



(12) 发明专利申请

(10) 申请公布号 CN 113158366 A

(43) 申请公布日 2021.07.23

(21) 申请号 202110401479.X

G06F 119/10 (2020.01)

(22) 申请日 2021.04.14

(71) 申请人 合肥工业大学

地址 230009 安徽省合肥市包河区屯溪路
193号

(72) 发明人 陈剑 曹昆明

(74) 专利代理机构 上海光华专利事务所(普通
合伙) 31219

代理人 林凡燕

(51) Int. Cl.

G06F 30/17 (2020.01)

G06F 30/27 (2020.01)

G06N 3/04 (2006.01)

G06N 3/08 (2006.01)

G01M 13/045 (2019.01)

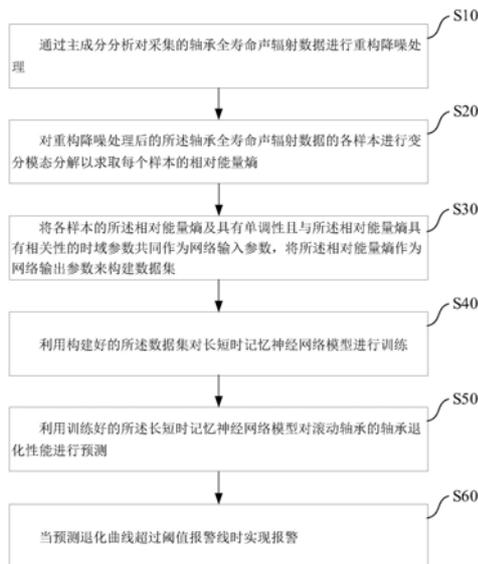
权利要求书2页 说明书12页 附图10页

(54) 发明名称

基于运行状态声辐射信号的轴承监测方法、
系统及设备

(57) 摘要

本发明提供一种基于运行状态声辐射信号的轴承监测方法、系统及设备,该检测方法包括通过主成分分析对采集的轴承全寿命声辐射数据进行重构降噪处理;对重构降噪处理后的轴承全寿命声辐射数据的各样本进行变分模态分解以求取每个样本的相对能量熵;将各样本的相对能量熵及具有单调性且与相对能量熵具有相关性的时域参数共同作为网络输入参数,将相对能量熵作为网络输出参数来构建数据集;利用数据集对长短时记忆神经网络模型进行训练;利用训练好的长短时记忆神经网络模型对滚动轴承的轴承退化性能进行预测。本发明构建了一种能够监测滚动轴承性能退化状态的指标,避免了时域指标在正常运行状态波动较大越过预警线导致误报的缺点。



1. 一种基于运行状态声辐射信号的轴承监测方法,其特征在于,包括:
通过主成分分析对采集的轴承全寿命声辐射数据进行重构降噪处理;
对重构降噪处理后的所述轴承全寿命声辐射数据的各样本进行变分模态分解以求取每个样本的相对能量熵;
将各样本的所述相对能量熵及具有单调性且与所述相对能量熵具有相关性的时域参数共同作为网络输入参数,将所述相对能量熵作为网络输出参数来构建数据集;
利用构建好的所述数据集对长短时记忆神经网络模型进行训练;
利用训练好的所述长短时记忆神经网络模型对滚动轴承的轴承退化性能进行预测。
2. 根据权利要求1所述的基于运行状态声辐射信号的轴承监测方法,其特征在于,所述监测方法还包括:
对重构降噪处理后的所述轴承全寿命声辐射数据的各样本进行变分模态分解以求取每个样本的第一相对能量熵;
对所述第一相对能量熵进行平均移动滤波处理以获取第二相对能量熵;
将所述第二相对能量熵、具有单调性且与所述第二相对能量熵具有相关性的时域参数共同作为网络输入参数,将所述第二相对能量熵作为网络输出参数来构建数据集。
3. 根据权利要求1所述的基于运行状态声辐射信号的轴承监测方法,其特征在于,对重构降噪处理后的所述轴承全寿命声辐射数据的各样本进行变分模态分解以求取每个样本的相对能量熵的步骤包括:
选取重构降噪处理后的所述轴承全寿命声辐射数据中的一组正常声辐射数据样本进行变分模态分解,根据样本与分解模态分量间的最小谱相关系数与设定阈值作比较,以确定变分模态分解层数;
按照确定的变分模态分解层数对重构降噪处理后的所述轴承全寿命声辐射数据的各样本进行变分模态分解以求取每个样本的相对能量熵。
4. 根据权利要求1所述的基于运行状态声辐射信号的轴承监测方法,其特征在于,将各样本的所述相对能量熵及具有单调性且与所述相对能量熵具有相关性的时域参数共同作为网络输入参数,将所述相对能量熵作为网络输出参数来构建数据集的步骤中,所述具有单调性且与所述相对能量熵具有相关性的时域参数包括有效值、平均值、峰值、均方根及方差。
5. 根据权利要求1-4中任意一项所述的基于运行状态声辐射信号的轴承监测方法,其特征在于,利用训练好的长短时记忆神经网络模型对滚动轴承的轴承退化性能进行预测的步骤之后还包括,当预测退化曲线超过阈值报警线时实现报警的步骤。
6. 根据权利要求5所述的基于运行状态声辐射信号的轴承监测方法,其特征在于,选取前指定百分比的正常样本的所述相对能量熵,结合拉伊达法则确定所述阈值报警线。
7. 一种基于运行状态声辐射信号的轴承监测系统,其特征在于,所述监测系统包括:
数据预处理模块,用于通过主成分分析对采集的轴承全寿命声辐射数据进行重构降噪处理;
特征提取模块,用于对重构降噪处理后的所述轴承全寿命声辐射数据的各样本进行变分模态分解以求取每个样本的相对能量熵;
轴承状态监测模块,用于将各样本的所述相对能量熵及具有单调性且与所述相对能量

熵具有相关性的时域参数共同作为网络输入参数,将所述相对能量熵作为网络输出参数来构建数据集,利用所述数据集对长短时记忆神经网络模型进行训练,利用训练好的长短时记忆神经网络模型对滚动轴承的轴承退化性能进行预测。

8. 根据权利要求7所述的基于运行状态声辐射信号的轴承监测系统,其特征在于,所述监测系统还包括报警模块,用于当预测退化曲线超过阈值报警线时实现报警。

9. 一种电子设备,其特征在于,包括相互耦合的处理器和存储器,所述存储器存储有程序指令,当所述存储器存储的程序指令被所述处理器执行时实现权利要求1-6中任意一项所述的基于运行状态声辐射信号的轴承监测方法。

10. 一种存储介质,其特征在于,包括程序,当所述程序在计算机上运行时,使得所述计算机执行如权利要求1-6中任意一项所述的基于运行状态声辐射信号的轴承监测方法。

基于运行状态声辐射信号的轴承监测方法、系统及设备

技术领域

[0001] 本发明涉及滚动轴承性能退化健康监测技术领域,特别涉及一种基于运行状态声辐射信号的轴承监测方法、系统及设备。

背景技术

[0002] 滚动轴承是机械设备动力传递和运行支撑的关键部件,其工作状态正常与否直接影响设备的安全运行;一般来说,滚动轴承从正常到失效会经历正常运行、早期退化、中期退化、快速退化四个阶段。轴承性能状态的退化,会导致设备运行状态的不平稳,从而造成事故的发生。目前,以滚动轴承为关键部件的机械设备维修多以定期检查、故障事后维修为主,这种方式不仅需要耗费大量的经济和时间成本,而且运维效率相当低下。滚动轴承性能退化特征往往伴随着一系列故障类型的发生,致使滚动轴承故障程度不断加重,最终引起失效。当滚动轴承性能早期退化发生时,若能够利用某种模型对其性能退化趋势进行有效预测,寻找到轴承运行历史数据中的演变规律,就可以大幅度提高运维效率和制定经济的维修计划。因此,滚动轴承的性能退化趋势预测成为了当前研究的热点。

[0003] 目前,针对轴承故障分类及状态监测多是基于振动传感器采集的振动信号,而滚动轴承运行时辐射出的复杂声信号往往包含更加丰富的早期故障信息,设备发生故障时会在噪声变化中得到反映,同时,声学监测具有非接触测量、简便易行、不增加附加质量影响设备运行等特点。为了预测轴承的退化过程,首先要提取典型特征,一般通过时频域特征提取轴承退化特征指标,但对于时域特征,尺寸指标不仅与设备状态有关,还与运行条件(速度和负载)有关,而无量纲指标与机器状态有关,对负载和速度的变化不敏感。因此,需要构建一种指标能够有效反应轴承的退化特性。

[0004] 现有的基于轴承声辐射信号进行轴承故障诊断通常基于轴承声辐射信号设计的基于滤波、峭度、绝对值加低通滤波的包络解调、自相关、功率谱密度的诊断方法,使用该方法能够诊断出轴承故障;另一种是使用包络分析对轴承声辐射信号进行故障缺陷检测,对声信号的模式进行分析处理,可以对轴承初期缺陷进行良好监测;第三种是基于机器学习方法进行轴承故障诊断。前两种方法通常存在依赖原始数据,对于高速列车需要实时在线监测任务中,其传统故障分析方法无法应对,不能及时有效地进行在线监测;而第三种的机器学习方法虽然能够根据人工提取的特征识别轴承故障类型,但是浅层结构存在一定的局限性,限制了从输入中学习更高级、更抽象信息的能力,且对数据的抗噪声干扰能力较差,适用于轴承故障分类,针对于非平稳、非线性的滚动轴承声辐射信号进行趋势预测容易导致预测滞后现象发生。

发明内容

[0005] 鉴于以上所述现有技术的缺点,本发明的目的在于提供一种基于运行状态声辐射信号的轴承监测方法、系统及设备,用于解决现有技术中的滚动轴承机械性能退化监测不能有效地进行在线监测,以及针对于非平稳、非线性的滚动轴承声辐射信号进行趋势预测

容易导致预测滞后现象发生的技术问题。

[0006] 为实现上述目的及其他相关目的,本发明提供一种基于运行状态声辐射信号的轴承监测方法,包括:

[0007] 通过主成分分析对采集的轴承全寿命声辐射数据进行重构降噪处理;

[0008] 对重构降噪处理后的所述轴承全寿命声辐射数据的各样本进行变分模态分解以求取每个样本的相对能量熵;

[0009] 将各样本的所述相对能量熵及具有单调性且与所述相对能量熵具有相关性的时域参数共同作为网络输入参数,将所述相对能量熵作为网络输出参数来构建数据集;

[0010] 利用构建好的所述数据集对长短时记忆神经网络模型进行训练;

[0011] 利用训练好的所述长短时记忆神经网络模型对滚动轴承的轴承退化性能进行预测。

[0012] 在一可选实施例中,所述监测方法还包括:

[0013] 对重构降噪处理后的所述轴承全寿命声辐射数据的各样本进行变分模态分解以求取每个样本的第一相对能量熵;

[0014] 对所述第一相对能量熵进行平均移动滤波处理以获取第二相对能量熵;

[0015] 将所述第二相对能量熵、具有单调性且与所述第二相对能量熵具有相关性的时域参数共同作为网络输入参数,将所述第二相对能量熵作为网络输出参数来构建数据集。

[0016] 在一可选实施例中,对重构降噪处理后的所述轴承全寿命声辐射数据的各样本进行变分模态分解以求取每个样本的相对能量熵的步骤包括:

[0017] 选取重构降噪处理后的所述轴承全寿命声辐射数据中的一组正常声辐射数据样本进行变分模态分解,根据样本与分解模态分量间的最小谱相关系数与设定阈值作比较,以确定变分模态分解层数;

[0018] 按照确定的变分模态分解层数对重构降噪处理后的所述轴承全寿命声辐射数据的各样本进行变分模态分解以求取每个样本的相对能量熵。

[0019] 在一可选实施例中,将各样本的所述相对能量熵及具有单调性且与所述相对能量熵具有相关性的时域参数共同作为网络输入参数,将所述相对能量熵作为网络输出参数来构建数据集的步骤中,所述具有单调性且与所述相对能量熵具有相关性的时域参数包括有效值、平均值、峰值、均方根及方差。

[0020] 在一可选实施例中,利用训练好的长短时记忆神经网络模型对滚动轴承的轴承退化性能进行预测的步骤之后还包括,当预测退化曲线超过阈值报警线时实现报警的步骤。

[0021] 在一可选实施例中,选取前指定百分比的正常样本的所述相对能量熵,结合拉伊达法则确定所述阈值报警线。

[0022] 为实现上述目的及其他相关目的,本发明还提供一种基于运行状态声辐射信号的轴承监测系统,包括:

[0023] 数据预处理模块,用于通过主成分分析对采集的轴承全寿命声辐射数据进行重构降噪处理;

[0024] 特征提取模块,用于对重构降噪处理后的所述轴承全寿命声辐射数据的各样本进行变分模态分解以求取每个样本的相对能量熵;

[0025] 轴承状态监测模块,用于将各样本的所述相对能量熵及具有单调性且与所述相对

能量熵具有相关性的时域参数共同作为网络输入参数,将所述相对能量熵作为网络输出参数来构建数据集,利用所述数据集对长短时记忆神经网络模型进行训练,利用训练好的长短时记忆神经网络模型对滚动轴承的轴承退化性能进行预测。

[0026] 在一可选实施例中,所述监测系统还包括报警模块,用于当预测退化曲线超过阈值报警线时实现报警。

[0027] 为实现上述目的及其他相关目的,本发明还提供一种电子设备,包括相互耦合的处理器和存储器,所述存储器存储有程序指令,当所述存储器存储的程序指令被所述处理器执行时实现上述任意一项所述的基于运行状态声辐射信号的轴承监测方法。

[0028] 为实现上述目的及其他相关目的,本发明还提供一种存储介质,包括程序,当所述程序在计算机上运行时,使得所述计算机执行所述的基于运行状态声辐射信号的轴承监测方法。

[0029] 本发明的基于运行状态声辐射信号的轴承监测方法、系统及设备,将VMD-REE与LSTM网络模型相结合实现滚动轴承性能退化趋势预测,达到更早地判别和预测出滚动轴承早期故障的目的。

[0030] 本发明的基于运行状态声辐射信号的轴承监测方法、系统及设备,构建了一种能够监测滚动轴承性能退化状态的指标,该指标在轴承正常运行状态趋于平稳,避免了时域指标在正常运行状态波动起伏越过预警线导致误报的缺点。

[0031] 本发明的基于运行状态声辐射信号的轴承监测方法、系统及设备,通过对轴承声辐射信号进行变分模态分解构建相对能量熵作为滚动轴承性能退化指标,避免了浅层网络结构的局限性,充分发挥长短时记忆神经网络从输入中学习更高级、更抽象信息的能力,并解决了长短时记忆神经网络最优堆栈层数选取困难的问题。

[0032] 本发明的基于运行状态声辐射信号的轴承监测方法、系统及设备,去除不具有单调性或者单调性变化不明显的时域特征参数,再根据相关性准则,保留与退化指标相关性大的时域特征参数作为输入,退化指标作为输出,避免了单特征输入单特征输出趋势预测滞后性的发生。

[0033] 本发明的基于运行状态声辐射信号的轴承监测方法、系统及设备,以原有数据为基础设置预警线,能有效监测滚动轴承的异常指标变化,其方法简单,在不同工况下都具有很好地实践价值。

附图说明

[0034] 图1显示为本发明的一实施例的基于运行状态声辐射信号的轴承监测方法的流程图示意图。

[0035] 图2显示为本发明的一实施例的基于运行状态声辐射信号的轴承监测方法中步骤S10的子流程图。

[0036] 图3显示为本发明的一实施例的基于运行状态声辐射信号的轴承监测系统的结构框图。

[0037] 图4显示为本发明的一实施例的电子设备的结构框图。

[0038] 图5显示为本发明的一实施例的实现基于运行状态声辐射信号的轴承监测方法的设备框图。

- [0039] 图6显示为本发明的一实施例的轴承试验装置的结构框图。
- [0040] 图7a-7c分别显示为本发明的一实施例的轴承1-3的轴承全寿命声辐射信号数据图。
- [0041] 图8a-8b分别显示为本发明的一实施例的轴承2的轴承全寿命声辐射信号的第500组样本原始信号的时域图、频域图。
- [0042] 图9a-9b分别显示为本发明的一实施例的轴承2的轴承全寿命声辐射信号的第500组样本的重构降噪的时域图、频域图。
- [0043] 图10显示为本发明的一实施例的轴承2的轴承全寿命声辐射信号的各样本的相对能量熵数据图。
- [0044] 图11显示为本发明的一实施例的LSTM堆栈层数与均方根误差图。
- [0045] 图12显示为本发明的一实施例的测试集性能退化评估及预警图。

具体实施方式

[0046] 以下通过特定的具体实例说明本发明的实施方式,本领域技术人员可由本说明书所揭露的内容轻易地了解本发明的其他优点与功效。本发明还可以通过另外不同的具体实施方式加以实施或应用,本说明书中的各项细节也可以基于不同观点与应用,在没有背离本发明的精神下进行各种修饰或改变。

[0047] 请参阅图1-12。需要说明的是,本实施例中所提供的图示仅以示意方式说明本发明的基本构想,遂图示中仅显示与本发明中有关的组件而非按照实际实施时的组件数目、形状及尺寸绘制,其实际实施时各组件的型态、数量及比例可为一种随意的改变,且其组件布局型态也可能更为复杂。

[0048] 为了解决现有技术中的滚动轴承机械性能退化监测不能有效地进行在线监测,以及针对于非平稳、非线性的滚动轴承声辐射信号进行趋势预测容易导致预测滞后现象发生的技术问题,本实施例公开了一种基于运行状态声辐射信号的轴承监测方法,其是通过主成分分析对轴承声辐射信号进行去噪,对重构后的寿命样本进行变分模态分解(VMD)得到K层有限带宽固有模态函数(BLIMFs);对BLIMFs分量的能量进行相对能量熵分析,将平均滤波处理后的相对能量熵作为轴承性能退化评估指标,并采用拉伊达法则确定阈值作为预警线;使用堆栈的长短时记忆神经网络(LSTM)网络作为预测模型,根据相关性准则,选取多特征参数作为网络输入,退化评估指标作为输出;当预测退化曲线超过阈值报警线时实现报警。其中,图1示出了本发明的基于运行状态声辐射信号的轴承监测方法的流程示意图。

[0049] 现将结合图1来对本实施例的轴承故障分类方法的各步骤S10-S60作具体说明。

[0050] 首先,执行步骤S10、通过主成分分析对采集的轴承全寿命声辐射数据进行重构降噪处理,其中,轴承全寿命声辐射数据可通过设置于主轴轴承试验机上安装的GARS声音传感器采集轴承从初始运行至完全失效的全寿命数据。请参阅图2,数据预处理的过程可进一步包括步骤S11-S15。

[0051] 在步骤S11中,进行数据构建,假设有m个轴承,则采集的全寿命声辐射信号有m个: $X = (x_1, x_2, \dots, x_m)^T$,每个全寿命声辐射信号有n维数据 $x_i = \{x_i^1, x_i^2, \dots, x_i^n\}$,则m个轴承组成m*n维矩阵,对X求样本均值:

$$[0052] \quad U = \frac{1}{m} \sum_{i=1}^m x_i \quad (1-1)$$

[0053] 式中:U为样本均值。

[0054] 在步骤S12中,对X进行中心化处理得到矩阵 \bar{X} :

$$[0055] \quad \bar{X} = X - U \quad (1-2)$$

[0056] 在步骤S13中,求出矩阵 \bar{X} 的协方差V:

$$[0057] \quad V = \frac{1}{m} \bar{X} \bar{X}^T \quad (1-3)$$

[0058] 在步骤S14中,对协方差V进行特征分解,得到特征值 λ_i 和对应的特征向量 ω_i ;将特征值按从大到小的顺序排列,设置贡献率(例如0.95),根据方差贡献率选择其中K个特征值,对应的K个特征向量作为列向量组成特征向量矩阵,将样本点投影到选取的特征向量上。

[0059] 在步骤S15中,m个轴承减去均值后的矩阵为data(m*n),协方差矩阵是n*n维,选取的K个特征向量组成的矩阵为vector(n*K),那么投影后的数据为矩阵fdata由式1-4获取:

$$[0060] \quad fdata(m*K) = data(m*n) \times vector(n*K) \quad (1-4);$$

[0061] 投影后的矩阵乘以vector(n*K)的转置,再加上去中心化的均值U完成重构。

[0062] 接着,执行步骤S20、对重构降噪处理后的所述轴承全寿命声辐射数据的各样本进行变分模态分解以求取每个样本的相对能量熵。具体包括选取重构降噪处理后的所述轴承全寿命声辐射数据中的一组正常声辐射数据样本进行变分模态分解以确定变分模态分解层数的步骤(步骤S21)和按照确定的变分模态分解层数对重构降噪处理后的所述轴承全寿命声辐射数据的各样本进行变分模态分解以求取每个样本的相对能量熵的步骤(步骤S22)。

[0063] 步骤S21可进一步包括:

[0064] 步骤S211、对滚动轴承的重构降噪处理后的所述轴承全寿命声辐射数据中一个正常声辐射信号进行VMD分解得到k个BLIMF分量,根据公式(1-5)计算各BLIMF的谱相关系数: $\rho_1, \rho_2, \dots, \rho_k$,并找出其中的最小值 ρ_{\min} ,若小于设定阈值0.1,则确定最小分解层数 $k = k - 1$;否则令 $k = k + 1$,重复上述循环直到找到满足要求的k值,式中 $|U_k|$ 和 $|V|$ 分别为原始信号和第k个BLIMF分量的傅里叶变换的模;

$$[0065] \quad \rho_i = \frac{\sum_{j=1}^n |U_k| \cdot |V|}{\sqrt{\sum_{j=1}^n |U_k|^2 \cdot \sum_{i=1}^n |V|^2}} \quad (1-5)$$

[0066] 步骤S212、初始化 $\{u_k^1\}$, $\{\omega_k^1\}$, $\{\lambda^1\}$ 和 $n=0$;

[0067] 步骤S213、更新 u_k^{n+1} , ω_k^{n+1}

$$[0068] \quad u_k^{n+1}(\omega) = \frac{f(\omega) - \sum_{i \neq k} u_i(\omega) + \frac{\lambda(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2}$$

$$[0069] \quad \omega_k^{n+1} = \frac{\int_0^\infty \omega |u(\omega)|^2 d\omega}{\int_0^\infty |u(\omega)|^2 d\omega}$$

[0070] 步骤S214、由式 $\lambda^{n+1}(\omega) = \lambda^n(\omega) + \tau(f(\omega) - \sum u_k^{n+1}(\omega))$ 更新 $\lambda^{n+1}(\omega)$; (1-6)

[0071] 步骤S215、重复步骤S213-S214,直到满足条件 $\frac{\sum_k \|u_k^{n+1} - u_k^n\|_2^2}{\sum_k \|u_k^n\|_2^2} < \epsilon$, (其中 $\epsilon > 0$

为判别精度)则迭代停止,得到k个模态分量。

[0072] 步骤S22可进一步包括:

[0073] 步骤S221、选择一个滚动轴承全寿命声辐射信号,取前10组样本对其进行VMD分解至K层,获取10组K个BLIMFs分量的能量为 $E_{10} = \{E_{10}^1, E_{10}^2, \dots, E_{10}^K\}$;求其均值为 \bar{E}_{10} 。可以理解的是,步骤S221中,选取的样本数量可以根据需要进行合理选择,只要选取的样本为正常状态下的样本数据均可。

[0074] 步骤S222、对全寿命声辐射信号的全部样本都进行VMD分解,得到N组K个BLIMFs分量的能量值

[0075] $E_n = \{E_n^1, E_n^2, \dots, E_n^K\} (n = 1, 2, \dots, N)$;其中N表示一个全寿命轴承数据的总样本数。

[0076] 步骤S223、计算K个BLIMFs分量的总能量 $E^K = \bar{E}_{10} + \sum_{n=1}^N E_n$,

[0077] 步骤S224、根据公式计算相对能量熵(第一相对能量熵),公式如下:

$$[0078] \quad p_n^K = E_n^K / E^K \quad (1-7)$$

$$[0079] \quad q_{10}^K = E_{10}^K / E^K \quad (1-8)$$

$$[0080] \quad REE_n = \sum_{k=1}^K p_n^K \log \frac{p_n^K}{q_{10}^K} \quad (1-9)$$

[0081] 其中, $p_n, q_{10} (n = 1, 2, \dots, N)$ 为两个信号的概率分布。

[0082] 步骤S225、对求取的相对能量熵进行平均移动滤波处理,时间窗长取为10(也可以是其他合适的值),这既保留了原始数据的性质和趋势,又使原来相对特征序列变得平稳。

[0083] 步骤S226、对其余轴承全寿命声辐射信号进行同样处理。

[0084] 接着,执行步骤S30,构建数据集:将各样本的所述相对能量熵及具有单调性且与所述相对能量熵具有相关性的时域参数共同作为网络输入参数,将所述相对能量熵作为网络输出参数来构建数据集。具体地,从有效值、平均值、峰值、波峰因子、裕度因子、脉冲系数、形状系数、均方根、偏度、峭度、方差等时域特征中,去除不具有单调性或者单调性变化不明显的特征参数;再根据相关性准则,保留与相对能量熵相关性大的特征参数。最终,共筛选6个特征参数组成特征参数集,分别是有效值、平均值、峰值、均方根、方差、平均移动滤波后的相对能量熵作为网络输入参数,将平均移动滤波后的相对能量熵作为网络输出参数。可以理解的是,在其他实施例中,也可以是选取平均移动滤波后的相对能量熵和有效值、平均值、峰值、均方根、方差中的一个和多个时域特征参数作为网络输入参数。

[0085] 再接着,执行步骤S40,利用构建好的所述数据集对长短时记忆神经网络模型(LSTM模型)进行训练,进一步可包括步骤S41-S46。

[0086] 步骤S41、构建LSTM网络模型。LSTM网络模型前向传播具体公式如下:

$$[0087] \quad f_t = \sigma(W_{fh}h_{t-1} + U_{fx}x_t + b_f) \quad (1-10)$$

$$[0088] \quad i_t = \sigma(W_{ih}h_{t-1} + U_{ix}x_t + b_i) \quad (1-11)$$

$$[0089] \quad o_t = \sigma(W_{oh}h_{t-1} + U_{ox}x_t + b_o) \quad (1-12)$$

$$[0090] \quad \tilde{C}_t = \tanh(W_{\tilde{c}h}h_{t-1} + U_{\tilde{c}x}x_t + b_{\tilde{c}}) \quad (1-13)$$

$$[0091] \quad C_t = f_t * c_{t-1} + i_t * \tilde{C}_t \quad (1-14)$$

$$[0092] \quad h_t = o_t * \tanh(c_t) \quad (1-15)$$

[0093] 式中: f_t 、 i_t 、 o_t 分别是t时刻的遗忘门、输入门和输出门; c_t 、 h_t 、 x_t 分别是t时刻的单位状态、隐藏状态、单位输入; W 和 U 是隐藏状态和单位输入的权重。

[0094] 步骤S42、构建训练集、测试集。在LSTM预测模型中,将m个轴承的6个特征参数构成数据集,取前80%数据构造训练集,后20%构造测试集,时间窗沿样本序列连续滑动,截取指定长度的时间序列作为预测模型的输入 $[X_{t-1}, X_t, X_{t+1}]$,时间步长选为3,每个输入 X_t 为六维向量,也即用前三组数据预测第四组数据。

[0095] 步骤S43、按照式1-16将数据集进行归一化处理,数据归一化既可减少训练时间也可以防止网络的激活函数处于过饱和状态。

$$[0096] \quad X'_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (1-16)$$

[0097] 式中, X'_i 为归一化值、 X_i 为样本值、 X_{\max} 为样本最大值、 X_{\min} 为样本最小值。

[0098] 步骤S44、设置网络模型参数。在一具体示例中,网络采用小批量输入,每次输入样本数量为mini-batch为20,网络训练采用250次epochs迭代训练计算,初始学习率为0.005。采用均方误差作为损失函数,adam优化器用于更新LSTM网络中的权重和偏差。

[0099] 步骤S45、网络堆栈层数的选取。在一具体示例中,使用训练集来选取最优堆栈层数,设置循环结构(最高循环次数为6),每一层的神经元个数均设为200,若均方根误差(RMSE)小于设定阈值0.04,则确定堆栈层数K,否则 $K=K+1$,重复循环,直至循环结束。

[0100] 步骤S46、确定堆栈层数后,用训练集对网络进行训练,用测试集进行预测。去归一化,求出预测值与真实值之间的均方误差(MSE)、平均绝对误差(MAE)、均方根误差(RMSE)、相关系数(R^2)值。

[0101] 再接着,执行步骤S50、利用训练好的所述长短时记忆神经网络模型对滚动轴承的轴承退化性能进行预测。

[0102] 最后,执行步骤S60、当预测退化曲线超过阈值报警线时实现报警,其中,选取前指定百分比的正常样本的所述相对能量熵,结合拉伊达法则确定所述阈值报警线。具体地,采用拉伊达法则确定报警阈值,即数学期望之差的绝对值大于3倍标准差,取相对能量熵前10%样本数据,计算其数学期望 \bar{x} ;计算相对能量熵前10%样本数据的标准差 δ ; $3\delta + \bar{x}$ 的值即为阈值报警线。采用这种方式确定的阈值报警线有99.73%概率将异常数据点判定为异常数据,避免了阈值选取的主观性。

[0103] 请参阅图3,本实施例还公开一种实现基于运行状态声辐射信号的轴承监测方法

的基于运行状态声辐射信号的轴承监测系统1,所述基于运行状态声辐射信号的轴承监测系统1包括数据预处理模块11、特征提取模块12、轴承状态监测模块13以及报警模块14。所述数据预处理模块11用于通过主成分分析对采集的轴承全寿命声辐射数据进行重构降噪处理;所述特征提取模块12用于对重构降噪处理后的所述轴承全寿命声辐射数据的各样本进行变分模态分解以求取每个样本的相对能量熵;所述轴承状态监测模块13用于将各样本的所述相对能量熵及具有单调性且与所述相对能量熵具有相关性的时域参数共同作为网络输入参数,将所述相对能量熵作为网络输出参数来构建数据集,利用所述数据集对长短时记忆神经网络模型进行训练,利用训练好的长短时记忆神经网络模型对滚动轴承的轴承退化性能进行预测;所述报警模块14用于当预测退化曲线超过阈值报警线时实现报警。

[0104] 需要说明的是,本发明的基于运行状态声辐射信号的轴承监测系统1是与上述基于运行状态声辐射信号的轴承监测方法相对应的系统,基于运行状态声辐射信号的轴承监测系统1中的功能模块分别对应基于运行状态声辐射信号的轴承监测方法的相应步骤。本发明的基于运行状态声辐射信号的轴承监测系统1可与基于运行状态声辐射信号的轴承监测方法相互相配合实施。本发明的基于运行状态声辐射信号的轴承监测方法中提到的相关技术细节在基于运行状态声辐射信号的轴承监测系统1中依然有效,为了减少重复,这里不再赘述。相应地,本发明的基于运行状态声辐射信号的轴承监测系统1中提到的相关技术细节也可应用在上述基于运行状态声辐射信号的轴承监测方法中。

[0105] 需要说明的是,上述的各功能模块实际实现时可以全部或部分集成到一个物理实体上,也可以物理上分开。且这些单元可以全部以软件通过处理元件调用的形式实现;也可以全部以硬件的形式实现;还可以部分单元通过处理元件调用软件的形式实现,部分单元通过硬件的形式实现。此外这些单元全部或部分可以集成在一起,也可以独立实现。这里所述的处理元件可以是一种集成电路,具有信号的处理能力。在实现过程中,上述方法的部分或全部步骤,或以上的各功能模块可以通过处理器元件中的硬件的集成逻辑电路或者软件形式的指令完成。

[0106] 需要说明的是,如图4所示,本实施例的基于运行状态声辐射信号的轴承监测系统还可以通过一电子设备2来实现,所述电子设备2包括包括相互连接的存储器23和处理器21,所述存储器23存储有程序指令,该程序指令被所述处理器212执行时实现上述的基于运行状态声辐射信号的轴承监测方法。需要说明的是,当需要和外部进行通信时,所述电子设备还包括通信器22,所述通信器22与所述处理器21连接。

[0107] 上述的处理器21可以是通用处理器,包括中央处理器(Central Processing Unit,简称CPU)、网络处理器(Network Processor,简称NP)等;还可以是数字信号处理器(Digital Signal Processing,简称DSP)、专用集成电路(Application Specific Integrated Circuit,简称ASIC)、现场可编程门阵列(Field-Programmable Gate Array,简称FPGA)或者其他可编程逻辑器件、分立门或者晶体管逻辑器件、分立硬件组件;上述的存储器23可能包含随机存取存储器(Random Access Memory,简称RAM),也可能还包括非易失性存储器(Non-Volatile Memory),例如至少一个磁盘存储器。

[0108] 需要说明的是,上述存储器23中的计算机程序可以通过软件功能单元的形式实现并作为独立的产品销售或使用,可以存储在一个计算机可读存储介质中。基于这样的理解,本发明的技术方案本质上或者说对现有技术做出贡献的部分或者该技术方案的部分可

以软件产品的形式体现出来,该计算机软件产品存储在一个存储介质中,包括若干指令用以使得一台计算机设备(可以是个人计算机,电子设备,或者网络设备等)执行本发明各个实施例方法的全部或部分步骤。

[0109] 本实施例还公开一种存储介质,其存储有程序,该程序被处理器21执行时实现上述的基于运行状态声辐射信号的轴承监测方法;所述存储介质包括所有形式的非易失性存储器、介质和存储器设备,包括例如:半导体存储器设备,例如EPROM、EEPROM和闪存设备;磁盘,例如内部硬盘或可移动盘;磁光盘;以及CD-ROM和DVD-ROM盘。

[0110] 下面将结合一个具体示例来验证本实施例的基于运行状态声辐射信号的轴承监测方法。

[0111] 图5示出了实现基于运行状态声辐射信号的轴承监测方法的设备框图,包括主轴轴承试验平台3、信号采集装置4以及信号分析处理器5三个部分,其中,信号采集装置4包括GARS声传感器41和LMS SCADAS XS数据采集仪42组成;如图6所示,所述轴承试验装置3由轴承试验主机31、冷却站34、加载站32和润滑站33等配套设备构成。

[0112] 实验数据来自合肥工业大学航空发动机主轴轴承试验机上的声音传感器采集的轴承寿命实验数据,轴承选用NU1010,其详细参数如表1所示。实验工况为:转速2000rpm、加载25KN、以20480Hz的采样频率每隔3min采集一次声信号,采样时间1s。每组信号包含20480个数据点,试验结束后拆卸检验,发现滚动轴承严重损坏。在同一实验条件下共采集了三个轴承从正常运行到失效的轴承性能退化过程数据,轴承实验数据如表2。

[0113] 表1轴承NU1010的参数

轴承型号	内径 (mm)	外径 (mm)	节径 (mm)	滚动体 个数	滚动体 直径 (mm)	额定动 载荷 (KN)	额定静 载荷 (KN)	接触角 (°)
NU1010	50	80	65	20	φ7.5	32	36	0

[0115] 表2轴承实验数据

实验轴承	数据采集	样本数(个)	时间跨度 (h)
轴承 1	声采集	347	17.35
轴承 2	声采集	937	46.85
轴承 3	声采集	565	28.25

[0117] 实验轴承1-3的全寿命声辐射信号幅值图如图7a-7c所示。采集的全寿命声辐射信号每组样本包含20480个数据点,在数据处理时每10个数据点取一个,即每组样本包含2048个数据点,从图6可以看出轴承从稳定运行到缓慢退化、直至快速退化的过程。

[0118] 为了验证降噪效果,选取轴承2为研究对象,对所有样本进行主成分分析并重构,采样率为12000,采样点数为2048,图8a、8b为轴承2第500组样本原始信号的时域图、频域图,图9a、9b为降噪后的时域图、频域图,从图中可以看出部分高频的噪声被去除,原始信号主要信息被保留。

[0119] 取轴承2前期正常信号样本,计算VMD分解各模态分量和原始信号的谱相关系数,

结果如表3所列,阈值为0.1,确定VMD分解层数 $K=4$,得到4个IMF分量,由公式计算出相对能量熵如图10所示,在正常运行阶段曲线平稳,在快速退化阶段曲线波动的幅度太大,由于故障原因信号随机性较大,现对特征指标进行处理,采用均匀移动平均滤波的进行光滑处理,时间窗长取为10,从图10中可以看出光滑处理后既保留了原始数据的性质和趋势,又使原来相对特征序列变得平稳。

[0120] 表3各模态分量与原始信号的谱相关系数

层数	谱相关系数 (第 250 组正常样本)				
	ρ_1	ρ_2	ρ_3	ρ_4	ρ_5
K					
1	0.9198				
2	0.9194	0.1763			
[0121] 3	0.9189	0.1975	0.1245		
4	0.9072	0.3499	0.1608	0.1094	
5	0.9068	0.3482	0.1708	0.1375	0.0968

[0122] 在LSTM预测模型中,将轴承1、轴承3、轴承2这三个轴承的6个特征参数构成数据集,前80%构造训练集,后20%构造测试集,采用滚动预测的方法,时间步长选为3,即用前三个数据去预测第四个数据,每个输入 X_t 为六维向量。将数据集进行归一化处理,网络采用小批量输入,每次输入样本数量mini-batch为20,使用训练集来选取最优堆栈层数如图11所示,阈值设置0.04,图中可以看出当堆栈层数为3时,均方根误差(RMSE)达到最小,且在阈值线以内,当堆栈层数继续增大时,RMSE变化波动不大,也在阈值线以内,证明LSTM网络堆栈层数不是越大越好。

[0123] 选用三个LSTM层以学习输入时间序列中隐藏的深度信息,LSTM层神经元的个数均为200。网络训练采用250次epochs迭代训练计算,初始学习率为0.005。采用均方误差作为损失函数,ADAM优化器用于更新LSTM网络中的权重和偏差。

[0124] 性能退化预测结果如图12所示。图中可以看出预测曲线在早期退化阶段超过预警线,可以很好的实现报警。从图12可以看出前124组样本几乎没有变化判断为正常运行样本,在125-222组样本出现细微波动,判断为早期轻微退化状态,此时轴承还可以继续使用,在223-271组样本之后波动较大判定为中期退化,在272组样本之后出现急剧增大的现象,判定为快速退化并趋于失效。

[0125] 该网络模型测试集产生的均方误差(MSE)、平均绝对误差(MAE)、均方根误差(RMSE)、相关系数(R^2)如表4所示,相关系数 R^2 越接近于1,模型的拟合程度越高,效果越好。从表中可以看出堆栈LSTM网络模型的MSE、MAE、RMSE最低,且 R^2 最高。堆栈LSTM在测试集中的相关系数为0.7533,在中期退化之前的相关系数为0.9157。

$$[0126] \quad MSE = \frac{1}{n} \sum_{i=1}^n (y_i' - y_i)^2 \quad (3-2)$$

$$[0127] \quad RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i' - y_i)^2} \quad (3-3)$$

$$[0128] \quad MAE = \frac{1}{n} \sum_{i=1}^n |y_i' - y_i| \quad (3-4)$$

$$[0129] \quad R^2 = 1 - \frac{\sum_{i=1}^n (y_i' - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2} \quad (3-5)$$

[0130] 其中 y_i' 为预测值; y_i 为实际值; \bar{y}_i 为实际值的平均值。

[0131] 表4预测方法对比

样本	预测方法	MSE	MAE	RMSE	R ²
[0132] 测试集	LSTM	0.0064	0.0376	0.0375	0.2031
	堆栈 SLSTM	0.0028	0.0239	0.0231	0.7533
	LSTM(1-271 组)	2.7922e-5	0.0019	0.0018	0.7979
	堆栈 SLSTM(1-271 组)	1.7169e-5	0.0015	0.0010	0.9157

[0133] 结果表明堆栈SLSTM模型在预警前对轴承预测的MSE为1.7169e-5,MAE为0.0015, RMSE为0.0010,相关系数R²达到91.57%,模型的拟合程度较高,对轴承性能退化趋势评估准确,轴承预测曲线在轴承早期退化阶段时予以及时报警。

[0134] 综上所述,本发明的基于运行状态声辐射信号的轴承监测方法、系统及设备,将VMD-REE与LSTM网络模型相结合实现滚动轴承性能退化趋势预测,达到更早地判别和预测出滚动轴承早期故障的目的。本发明的基于运行状态声辐射信号的轴承监测方法、系统及设备,构建了一种能够监测滚动轴承性能退化状态的指标,该指标在轴承正常运行状态趋于平稳,避免了时域指标在正常运行状态波动起伏越过预警线导致误报的缺点。本发明的基于运行状态声辐射信号的轴承监测方法、系统及设备,通过对轴承声辐射信号进行变分模态分解构建相对能量熵作为滚动轴承性能退化指标,避免了浅层网络结构的局限性,充分发挥长短时记忆神经网络从输入中学习更高级、更抽象信息的能力,并解决了长短时记忆神经网络最优堆栈层数选取困难的问题。本发明的基于运行状态声辐射信号的轴承监测方法、系统及设备,去除不具有单调性或者单调性变化不明显的时域特征参数,再根据相关性准则,保留与退化指标相关性大的时域特征参数作为输入,退化指标作为输出,避免了单特征输入单特征输出趋势预测滞后性的发生。本发明的基于运行状态声辐射信号的轴承监测方法、系统及设备,以原有数据为基础设置预警线,能有效监测滚动轴承的异常指标变化,其方法简单,在不同工况下都具有很好地实践价值。所以,本发明有效克服了现有技术中的种种缺点而具高度产业利用价值。

[0135] 在本文的描述中,提供了许多特定细节,诸如部件和/或方法的实例,以提供对本发明实施例的完全理解。然而,本领域技术人员将认识到可以在没有一项或多项具体细节的情况下或通过其他设备、系统、组件、方法、部件、材料、零件等等来实践本发明的实施例。在其他情况下,未具体示出或详细描述公知的结构、材料或操作,以避免使本发明实施例的方面变模糊。

[0136] 在整篇说明书中提到“一个实施例”、“实施例”或“具体实施例”意指与结合实施例描述的特定特征、结构或特性包括在本发明的至少一个实施例中,并且不一定在所有实施

例中。因而，在整篇说明书中不同地方的短语“在一个实施例中”、“在实施例中”或“在具体实施例中”的各个表象不一定是指相同的实施例。此外，本发明的任何具体实施例的特定特征、结构或特性可以按任何合适的方式与一个或多个其他实施例结合。应当理解本文所述和所示的发明实施例的其他变型和修改可能是根据本文教导的，并将被视作本发明精神和范围的一部分。

[0137] 还应当理解还可以以更分离或更整合的方式实施附图所示元件中的一个或多个，或者甚至因为在某些情况下不能操作而被移除或因为可以根据特定应用是有用的而被提供。

[0138] 另外，除非另外明确指明，附图中的任何标志箭头应当仅被视为示例性的，而并非限制。此外，除非另外指明，本文所用的术语“或”一般意在表示“和/或”。在术语因提供分离或组合能力是不清楚的而被预见的情况下，部件或步骤的组合也将视为已被指明。

[0139] 如在本文的描述和在下面整篇权利要求书中所用，除非另外指明，“一个”、“一个”和“该”包括复数参考物。同样，如在本文的描述和在下面整篇权利要求书中所用，除非另外指明，“在…中”的意思包括“在…中”和“在…上”。

[0140] 本发明所示实施例的上述描述(包括在说明书摘要中所述的内容)并非意在详尽列举或将本发明限制到本文所公开的精确形式。尽管在本文仅为说明的目的而描述了本发明的具体实施例和本发明的实例，但是正如本领域技术人员将认识 and 理解的，各种等效修改是可以在本发明的精神和范围内的。如所指出的，可以按照本发明所述实施例的上述描述来对本发明进行这些修改，并且这些修改将在本发明的精神和范围内。

[0141] 本文已经在总体上将系统和方法描述为有助于理解本发明的细节。此外，已经给出了各种具体细节以提供本发明实施例的总体理解。然而，相关领域的技术人员将会认识到，本发明的实施例可以在没有多个具体细节的情况下进行实践，或者利用其它装置、系统、配件、方法、组件、材料、部分等进行实践。在其它情况下，并未特别示出或详细描述公知结构、材料和/或操作以避免对本发明实施例的各方面造成混淆。

[0142] 因而，尽管本发明在本文已参照其具体实施例进行描述，但是修改自由、各种改变和替换亦在上述公开内，并且应当理解，在某些情况下，在未背离所提出发明的范围和精神的前提下，在没有对应使用其他特征的情况下将采用本发明的一些特征。因此，可以进行许多修改，以使特定环境或材料适应本发明的实质范围和范围。本发明并非意在限制到在下面权利要求书中使用的特定术语和/或作为设想用以执行本发明的最佳方式公开的具体实施例，但是本发明将包括落入所附权利要求书范围内的任何和所有实施例及等同物。因而，本发明的范围将只由所附的权利要求书进行确定。

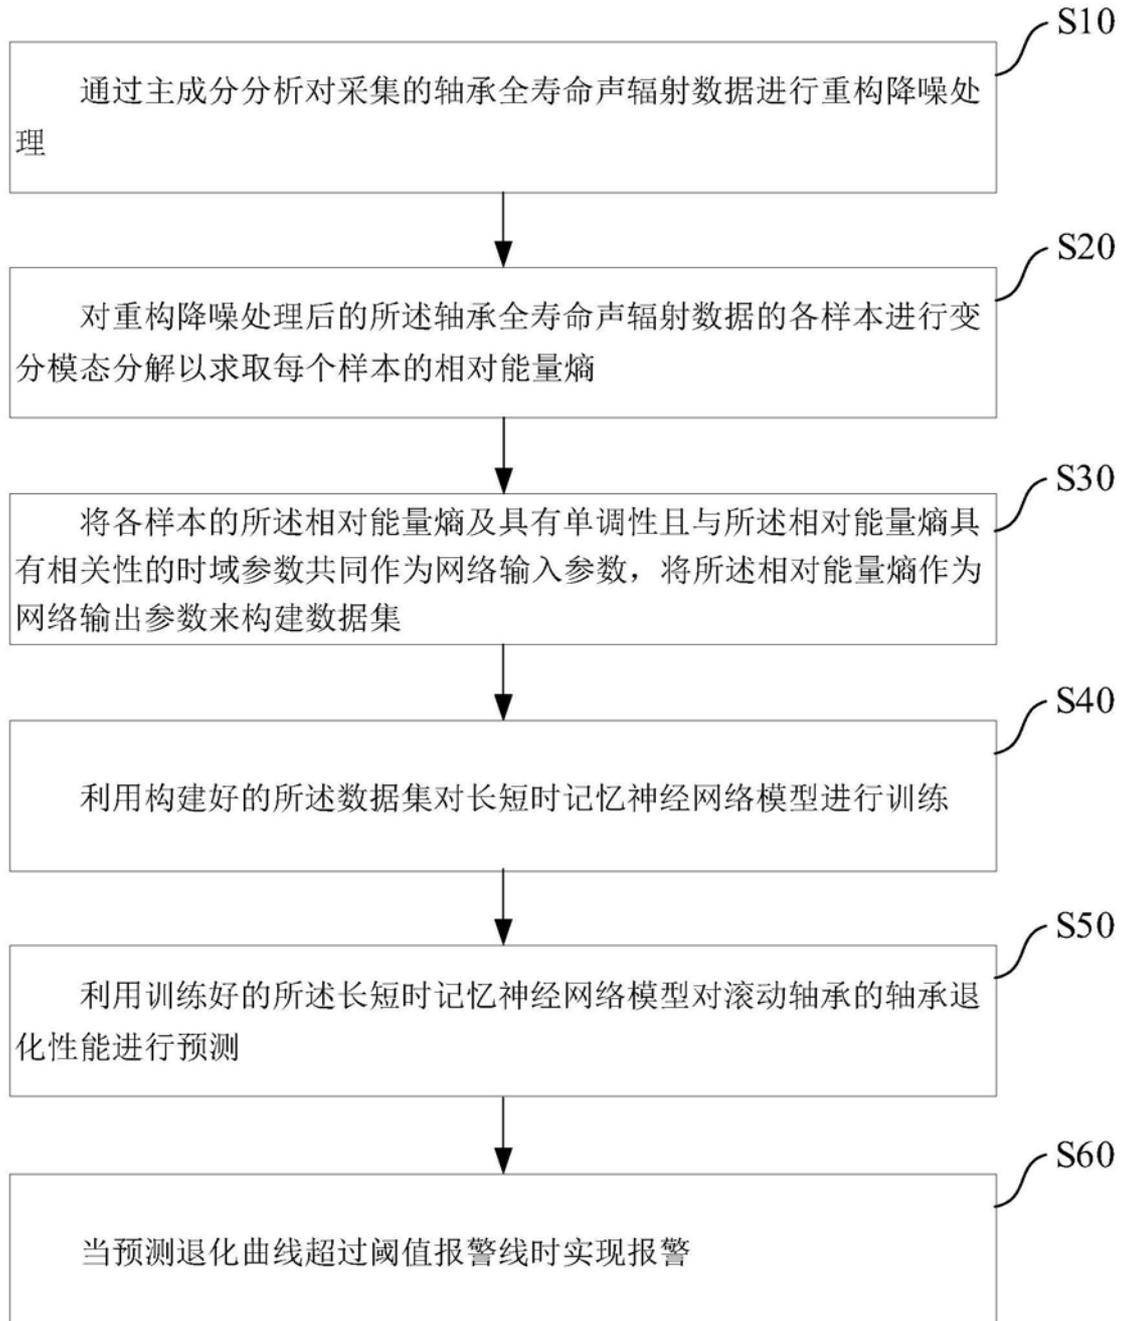


图1

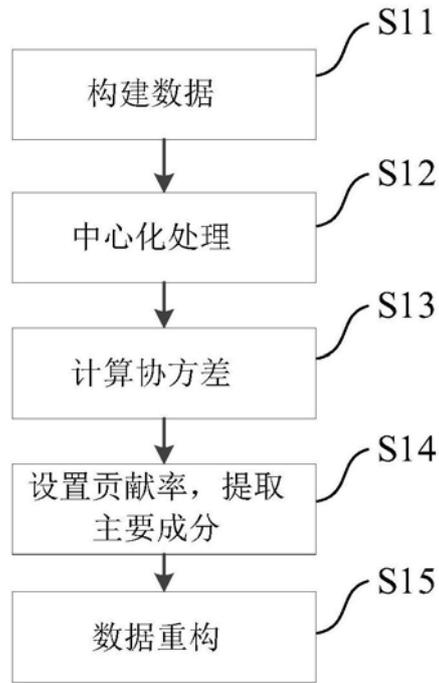


图2

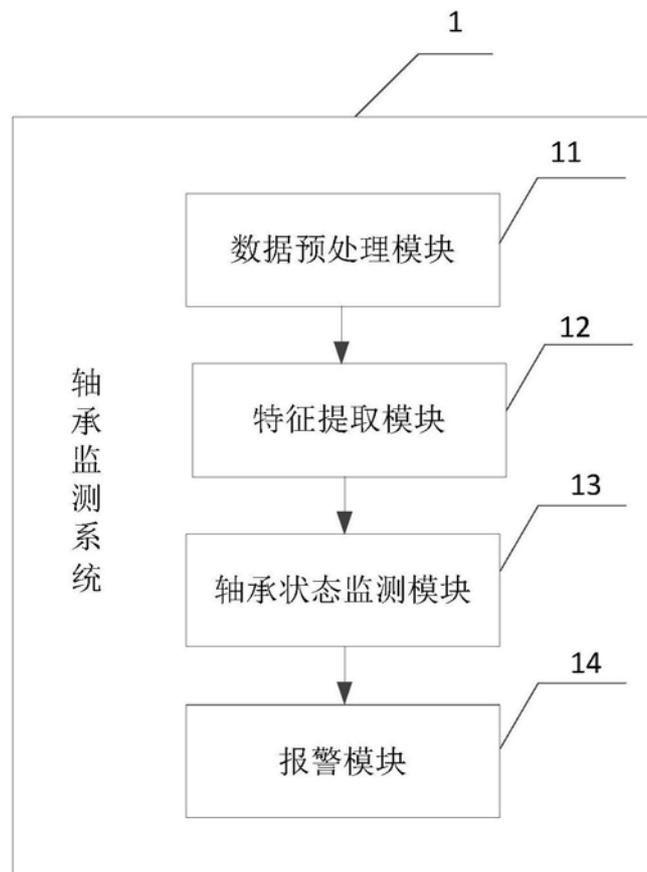


图3

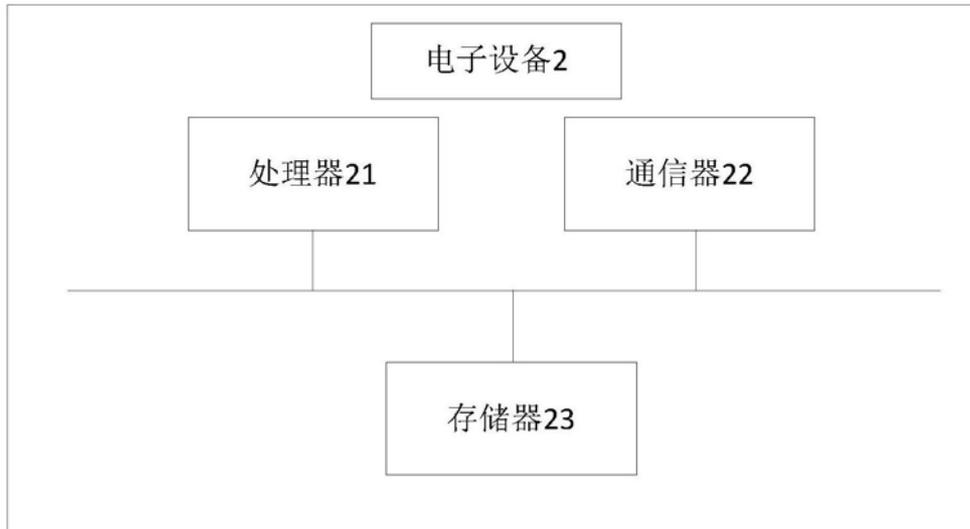


图4

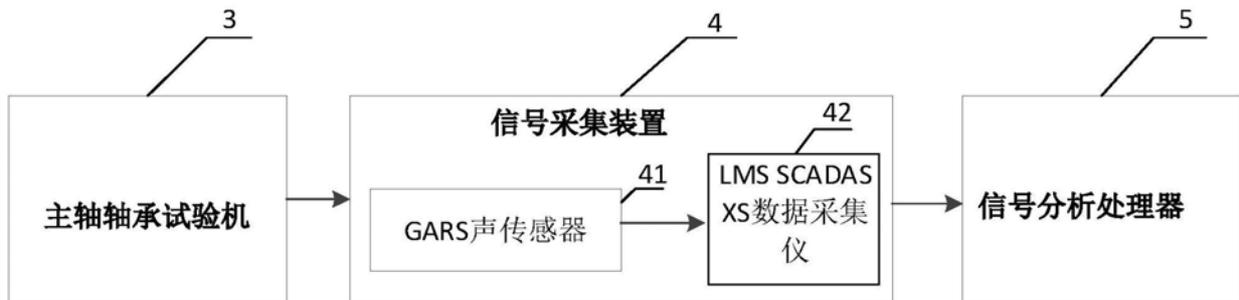


图5

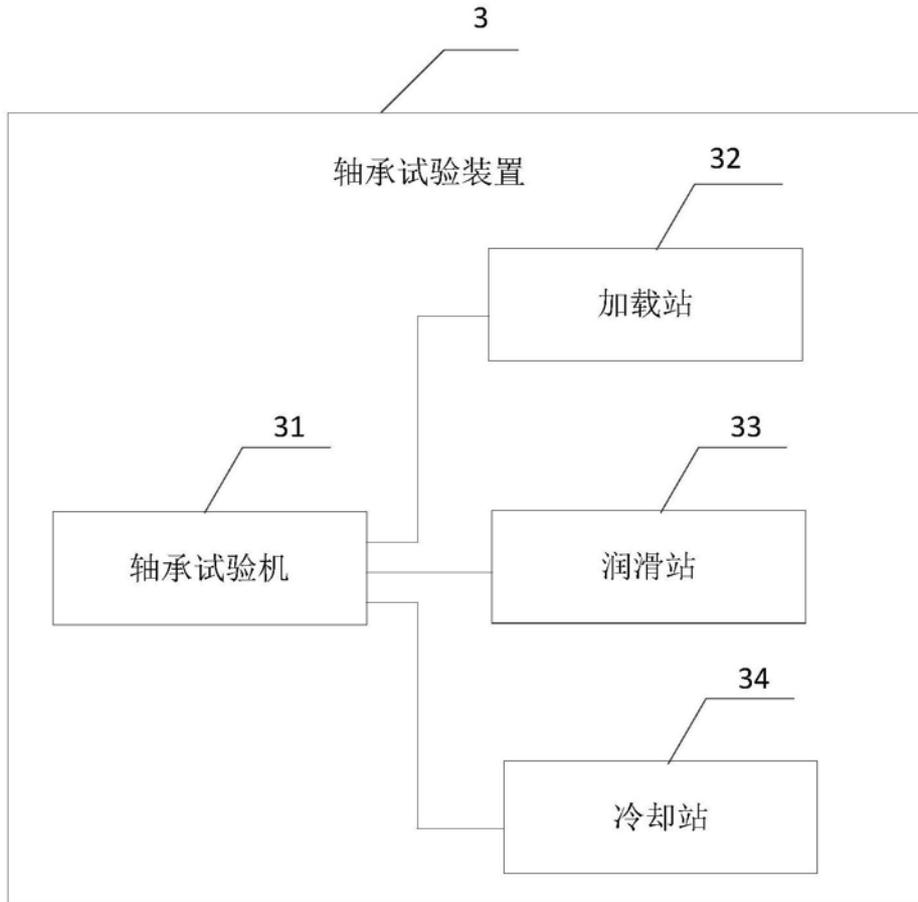


图6

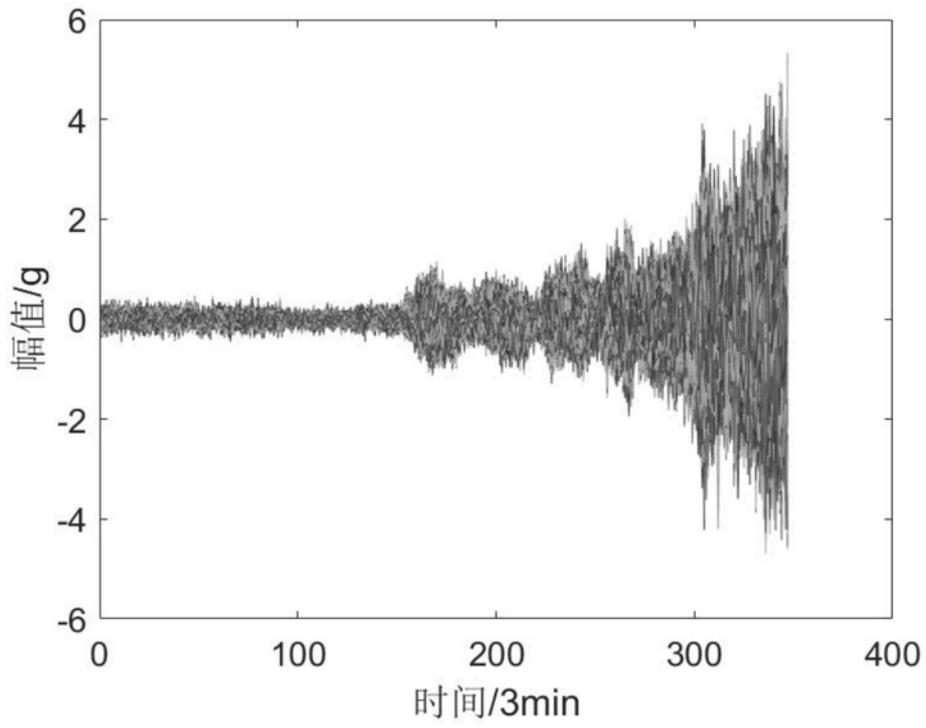


图7a

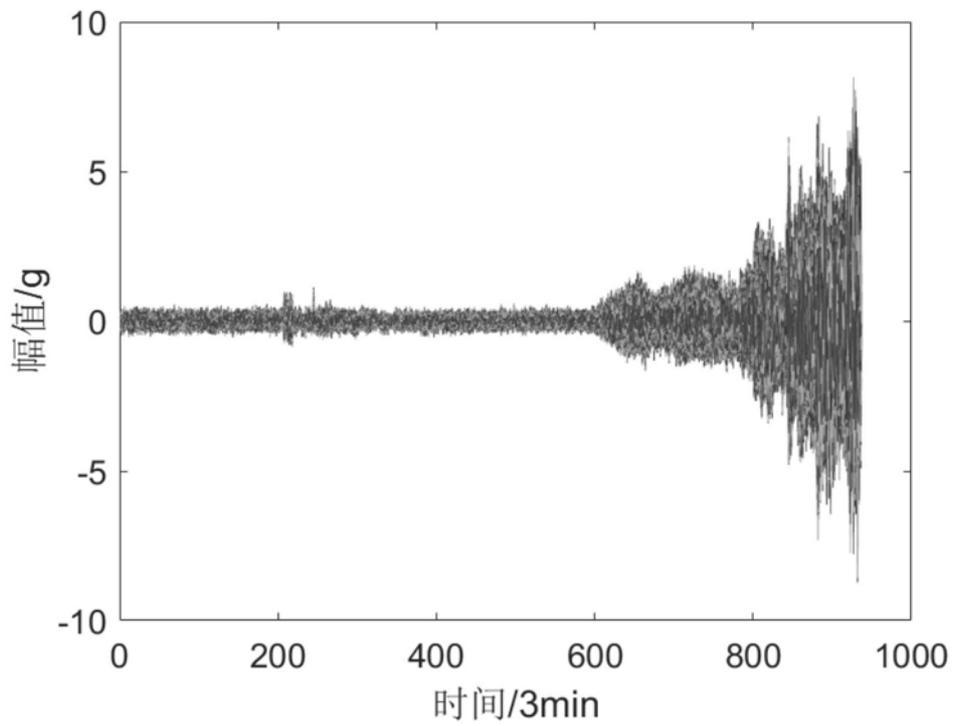


图7b

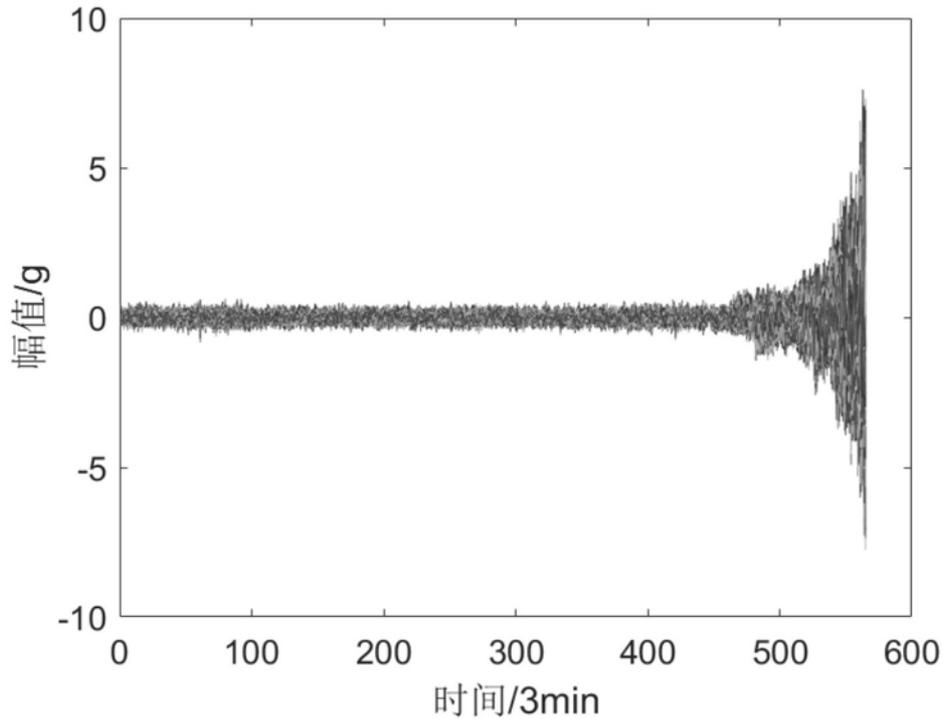


图7c

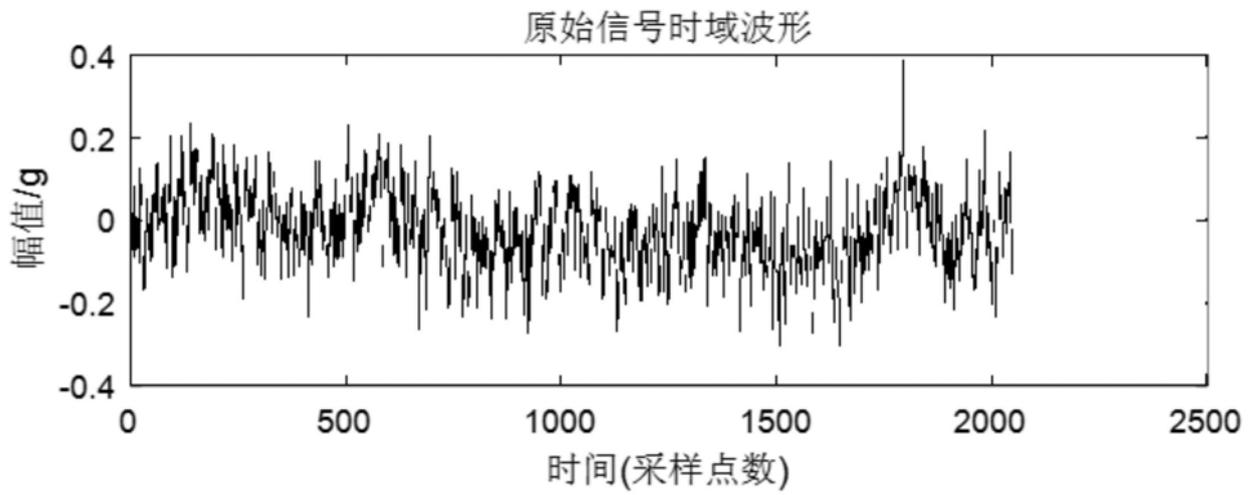


图8a

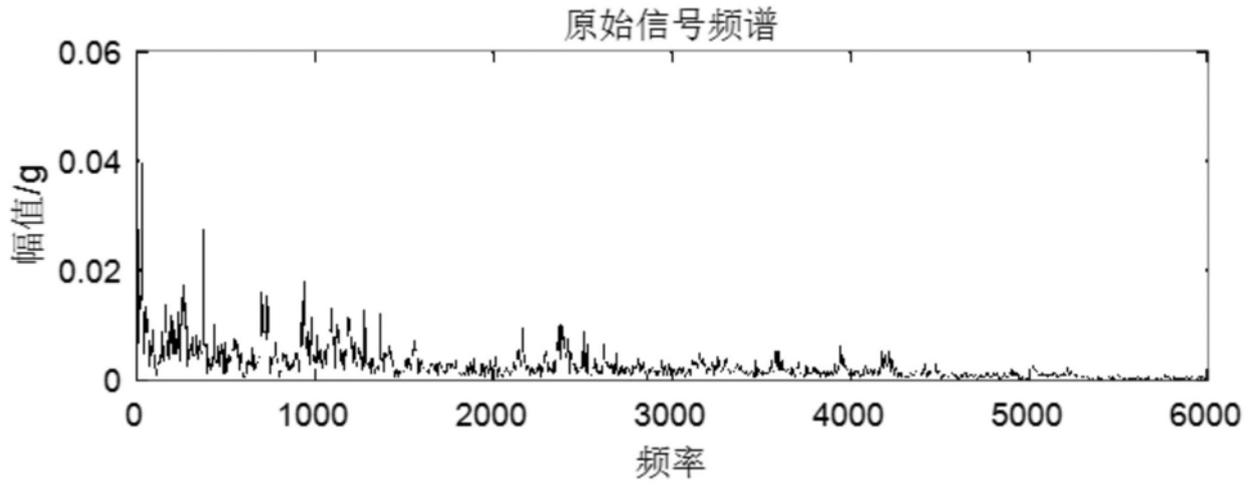


图8b

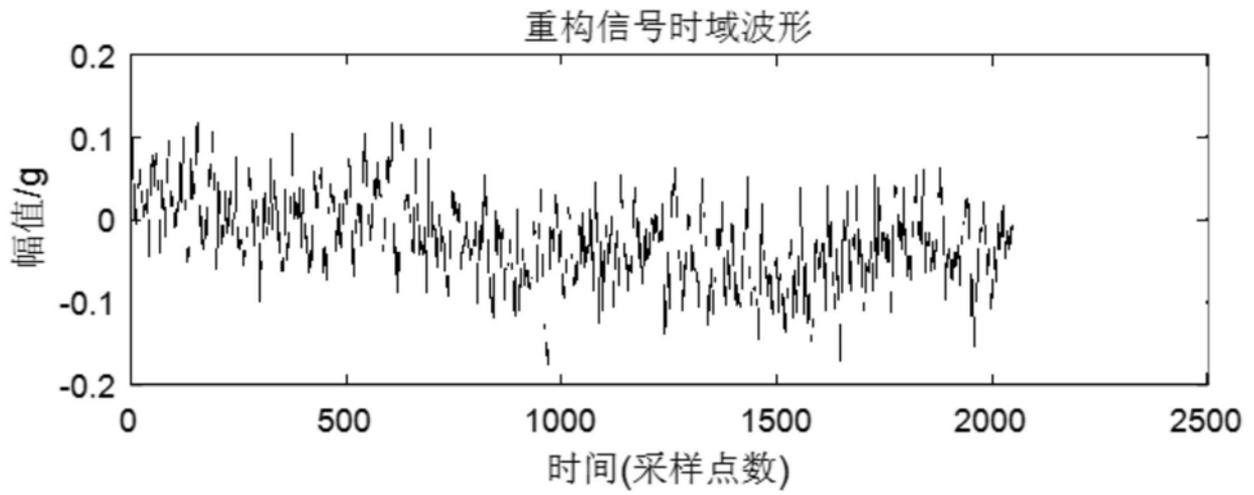


图9a

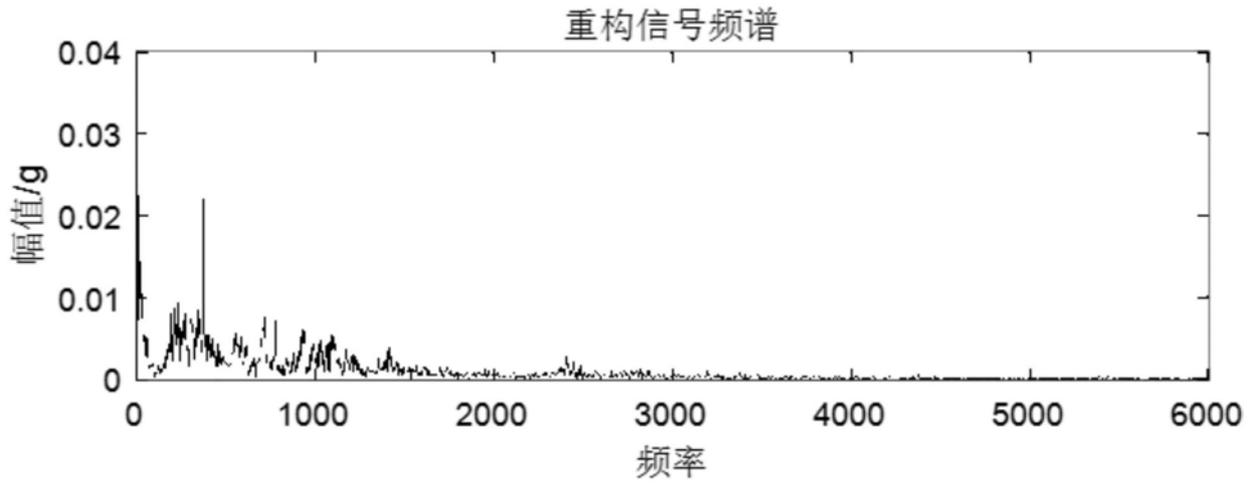


图9b

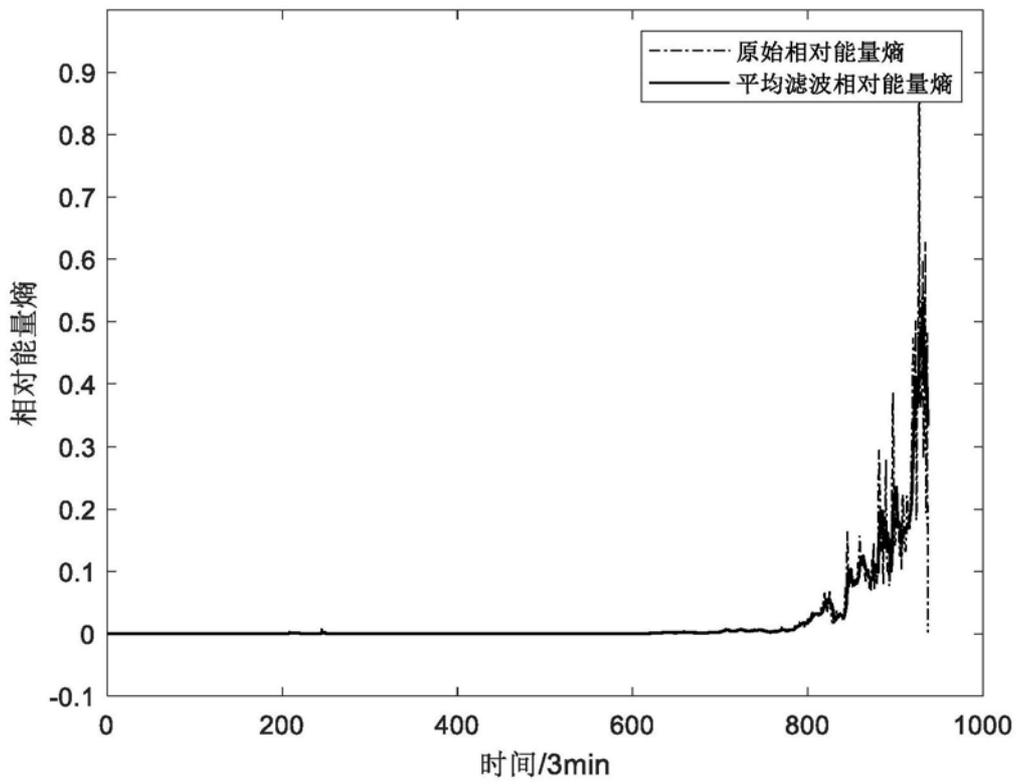


图10

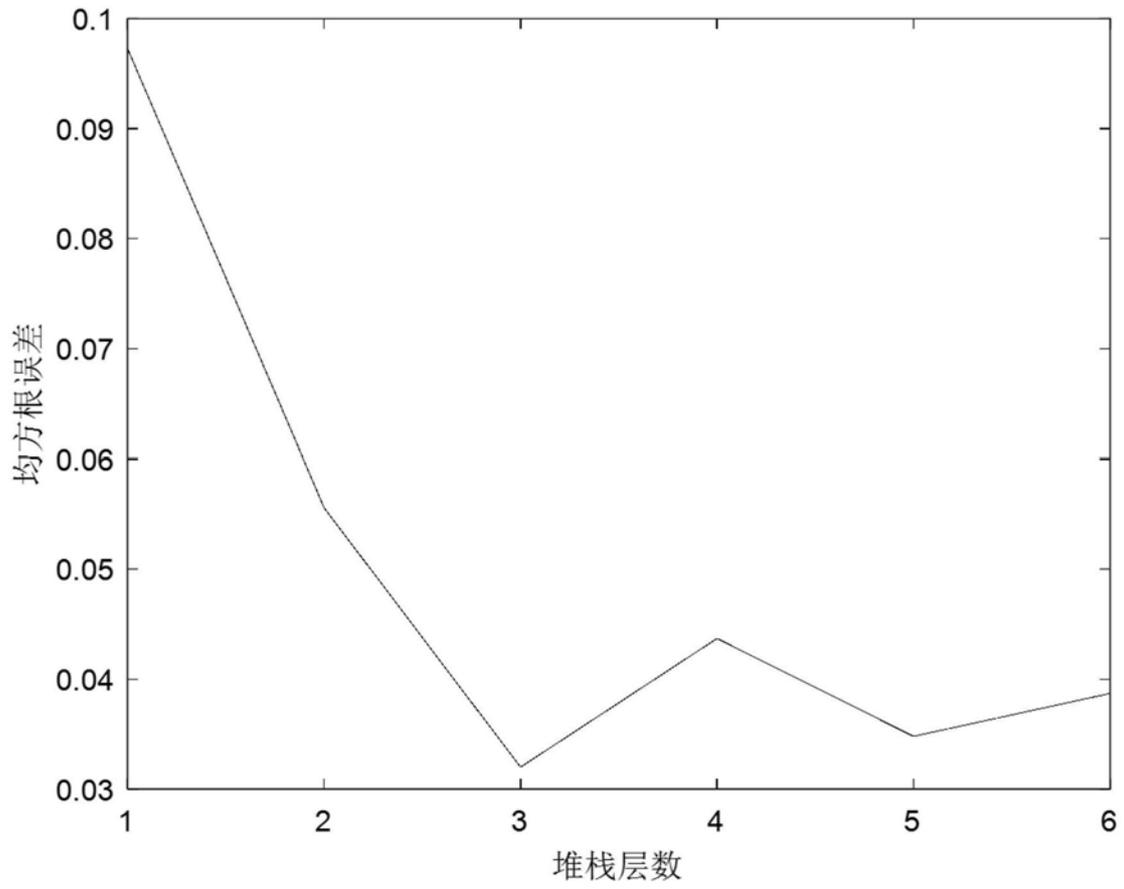


图11

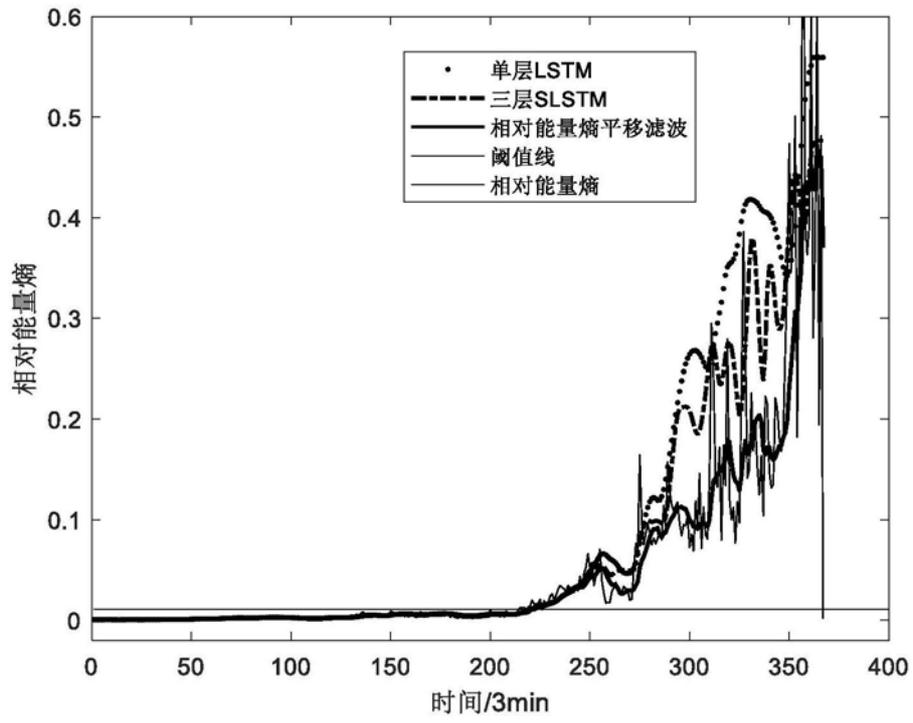


图12