 + \exp(-a_t x)}$$

[0030] 其中 $N_t(0, 1)$ 表示零均值、单位方差的高斯随机变量, 常数 σ 和 $N_t(0, 1)$ 共同产生了一个噪声输入分量 $n_t = \sigma \cdot N_t(0, 1)$, σ 取 $0.2 \sim 0.5$; ω_{pt} 为连续受限玻尔兹曼机模型中可视单元 p 与隐单元 t 之间的连接权值; $\varphi_t(x)$ 是渐近线在 θ_L 和 θ_H 处的 Sigmoid 函数, 其中 $\theta_L = 0$, $\theta_H = 1$, 参数 a_t 为噪声控制变量, 控制 Sigmoid 曲线的斜率;

[0031] 采用一步重构的最小化对比散度算法训练连续受限玻尔兹曼机, 模型的权值 ω_{pt} 和噪声控制参数 a_t 的更新公式为:

$$[0032] \quad \Delta \omega_{pt} = \eta_\omega (\langle v_p h_t \rangle - \langle v' p h' t \rangle)$$

$$[0033] \quad \Delta a_t = \frac{\eta_a}{a_t^2} (\langle h_t^2 \rangle - \langle h_t' \rangle)$$

[0034] 式中 $h' t$ 为隐单元 t 的一步重构状态, $\langle \cdot \rangle$ 为训练数据的期望, η_ω 和 η_a 为学习率, 取值为 $0.01 \sim 0.5$;

[0035] 步骤2.2: 重复步骤2.1操作3次, 依次得到3个连续受限玻尔兹曼机模型, 逐层堆叠连续受限玻尔兹曼机模型构建连续深度置信网络模型: 第一个连续受限玻尔兹曼机模型的输入为综合监测指标值, 第二个连续受限玻尔兹曼机模型的输入为第一个连续受限玻尔兹曼机模型的输出, 第三个连续受限玻尔兹曼机模型的输入为第二个连续受限玻尔兹曼机模型的输出。

[0036] 进一步的优选方案, 所述一种基于连续深度置信网络的滚动轴承故障预测方法, 其特征在于: 采用遗传算法优化连续深度置信网络模型结构: 待优化的模型参数有3个, 分

别为3个隐含层的神经元数 l_1 、 l_2 和 l_3 ,具体的优化过程包括以下步骤:

[0037] 步骤2.3.1:给定一组 l_1 、 l_2 和 l_3 的初始值,根据试验任务设置种群规模 N_1 、最大迭代次数 T_1 、交叉概率 p_c 和变异概率 p_m ,种群中的每一个个体表示一种网络结构;

[0038] 步骤2.3.2:提供一组训练样本给连续深度置信网络的可视层,训练连续深度置信网络模型,用测试样本检验模型预测性能,计算预测误差,预测误差的指标为均方根误差;所述训练样本为滚动轴承正常工作阶段的综合监测指标值,所述测试样本为滚动轴承微弱故障阶段和完全失效阶段的综合监测指标值;

[0039] 步骤2.3.3:以均方根误差作为目标函数,根据目标函数确定遗传算法的适应度函数,计算每个个体的适应度;

[0040] 步骤2.3.4:对当前种群进行遗传操作,产生新的种群,遗传操作包括选择、交叉和变异;

[0041] 步骤2.3.5:判断遗传算法是否达到最大迭代次数。若满足,则结束优化,若不满足,返回步骤2.3.2。

[0042] 有益效果

[0043] 本发明的有益效果是:本发明在采用局部线性嵌入方法融合振动信号的时域特征信息定义的综合监测指标能有效地描述滚动轴承全寿命的性能退化,具体分为三个阶段:正常阶段,微弱故障阶段和故障逐渐演化为失效阶段,另外本发明实施例在经遗传算法优化的连续深度置信网络模型上进行了两次验证,一次是利用仿真信号来验证连续深度置信网络模型在非线性和非平稳时序信号预测中的有效性;另一个是利用NASA滚动轴承正常工作阶段的综合监测指标数据来验证本发明方法在轴承故障预测中的准确性和可靠性。相比与传统方法,本发明得到的滚动轴承性能退化预测曲线精度高,可靠性强,可以应用于滚动轴承的健康监测。

[0044] 本发明的附加方面和优点将在下面的描述中部分给出,部分将从下面的描述中变得明显,或通过本发明的实践了解到。

附图说明

[0045] 本发明的上述和/或附加的方面和优点从结合下面附图对实施例的描述中将变得明显和容易理解,其中:

[0046] 图1为本发明滚动轴承故障预测方法的流程图;

[0047] 图2为本发明仿真信号图;

[0048] 图3为本发明仿真信号预测结果图;

[0049] 图4为本发明滚动轴承全寿命周期振动信号时域图;

[0050] 图5为本发明综合监测指标图;

[0051] 图6为本发明实验信号预测结果图。

具体实施方式

[0052] 下面详细描述本发明的实施例,描述的实施例是示例性的,旨在用于解释本发明,而不能理解为对本发明的限制。

[0053] 参照图1所示,本发明实施例的内容可主要分为三部分。第一部分是提取滚动轴承

振动信号的6种时域特征量，分别为均方根值、峰峰值、峭度、脉冲指标、裕度指标和波形指标，组成一个6维特征向量，然后利用局部线性嵌入方法融合所提取的时域特征信息，得到映射矩阵，将映射矩阵的特征值从小到大排列，将第2个特征值对应的特征向量定义为一个新的综合监测指标，来更好地定量地评估轴承的性能退化；第二部分是将滚动轴承正常工作阶段的综合监测指标值作为训练样本，逐层训练连续受限玻尔兹曼机进而构造连续深度置信网络预测模型；第三部分是采用遗传算法来优化连续深度置信网络的结构，进一步提升预测性能。

[0054] 参照图2所示，由Mackey-Glass差分延迟方程产生的550个数据点的仿真信号，前500个数据点作为训练样本，后50个数据点作为测试样本。图中横坐标表示数据点数；纵坐标表示幅值，幅值的量纲为1；黑色实线表示训练样本，黑色虚线表示测试样本。

[0055] 参照图3所示，采用本发明方法预测仿真信号中后50个数据点，预测结果与真实值非常接近。图中横坐标表示测试样本中的数据点数；纵坐标表示幅值，幅值的量纲为1；黑色实线表示真实值，黑色虚线表示预测值。

[0056] 参照图4所示，滚动轴承全寿命周期振动信号时域图，总共有总共46200000个振动数据点。图中横坐标表示时间，单位为day；纵坐标表示振动幅值，单位为m/s²。由图可知，第32天左右，滚动轴承出现微弱故障，第34天左右，滚动轴承失效。

[0057] 参照图5所示，采用局部线性嵌入方法融合振动信号的时域特征信息，得到3080个数据点的综合监测指标。根据这个综合监测指标，轴承全寿命周期可以分为三个阶段：正常阶段（第1天至第32天），微弱故障阶段（第32天至第34天）和故障逐渐演化为失效阶段（第34天至第35天）。所定义的综合监测指标能有效地描述轴承的性能退化。图中横坐标表示时间，单位为day；纵坐标表示幅值，幅值的量纲为1。

[0058] 参照图6所示，采用本发明方法预测滚动轴承的故障，预测结果与滚动轴承故障实际发展趋势相吻合。训练样本为第7到第28天内的1848个综合监测指标值，即训练样本全部来自滚动轴承正常工作阶段。测试样本为第28到第35天内的616个综合指标值，即测试样本来自滚动轴承正常阶段，微弱故障阶段和故障逐渐演化为失效阶段。图中横坐标表示时间，单位为day；纵坐标表示幅值，幅值的量纲为1。

[0059] 本发明按以下步骤实施：

[0060] 步骤1：提取滚动轴承振动信号的多个时域统计特征量，并采用提取的时域统计特征量构造一个多维非线性特征向量；利用局部线性嵌入方法对多维非线性特征向量进行融合，得到映射矩阵，取映射矩阵特征值中，按从小到大排序的第2个特征值对应的特征向量作为综合监测指标，来更好地定量地评估轴承的性能退化；

[0061] 步骤1的具体过程为：

[0062] 步骤1.1：采集滚动轴承振动加速度信号，提取振动加速度信号的6个时域统计特征量，分别为均方根值、峰峰值、峭度、脉冲指标、裕度指标和波形指标，组成一个6维特征向量；每个6维特征向量为一个样本点，本实施例中样本点数为3080；

[0063] 步骤1.2：计算每一个样本点 x_i 的近邻点， $x_i \in \mathbb{R}^D, D=6, i=1, 2, \dots, N, N$ 为样本点个数；将相对于样本点 x_i 欧式距离最近的K个样本点定义为样本点 x_i 的K个近邻点；K取12；

[0064] 步骤1.3：根据每个样本点的近邻点计算出局部重建权值矩阵W，使样本点的重建误差最小：

[0065] 定义成本函数 $\varepsilon(W)$ 用来测量重构误差, $\varepsilon(W)$ 为:

$$[0066] \min \varepsilon(W) = \sum_{i=1}^N \left| \mathbf{x}_i - \sum_{j=1}^K \mathbf{w}_{ij} \mathbf{x}_j \right|^2$$

[0067] 式中 $w_{ij}, j=1, 2, \dots, K$ 为第j个近邻点 x_j 到第i个样本点 x_i 之间的权重,且满足 $\sum_{j=1}^K w_{ij} = 1$;

[0068] 步骤1.4:根据得到的局部重建权值矩阵W,计算6维特征向量的低维表示Y,得到将所有6维原始空间上的观测样本点映射到内部全局坐标的低维向量 $y_i, y_i \in R^d, d$ 为本征维度;映射条件满足如下关系:

$$[0069] \min \varepsilon(Y) = \sum_{i=1}^N \left| \mathbf{y}_i - \sum_{j=1}^K \mathbf{w}_{ij} \mathbf{y}_j \right|^2 = \text{tr}(\mathbf{Y}^T \mathbf{M} \mathbf{Y})$$

[0070] 且满足条件

$$[0071] \begin{cases} \sum_{i=1}^N \mathbf{y}_i = \mathbf{0} \\ \frac{1}{N} \sum_{i=1}^N \mathbf{y}_i^T \mathbf{y}_i = \mathbf{I} \\ \mathbf{M} = (\mathbf{I} - \mathbf{W})^T (\mathbf{I} - \mathbf{W}) \end{cases}$$

[0072] 其中 $\varepsilon(Y)$ 为损失函数值, y_i 是 x_i 在低维空间上的输出向量, y_j 是 y_i 的近邻点, $\text{tr}(\cdot)$ 为矩阵求迹运算符, I 为 $N \times N$ 的单位矩阵, M 为稀疏对称半正定的映射矩阵;损失函数 $\varepsilon(Y)$ 是向量 y_i 的一个二元方的形式,为简化,可以通过求解稀疏矩阵的特征向量求解最小值,即求解最小化损失函数 $\varepsilon(Y)$ 的问题可以转化为求解对称矩阵M的特征值问题;

[0073] 步骤1.5:计算映射矩阵M的特征值,将M的特征值从小到大排列,舍去第1个几乎接近于零的特征值,取映射矩阵特征值中,按从小到大排序的第2个特征值对应的特征向量作为综合监测指标。

[0074] 步骤2:采集滚动轴承正常工作阶段的综合监测指标值作为训练样本,逐层训练连续受限玻尔兹曼机,进而构造连续深度置信网络模型;

[0075] 采用连续受限玻尔兹曼机逐层构造连续深度置信网络模型过程为:

[0076] 步骤2.1:连续受限玻尔兹曼机由可视层和隐含层组成,可视层接受输入的综合监测指标值;为了更好地建模振动数据,连续受限玻尔兹曼机的可视层中通过添加零均值的高斯噪声引入连续随机单元;取 h_t 为隐单元t的状态, v_p 表示输入的可视单元p的状态,有:

$$[0077] h_t = \varphi_t \left(\sum_t \omega_{pt} v_p + \sigma \cdot N_t(0, 1) \right)$$

$$[0078] \varphi_t(x) = \theta_L + (\theta_H - \theta_L) \cdot \frac{1}{1 + \exp(-a_t x)}$$

[0079] 其中 $N_t(0, 1)$ 表示零均值、单位方差的高斯随机变量,常数 σ 和 $N_t(0, 1)$ 共同产生了一个噪声输入分量 $n_t = \sigma \cdot N_t(0, 1)$, σ 取 $0.2 \sim 0.5$; ω_{pt} 为连续受限玻尔兹曼机模型中可视单元p与隐单元t之间的连接权值; $\varphi_t(x)$ 是渐近线在 θ_L 和 θ_H 处的Sigmoid函数,其中 $\theta_L = 0, \theta_H = 1$,参数 a_t 为噪声控制变量,控制Sigmoid曲线的斜率,当 a_t 由小变大时,可以完成从无噪声的确定性状态到二进制随机状态的平滑过渡;

[0080] 采用一步重构的最小化对比散度算法训练连续受限玻尔兹曼机,模型的权值 ω_{pt}

和噪声控制参数 a_t 的更新公式为:

$$[0081] \Delta \omega_{pt} = \eta_\omega (\langle v_{ph} \rangle - \langle v'_{ph} \rangle)$$

$$[0082] \Delta a_t = \frac{\eta_a}{a_t^2} (\langle h_t^2 \rangle - \langle h_t'^2 \rangle)$$

[0083] 式中 $h'_{\cdot t}$ 为隐单元t的一步重构状态, $\langle \cdot \rangle$ 为训练数据的期望, η_ω 和 η_a 为学习率,取值为0.01~0.5;

[0084] 步骤2.2:重复步骤2.1操作3次,依次得到3个连续受限玻尔兹曼机模型,逐层堆叠连续受限玻尔兹曼机模型构建连续深度置信网络模型:第一个连续受限玻尔兹曼机模型的输入为综合监测指标值,第二个连续受限玻尔兹曼机模型的输入为第一个连续受限玻尔兹曼机模型的输出,第三个连续受限玻尔兹曼机模型的输入为第二个连续受限玻尔兹曼机模型的输出。

[0085] 步骤2.3:采用遗传算法来优化连续深度置信网络模型的结构,进一步提升预测性能。待优化的模型参数有3个,分别为3个隐含层的神经元数 l_1 、 l_2 和 l_3 ,其中 $l_1 \in [1, 20]$ 、 $l_2 \in [1, 40]$ 、 $l_3 \in [1, 20]$;具体的优化过程包括以下步骤:

[0086] 步骤2.3.1:给定一组 l_1 、 l_2 和 l_3 的初始值 $l_1=10$, $l_2=10$, $l_3=10$,根据试验任务设置种群规模 $N_1=40$ 、最大迭代次数 $T_1=80$ 、交叉概率 $p_c=0.8$ 和变异概率 $p_m=0.033$,种群中的每一个个体表示一种网络结构;

[0087] 步骤2.3.2:提供一组训练样本给连续深度置信网络的可视层,训练连续深度置信网络模型,用测试样本检验模型预测性能,计算预测误差,预测误差的指标为均方根误差;所述训练样本为滚动轴承正常工作阶段的综合监测指标值,所述测试样本为滚动轴承微弱故障阶段和完全失效阶段的综合监测指标值;

[0088] 步骤2.3.3:以均方根误差作为目标函数,根据目标函数确定遗传算法的适应度函数,计算每个个体的适应度;

[0089] 步骤2.3.4:对当前种群进行遗传操作,产生新的种群,遗传操作包括选择、交叉和变异;

[0090] 步骤2.3.5:判断遗传算法是否达到最大迭代次数。若满足,则结束优化,若不满足,返回步骤2.3.2。

[0091] 步骤3:采用连续深度置信网络模型预测滚动轴承未来的工作状态。

[0092] 实施例1:

[0093] 由混沌Mackey-Glass差分延迟方程产生一个非线性、非平稳的时间序列 $x(t)$,来验证本发明方法在分析和表述非线性、非平稳信号时的有效性:

$$[0094] \frac{dx(t)}{dt} = \frac{ax(t-\tau)}{1+x^{10}(t-\tau)} - bx(t)$$

[0095] 本算例中,设置初始条件为 $a=0.25$, $b=0.1$, $x(0)=0.6$, $\tau=56$ 。获取550个数据点的仿真信号如图2所示,幅值的量纲为1,其中前500个点作为训练样本,后50个点作为测试样本。

[0096] 采用连续深度置信网络方法预测仿真信号中最后50个数据点,预测结果参照图3所示。由此可见,本发明提出的方法,其预测值与真实值非常接近,能有效用于非线性、非平稳信号的分析和表达。

[0097] 实施例2:

[0098] 本例中,采用美国宇航局的预测数据库中的滚动轴承全寿命监测数据来验证本发明法在滚动轴承故障预测中的准确性。实验装置为四个轴承安装于一个轴上,并有一个直流电机驱动,转速维持在2000rpm,轴上径向负载6000磅。轴承为Rexnord ZA-115双列轴承,轴承每列有16个滚动体,直径0.311英寸,节径2.815英寸,接触角15.17°。每个轴承上都有两个垂直安置的PCB 353B33高灵敏度加速度传感器,采集振动加速度信号,振动数据采用NI公司的DAQCard-6062E采集卡每隔20分钟采集一次。数据的采样频率为20kHz,每一次采样的数据长度为20480点。

[0099] 图4为3号滚动轴承全寿命振动信号,总共46200000个数据点。将全寿命振动信号进行分段时域特征提取,每一段含15000个数据点,依次提取每一段振动信号的6种时域特征量,分别为均方根值、峰峰值、峭度、脉冲指标、裕度指标和波形指标,每一种特征的数据点数为3080。将这个6种特征组成一个6维特征向量,采用局部线性嵌入(LLE)方法融合所提取的时域特征信息,从而定义一个含3080个数据点的综合监测指标如图5所示,用于更好地定量地评估滚动轴承的性能退化。其中,局部线性嵌入方法中的参数K=12。

[0100] 构建含3个隐含层的连续深度置信网络模型,预测的回归步长选择经验值5,即连续深度置信网络预测模型的输入层神经元数为5。 $\eta_{\omega}=0.01$, $\eta_a=0.025$, $\sigma=0.5$, $\theta_L=0$, $\theta_H=1$ 。训练样本为第7到第28天内的1848个综合监测指标值,即训练样本全部来自滚动轴承正常工作阶段。测试样本为第28到第35天内的616个综合指标值,即测试样本来自滚动轴承正常阶段,微弱故障阶段和故障逐渐演化为失效阶段。采用遗传算法优化模型结构,以RMSE为目标函数,给定初始网络结构, $l_1=10$, $l_2=10$, $l_3=10$,设置种群规模 $N_1=40$,最大迭代次数 $T_1=80$,交叉概率 $p_c=0.8$,变异概率 $p_m=0.033$,最终,本发明的连续深度置信网络模型的结构被优化为“5-32-15-9-1”,即网络模型总共有5层,分别为1个输入层,3个隐含层和1个输出层,3个隐含层的神经元数依次为32,15和9。采用该预测模型来预测3号轴承的故障发展趋势,预测结果如图6所示。表1给出了人工神经网络和本发明方法的预测对比结果,其中RMSE为均方根误差,NRMSE为标准均方根误差,MAE为平均绝对误差,CORR为相关系数,它们都是常用的预测性能评价指标。由表1可见,用本发明提出的方法,预测性能更好,而人工神经网络的预测结果则与真实值有较大误差。因此,本发明提出的方法,其预测结果与滚动轴承故障实际发展趋势相吻合,能有效解决滚动轴承状态检测和故障预测。

[0101] 表1预测结果对比

[0102]

预测方法	预测性能评价指标			
	RMSE	NRMSE	MAE	CORR
本发明方法	0.0120	0.2767	0.0085	0.9364
人工神经网络	0.0290	0.6664	0.0177	0.7146

[0103] 尽管上面已经示出和描述了本发明的实施例,可以理解的是,上述实施例是示例性的,不能理解为对本发明的限制,本领域的普通技术人员在不脱离本发明的原理和宗旨的情况下在本发明的范围内可以对上述实施例进行变化、修改、替换和变型。

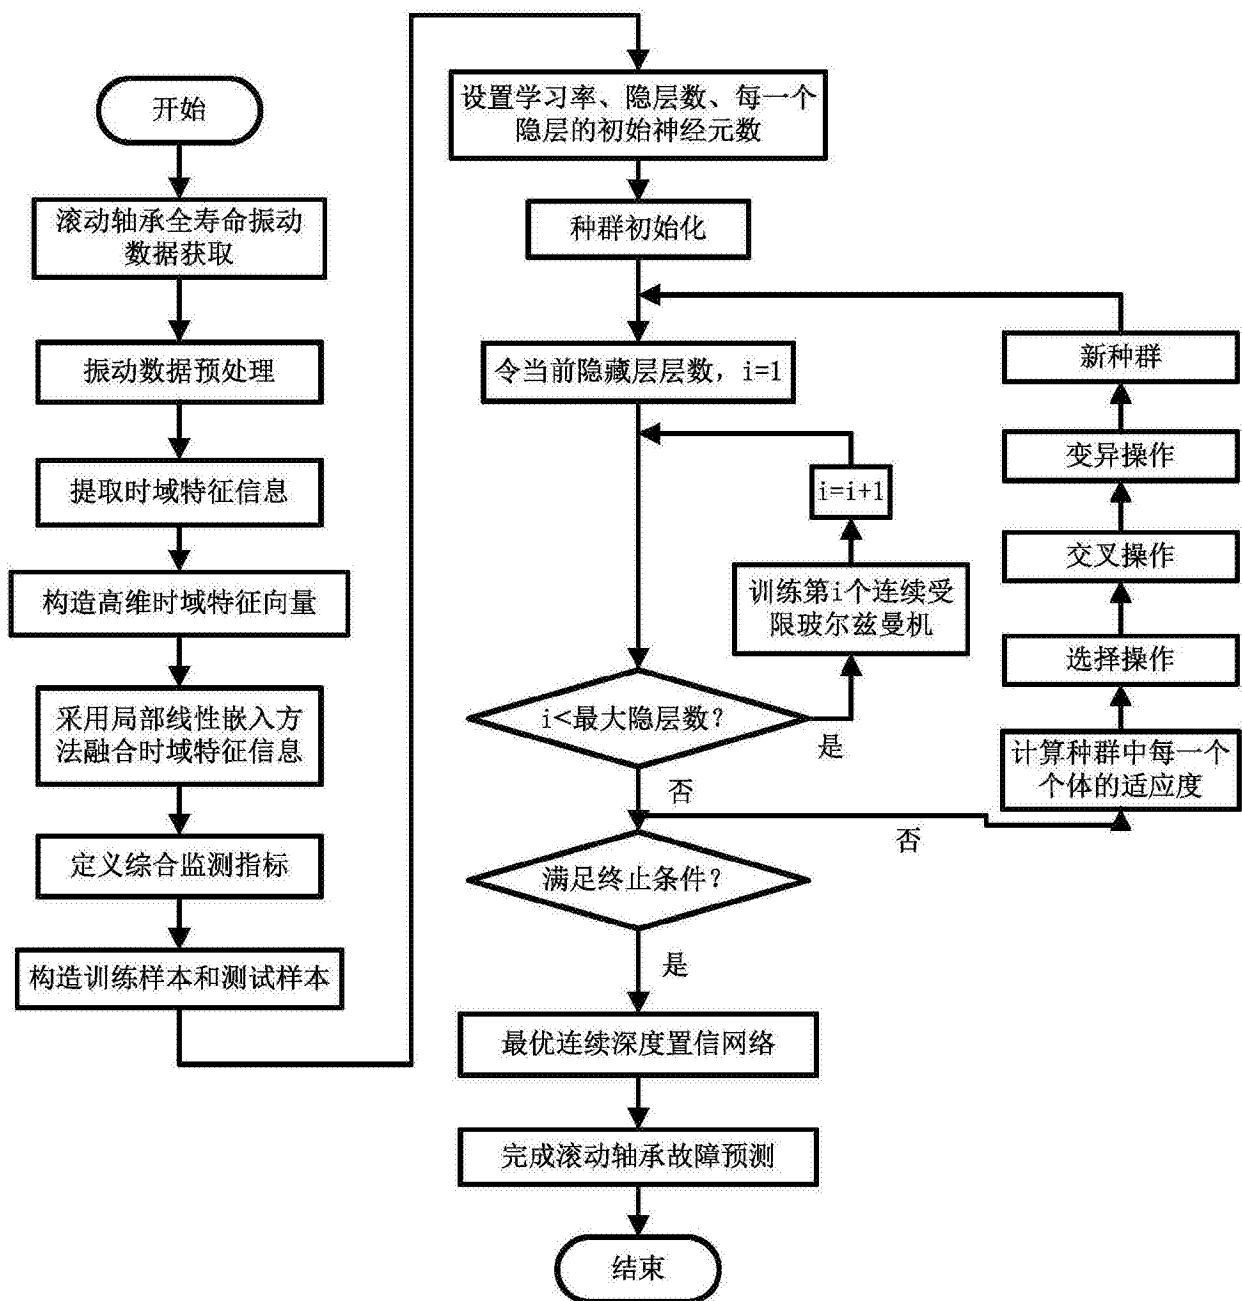


图1

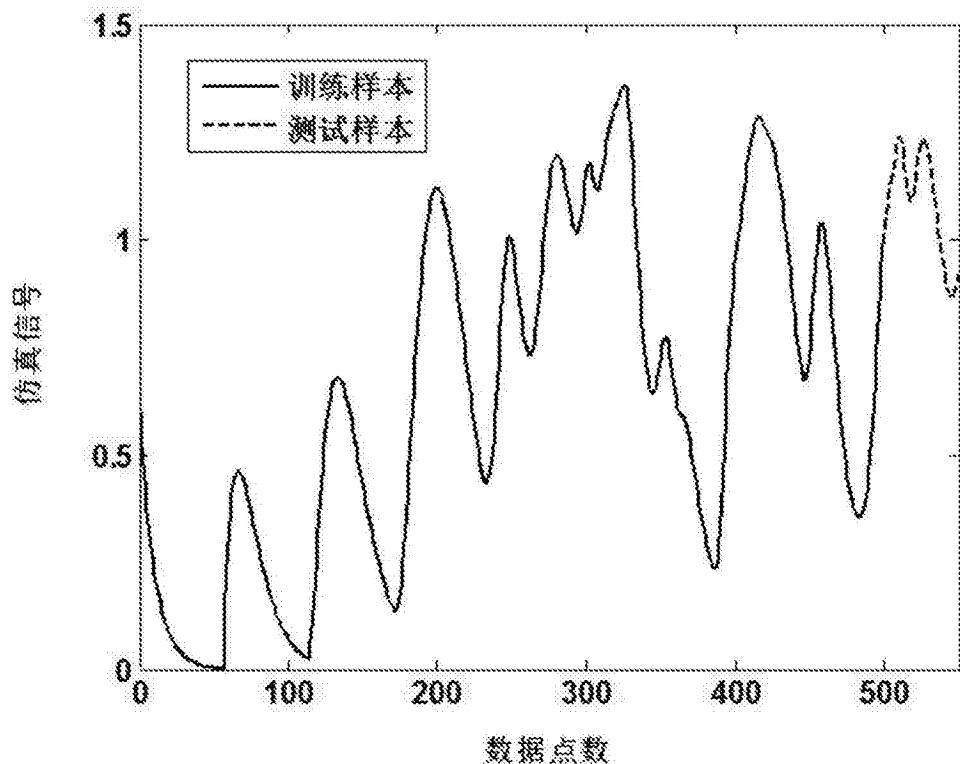


图2

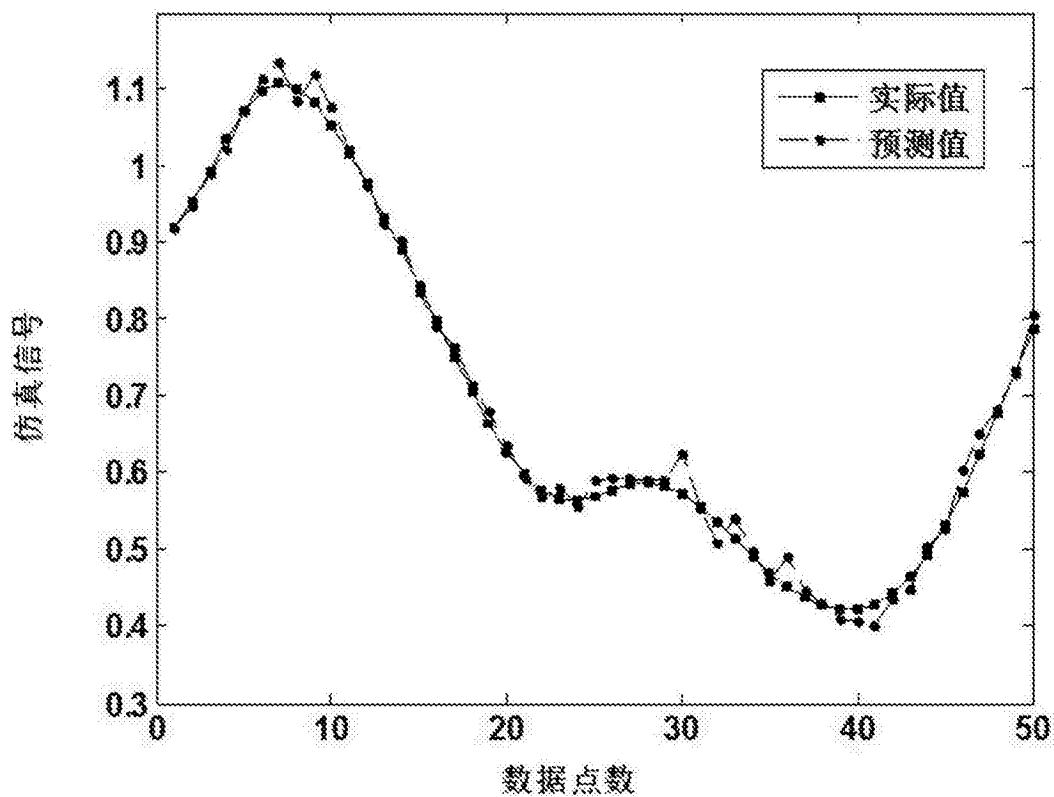


图3

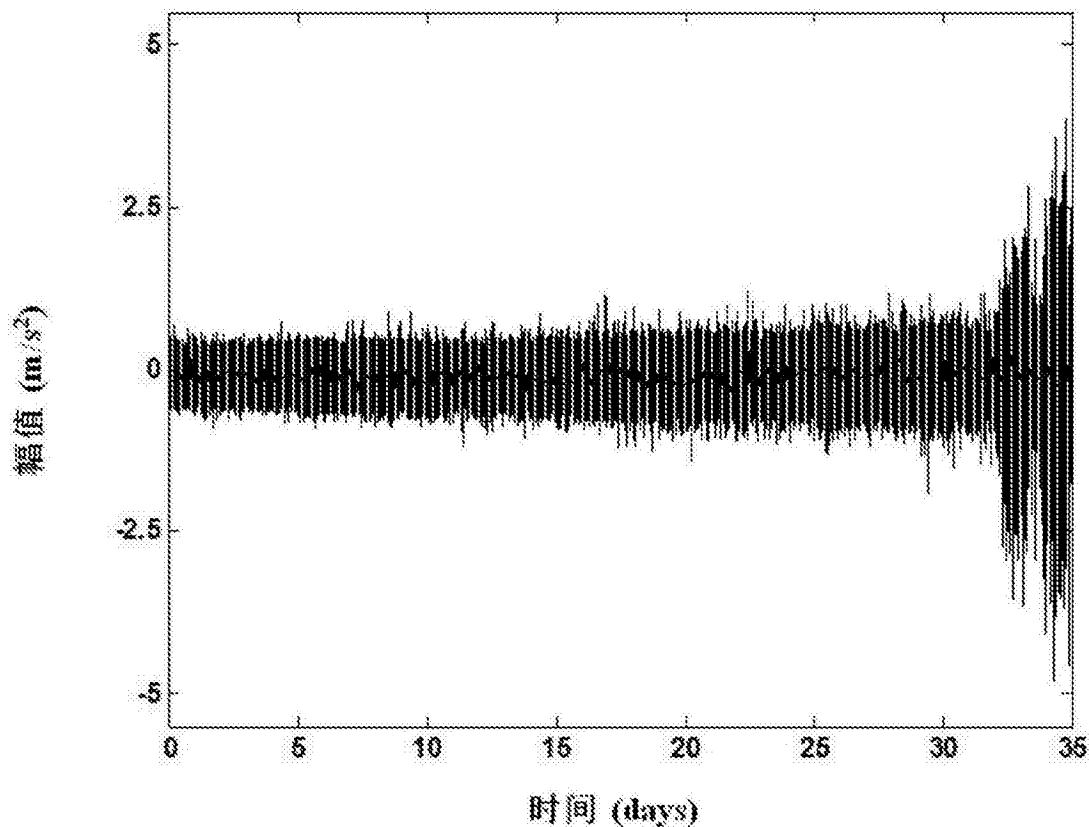


图4

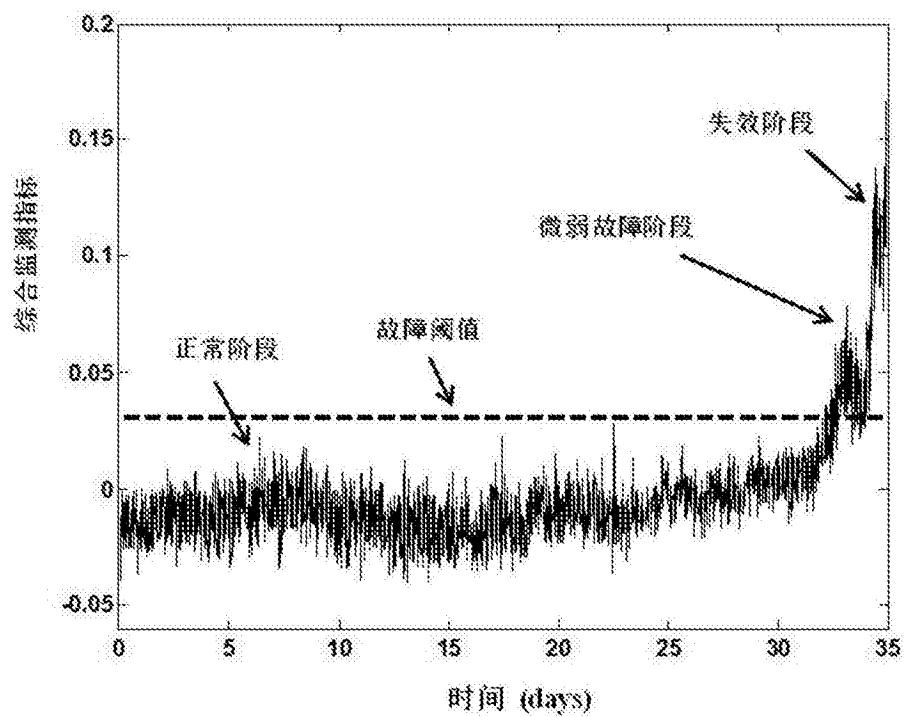


图5

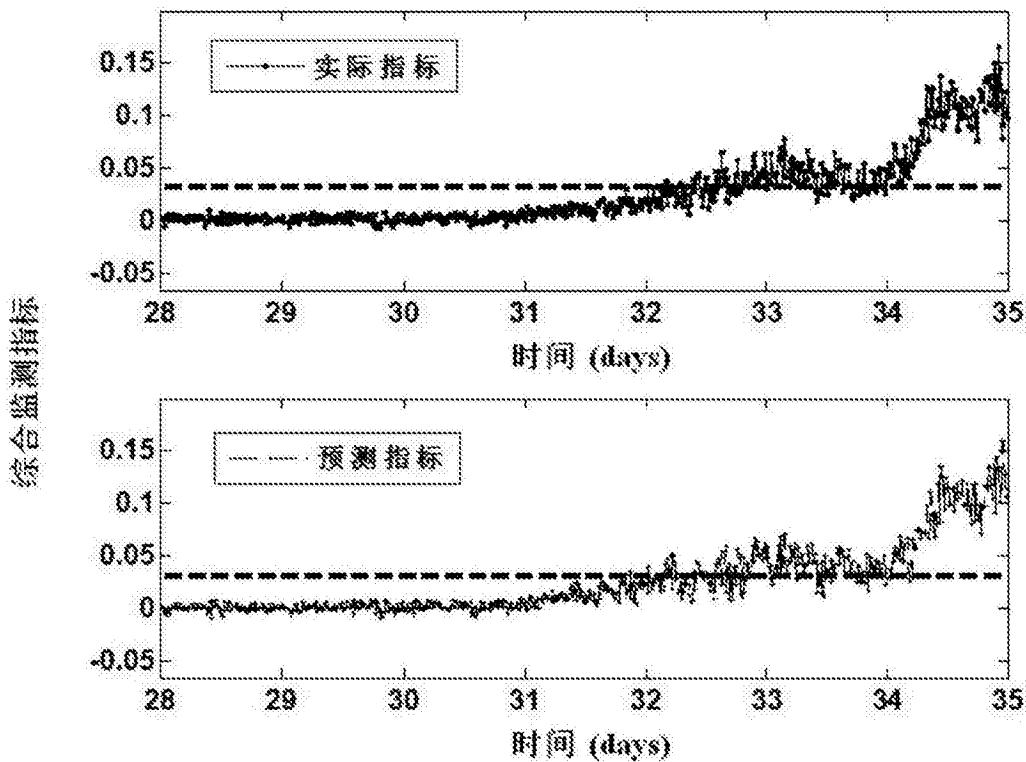


图6