



(12) 发明专利

(10) 授权公告号 CN 110672324 B

(45) 授权公告日 2021.03.26

(21) 申请号 201910824743.3

(22) 申请日 2019.09.02

(65) 同一申请的已公布的文献号
申请公布号 CN 110672324 A

(43) 申请公布日 2020.01.10

(73) 专利权人 佛山科学技术学院
地址 528000 广东省佛山市南海区狮山镇
广云路33号

(72) 发明人 张彩霞 曾平 王向东

(74) 专利代理机构 广州嘉权专利商标事务所有
限公司 44205

代理人 蔡伟杰

(51) Int.Cl.

G01M 13/045 (2019.01)

G06F 17/16 (2006.01)

(56) 对比文件

CN 110031226 A, 2019.07.19

CN 105760839 A, 2016.07.13

CN 109582003 A, 2019.04.05

CN 109827777 A, 2019.05.31

JP H04254013 A, 1992.09.09

魏永合 等. 基于LLE及其改进距离算法的轴承故障诊断模型.《组合机床与自动化加工技术》.2018, (第7期), 第73-77、81页.

审查员 宋睿


权利要求书3页 说明书6页 附图3页

(54) 发明名称

一种基于有监督LLE算法的轴承故障诊断及装置

(57) 摘要

本发明涉及故障诊断技术领域,具体涉及一种基于有监督LLE算法的轴承故障诊断及装置,首先获取训练数据,所述训练数据为表征轴承振动信号的历史数据,提取所述训练数据的特征值和所述特征值对应的故障类型,接着确定所述训练数据的优选降维训练数据,进而计算所述优选降维训练数据中各个故障类型对应的均值和协方差矩阵,通过对实时接收的测试数据进行降维,得到降维测试数据,根据所述均值和协方差矩阵计算所述降维数据在各个故障类型下的概率值,将概率值最大的故障类型作为轴承故障诊断的故障类型,本发明提高了轴承故障诊断的在线预测速率。



1. 一种基于有监督LLE算法的轴承故障诊断方法,其特征在于,包括:

获取训练数据,所述训练数据为表征轴承振动信号的历史数据,提取所述训练数据的特征值和所述特征值对应的故障类型;

确定所述训练数据的优选降维训练数据,所述优选降维训练数据中,所有故障类型的类间离散度与类内离散度的比值最大;

计算所述优选降维训练数据中各个故障类型对应的均值和协方差矩阵;

对实时接收的测试数据进行降维,得到降维测试数据;

根据所述均值和协方差矩阵计算所述降维测试数据在各个故障类型下的概率值,将概率值最大的故障类型作为轴承故障诊断的故障类型;

其中,所述确定所述训练数据的优选降维训练数据,包括:

利用LLE算法对所述训练数据进行降维,得到降维训练数据,并确定所述降维训练数据的优选近邻数和优选故障维度;

将所述优选近邻数和优选故障维度对应的降维训练数据作为优选降维训练数据;

其中,所述利用LLE算法对所述训练数据进行降维,得到降维训练数据,并确定所述降维训练数据的优选近邻数和优选故障维度,包括:

步骤310、设置近邻数p的取值范围和故障维度q的取值范围;

步骤320、选择一个p值和一个q值作为一个参数组,将所有参数组形成参数集合,所述参数集合包括p值和q值的所有组合形式;

步骤330、依次选择一个参数组,作为所述训练数据的近邻数p和故障维度q;

步骤340、利用LLE算法对步骤330得到的训练样本数据进行降维,得到降维后的数据集Y和故障集 ϕ ,其中,数据集 $Y = \{y_1, y_2, \dots, y_N\}$,Y为一个 $N \times m$ 的矩阵,N为样本个数,m为降维后的故障维度;故障集 $\phi = \{\phi_1, \phi_2, \dots, \phi_s\}$,s为故障类别总数;

步骤350、利用所述降维后的数据集和故障集计算评价指标F,具体为:

通过以下公式计算每个故障类别的均值向量 c_i :

$$c_i = \frac{1}{N_i} \sum_{y_j \in \phi_i} y_j, \quad i = 1, 2, \dots, s;$$

通过以下公式计算所有类别的类内离散度矩阵 S_i :

$$S_i = \sum_{y_j \in \phi_i} (y_j - c_i)(y_j - c_i)^T, \quad i = 1, 2, \dots, s;$$

对所有类内离散度矩阵的求和,得到混合类内离散度矩阵 S_w :

$$S_w = S_1 + S_2 + \dots + S_s;$$

通过以下公式计算类间离散度矩阵:

$$S_b = \sum_{i=1}^s (c_i - c)(c_i - c)^T;$$

通过以下公式计算评价指标F:

$$F = S_b / S_w;$$

步骤360、判断所述参数集合中的所有参数组是否均计算出评价指标,若否,跳转到步骤330,若是,执行以下步骤:

步骤370、比较各个参数组中评价指标的大小,选择评价指标最大的参数组作为优选参数组,将该参数组的p值作为优选近邻数,将该参数组的q值作为优选故障维度。

2.根据权利要求1所述的一种基于有监督LLE算法的轴承故障诊断方法,其特征在于,所述特征值包括振动位移、振动速度、振动加速度、高频加速度,所述故障类型包括磨损失效、疲劳失效、腐蚀失效。

3.根据权利要求2所述的一种基于有监督LLE算法的轴承故障诊断方法,其特征在于,所述对实时接收的测试数据进行降维,得到降维测试数据,包括:

实时接收测试数据,将所述优选近邻数作为所述测试数据的近邻数,将所述优选故障维度作为所述测试数据的故障维度,利用LLE算法对所述测试数据进行降维,得到降维测试数据。

4.一种基于有监督LLE算法的轴承故障诊断装置,其特征在于,所述装置包括:存储器、处理器以及存储在所述存储器中并可在所述处理器上运行的计算机程序,所述处理器执行所述计算机程序运行在以下装置的模块中:

提取模块,用于获取训练数据,所述训练数据为表征轴承振动信号的历史数据,提取所述训练数据的特征值和所述特征值对应的故障类型;

确定模块,用于确定所述训练数据的优选降维训练数据,所述优选降维训练数据中,所有故障类型的类间离散度与类内离散度的比值最大;

计算模块,用于所述优选降维训练数据中各个故障类型对应的均值和协方差矩阵;

降维模块,用于对实时接收的测试数据进行降维,得到降维测试数据;

诊断模块,用于根据所述均值和协方差矩阵计算所述降维测试数据在各个故障类型下的概率值,将概率值最大的故障类型作为轴承故障诊断的故障类型;

其中,所述确定模块具体用于:

利用LLE算法对所述训练数据进行降维,得到降维训练数据,并确定所述降维训练数据的优选近邻数和优选故障维度;

将所述优选近邻数和优选故障维度对应的降维训练数据作为优选降维训练数据;

其中,所述确定模块还具体用于:

步骤310、设置近邻数p的取值范围和故障维度q的取值范围;

步骤320、选择一个p值和一个q值作为一个参数组,将所有参数组形成参数集合,所述参数集合包括p值和q值的所有组合形式;

步骤330、依次选择一个参数组,作为所述训练数据的近邻数p和故障维度q;

步骤340、利用LLE算法对步骤330得到的训练样本数据进行降维,得到降维后的数据集Y和故障集 ϕ ,其中,数据集 $Y = \{y_1, y_2, \dots, y_N\}$,Y为一个 $N \times m$ 的矩阵,N为样本个数,m为降维后的故障维度;故障集 $\phi = \{\phi_1, \phi_2, \dots, \phi_s\}$,s为故障类别总数;

步骤350、利用所述降维后的数据集和故障集计算评价指标F,具体为:

通过以下公式计算每个故障类别的均值向量 c_i :

$$c_i = \frac{1}{N_i} \sum_{y_j \in \phi_i} y_j, \quad i = 1, 2, \dots, s;$$

通过以下公式计算所有类别的类内离散度矩阵 S_i :

$$S_i = \sum_{y_j \in \phi_i} (y_j - c_i)(y_j - c_i)^T, \quad i = 1, 2, \dots, s;$$

对所有类内离散度矩阵的求和,得到混合类内离散度矩阵 S_w :

$$S_w = S_1 + S_2 + \dots + S_s;$$

通过以下公式计算类间离散度矩阵:

$$S_b = \sum_{i=1}^s (c_i - c)(c_i - c)^T;$$

通过以下公式计算评价指标 F :

$$F = S_b / S_w;$$

步骤360、判断所述参数集合中的所有参数组是否均计算出评价指标,若否,跳转到步骤330,若是,执行以下步骤:

步骤370、比较各个参数组中评价指标的大小,选择评价指标最大的参数组作为优选参数组,将该参数组的 p 值作为优选近邻数,将该参数组的 q 值作为优选故障维度。

5. 根据权利要求4所述的一种基于有监督LLE算法的轴承故障诊断装置,其特征在于,所述特征值包括振动位移、振动速度、振动加速度、高频加速度,所述故障类型包括磨损失效、疲劳失效、腐蚀失效。

一种基于有监督LLE算法的轴承故障诊断及装置

技术领域

[0001] 本发明涉及故障诊断技术领域，具体涉及一种基于有监督LLE算法的轴承故障诊断及装置。

背景技术

[0002] 作为新兴的综合性的边缘学科，轴承故障诊断技术已初步形成了比较完整的学科体系。就其技术手段而言，振动诊断技术已经成为轴承故障诊断的主流技术。而计算机技术与信号信息处理技术的飞速进步，极大地推动了轴承故障诊断和监测技术向着科学化和实用化的方向发展。

[0003] 然而，在目前的轴承故障诊断领域，往往存在大规模数据并发的情况，对故障诊断的实时性要求带来极大的挑战，迫切需要提高轴承故障诊断的在线预测速率。

发明内容

[0004] 本发明的目的在于提供一种基于有监督LLE算法的轴承故障诊断及装置，旨在提高轴承故障诊断的在线预测速率。

[0005] 为了实现上述目的，本发明提供以下技术方案：

[0006] 一种基于有监督LLE算法的轴承故障诊断方法，包括：

[0007] 获取训练数据，所述训练数据为表征轴承振动信号的历史数据，提取所述训练数据的特征值和所述特征值对应的故障类型；

[0008] 确定所述训练数据的优选降维训练数据，所述优选降维训练数据中，所有故障类型的类间离散度与类内离散度的比值最大；

[0009] 计算所述优选降维训练数据中各个故障类型对应的均值和协方差矩阵；

[0010] 对实时接收的测试数据进行降维，得到降维测试数据；

[0011] 根据所述均值和协方差矩阵计算所述降维数据在各个故障类型下的概率值，将概率值最大的故障类型作为轴承故障诊断的故障类型。

[0012] 进一步，所述特征值包括振动位移、振动速度、振动加速度、高频加速度，所述故障类型包括磨损失效、疲劳失效、腐蚀失效。

[0013] 进一步，所述确定所述训练数据的优选降维训练数据，包括：

[0014] 利用LLE算法对所述训练数据进行降维，得到降维训练数据，并确定所述降维训练数据的优选近邻数和优选故障维度；

[0015] 将所述优选近邻数和优选故障维度对应的降维训练数据作为优选降维训练数据。

[0016] 进一步，所述利用LLE算法对所述训练数据进行降维，得到降维训练数据，并确定所述降维训练数据的优选近邻数和优选故障维度，包括：

[0017] 步骤310、设置近邻数 p 的取值范围和故障维度 q 的取值范围；

[0018] 步骤320、选择一个 p 值和一个 q 值作为一个参数组，将所有参数组形成参数集合，所述参数集合包括 p 值和 q 值的所有组合形式；

[0019] 步骤330、依次选择一个参数组,作为所述训练数据的近邻数 p 和故障维度 q ;

[0020] 步骤340、利用LLE算法对步骤330得到的训练样本数据进行降维,得到降维后的数据集 Y 和故障集 Φ ,其中,数据集 $Y = \{y_1, y_2, \dots, y_N\}$, Y 为一个 $N \times m$ 的矩阵, N 为样本个数, m 为故障维度;故障集 $\Phi = \{\phi_1, \phi_2, \dots, \phi_s\}$, s 为故障类别总数;

[0021] 步骤350、利用所述降维后的数据集和故障集计算评价指标 F ,具体为:

[0022] 通过以下公式计算每个故障类别的均值向量 c_i :

$$[0023] \quad c_i = \frac{1}{N_i} \sum_{y_j \in \phi_i} y_j, \quad i = 1, 2, \dots, s;$$

[0024] 通过以下公式计算所有类别的类内离散度矩阵 S_i :

$$[0025] \quad S_i = \sum_{y_j \in \phi_i} (y_j - c_i)(y_j - c_i)^T, \quad i = 1, 2, \dots, s;$$

[0026] 对所有类内离散度矩阵的求和,得到混合类内离散度矩阵 S_w :

$$[0027] \quad S_w = S_1 + S_2 + \dots + S_s;$$

[0028] 通过以下公式计算类间离散度矩阵:

$$[0029] \quad S_b = \sum_{i=1}^s (c_i - c)(c_i - c)^T;$$

[0030] 通过以下公式计算评价指标 F :

$$[0031] \quad F = S_b / S_w;$$

[0032] 步骤360、判断所述参数集合中的所有参数组是否均计算出评价指标,若否,跳转到步骤330,若是,执行以下步骤:

[0033] 步骤370、比较各个参数组中评价指标的大小,选择评价指标最大的参数组作为优选参数组,将该参数组的 p 值作为优选近邻数,将该参数组的 q 值作为优选故障维度。

[0034] 进一步,所述对实时接收的测试数据进行降维,得到降维测试数据,包括:

[0035] 将所述优选近邻数作为所述测试数据的近邻数,将所述优选故障维度作为所述测试数据的故障维度,利用LLE算法对所述测试数据进行降维,得到降维测试数据。

[0036] 一种基于有监督LLE算法的轴承故障诊断装置,所述装置包括:存储器、处理器以及存储在所述存储器中并可在所述处理器上运行的计算机程序,所述处理器执行所述计算机程序运行在以下装置的模块中:

[0037] 提取模块,用于获取训练数据,所述训练数据为表征轴承振动信号的历史数据,提取所述训练数据的特征值和所述特征值对应的故障类型;

[0038] 确定模块,用于确定所述训练数据的优选降维训练数据,所述优选降维训练数据中,所有故障类型的类间离散度与类内离散度的比值最大;

[0039] 计算模块,用于所述优选降维训练数据中各个故障类型对应的均值和协方差矩阵;

[0040] 降维模块,用于对实时接收的测试数据进行降维,得到降维测试数据;

[0041] 诊断模块,用于根据所述均值和协方差矩阵计算所述降维数据在各个故障类型下的概率值,将概率值最大的故障类型作为轴承故障诊断的故障类型。

[0042] 进一步,所述特征值包括振动位移、振动速度、振动加速度、高频加速度,所述故障

类型包括磨损失效、疲劳失效、腐蚀失效。

[0043] 进一步,所述确定模块具体用于:

[0044] 利用LLE算法对所述训练数据进行降维,得到降维训练数据,并确定所述降维训练数据的优选近邻数和优选故障维度;

[0045] 将所述优选近邻数和优选故障维度对应的降维训练数据作为优选降维训练数据。

[0046] 本发明的有益效果是:本发明公开一种基于有监督LLE算法的轴承故障诊断及装置,首先获取训练数据,所述训练数据为表征轴承振动信号的历史数据,提取所述训练数据的特征值和所述特征值对应的故障类型,接着确定所述训练数据的优选降维训练数据,进而计算所述优选降维训练数据中各个故障类型对应的均值和协方差矩阵,通过对实时接收的测试数据进行降维,得到降维测试数据,根据所述均值和协方差矩阵计算所述降维数据在各个故障类型下的概率值,将概率值最大的故障类型作为轴承故障诊断的故障类型。本发明提高了轴承故障诊断的在线预测速率。

附图说明

[0047] 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,下面将对实施例中所需要使用的附图作简单地介绍,显而易见地,下面描述中的附图仅仅是本发明的一些实施例,对于本领域普通技术人员来讲,在不付出创造性劳动性的前提下,还可以根据这些附图获得其他的附图。

[0048] 图1是本发明实施例一种基于有监督LLE算法的轴承故障诊断方法的流程示意图;

[0049] 图2是本发明实施例步骤S200的流程示意图;

[0050] 图3是本发明实施例步骤S210的流程示意图;

[0051] 图4是本发明实施例一种基于有监督LLE算法的轴承故障诊断装置的结构示意图。

具体实施方式

[0052] 下面将结合附图对本发明的技术方案进行清楚、完整的描述,显然,所描述的实施例是本发明一部分实施例,而不是全部的实施例。基于本发明中的实施例,本领域普通技术人员在没有做出创造性劳动前提下所获得的所以其他实施例,都属于本发明的保护范围。

[0053] 参考图1,本发明实施例提供一种基于有监督LLE算法的轴承故障诊断方法,包括以下步骤:

[0054] 步骤S100、获取训练数据,所述训练数据为表征轴承振动信号的历史数据,提取所述训练数据的特征值和所述特征值对应的故障类型;

[0055] 步骤S200、确定所述训练数据的优选降维训练数据,所述优选降维训练数据中,所有故障类型的类间离散度与类内离散度的比值最大;

[0056] 步骤S300、计算所述优选降维训练数据中各个故障类型对应的均值和协方差矩阵;

[0057] 步骤S400、对实时接收的测试数据进行降维,得到降维测试数据;

[0058] 步骤S500、根据所述均值和协方差矩阵计算所述降维数据在各个故障类型下的概率值,将概率值最大的故障类型作为轴承故障诊断的故障类型。

[0059] 本实施例利用有监督的降维方法实现轴承故障诊断。通过对训练数据进行训练,

将高维数据中的特征值和故障类型提取出来,使得训练数据在低维空间中有非常好的区分度,本实施例需要存储的参数类型更少,预测速率更快,适合在线预测。

[0060] 在一个实施例中,所述特征值包括振动位移(峰峰值)、振动速度(真有效值)、振动加速度(峰值)、高频加速度,所述故障类型包括磨损失效、疲劳失效、腐蚀失效。

[0061] 参考图2,作为本实施例的进一步改进,所述步骤S200包括以下步骤:

[0062] 步骤S210、利用LLE算法对所述训练数据进行降维,得到降维训练数据,并确定所述降维训练数据的优选近邻数和优选故障维度;

[0063] 步骤S220、将所述优选近邻数和优选故障维度对应的降维训练数据作为优选降维训练数据。

[0064] 参考图3,作为本实施例的进一步改进,所述步骤S210包括:

[0065] 步骤S211、设置近邻数 p 的取值范围和故障维度 q 的取值范围。

[0066] 本实施例中,需要找出降维训练数据中每个训练数据的 p 个近邻点。把每个训练数据点中欧氏距离最近的 p 个训练数据点找出, p 即所谓近邻数。

[0067] 近邻数 p 的取值范围和故障维度 q 的取值范围可以根据历史记录,或者根据轴承故障的诊断需求人为设置, p 和 q 的取值范围越大,则训练时间越长、诊断更全面, p 和 q 的取值范围越小,则训练时间越短。

[0068] 近邻数 p 是LLE算法中的第一个重要参数。LLE算法的前提假设是每一个训练数据点都是局部线性的,即每一个训练数据点都可以用它的近邻点线性组合来表达,在高维向低维映射的过程中,保持了训练数据之间的近邻关系。 p 的取值过大使得局部线性的范围过大,无法很好的体现LLE算法的局部特征。而当 p 的取值过小,LLE算法就很难保证训练数据在低维空间中的拓扑结构。

[0069] 故障维度 q 是LLE算法中的第二个重要的参数,故障维度 q 的取值过大,将会使降维后的训练数据中含有过多的冗余,反之如果故障维度 q 的取值过小,使得在高维空间中彼此分开的训练数据在低维空间中交叠。

[0070] 步骤S212、选择一个 p 值和一个 q 值作为一个参数组,将所有参数组形成参数集合,所述参数集合包括 p 值和 q 值的所有组合形式。

[0071] 步骤S213、依次选择一个参数组,作为所述训练数据的近邻数 p 和故障维度 q 。

[0072] 步骤S214、利用LLE算法对步骤S213得到的训练样本数据进行降维,得到降维后的数据集和故障集。

[0073] 其中,数据集 $Y = \{y_1, y_2, \dots, y_N\}$, Y 为一个 $N \times m$ 的矩阵, N 为样本个数, m 为故障维度;故障集 $\phi = \{\phi_1, \phi_2, \dots, \phi_s\}$, s 为故障类别总数;

[0074] 降维后的训练样本数据不用再训练分类器,而是通过不同故障类型数据的样本分布来直接确定测试数据的故障类型。

[0075] 步骤S215、利用所述降维后的数据集和故障集计算评价指标 F 。

[0076] 具体为:

[0077] 通过以下公式计算每个故障类别的均值向量 c_i :

$$[0078] \quad c_i = \frac{1}{N_i} \sum_{y \in \phi_i} y_j, \quad i = 1, 2, \dots, s;$$

[0079] 通过以下公式计算所有类别的类内离散度矩阵 S_i :

$$[0080] \quad S_i = \sum_{y_j \in \phi_i} (y_j - c_i)(y_j - c_i)^T, \quad i = 1, 2, \dots, s;$$

[0081] 对所有类内离散度矩阵的求和,得到混合类内离散度矩阵 S_w :

$$[0082] \quad S_w = S_1 + S_2 + \dots + S_s;$$

[0083] 通过以下公式计算类间离散度矩阵:

$$[0084] \quad S_b = \sum_{i=1}^s (c_i - c)(c_i - c)^T;$$

[0085] 通过以下公式计算评价指标 F :

$$[0086] \quad F = S_b / S_w;$$

[0087] 步骤S216、判断所述参数集合中的所有参数组是否均计算出评价指标,若否,跳转到步骤S213,若是,执行以下步骤。

[0088] 步骤S217、比较各个参数组中评价指标的大小,选择评价指标最大的参数组作为优选参数组,将该参数组的 p 值作为优选近邻数,将该参数组的 q 值作为优选故障维度。

[0089] 选择优选参数组是为了最大化不同故障类型数据的类间间距、最小化不同故障类型数据间的类内间距。

[0090] LLE算法是一种典型的无监督学习方法,本实施例中,通过遍历近邻数 p 和故障维度 q ,使得最大化不同故障类别数据的类间间距,最小化类内间距。这样通过已知的特征值和故障类型,引导降维后的特征选取,实现了有监督的LLE算法。与传统的轴承故障诊断方法相比,本实施例需要存储的参数类型更少,预测速率更快,适合在线预测。

[0091] 作为本实施例的进一步改进,所述步骤S400包括:

[0092] 将所述优选近邻数作为所述测试数据的近邻数,将所述优选故障维度作为所述测试数据的故障维度,利用LLE算法对所述测试数据进行降维,得到降维测试数据。

[0093] 参考图4,本实施例还提供一种基于有监督LLE算法的轴承故障诊断装置,所述装置包括:存储器、处理器以及存储在所述存储器中并可在所述处理器上运行的计算机程序,所述处理器执行所述计算机程序运行在以下装置的模块中:

[0094] 提取模块100,用于获取训练数据,所述训练数据为表征轴承振动信号的历史数据,提取所述训练数据的特征值和所述特征值对应的故障类型;

[0095] 确定模块200,用于确定所述训练数据的优选降维训练数据,所述优选降维训练数据中,所有故障类型的类间离散度与类内离散度的比值最大;

[0096] 计算模块300,用于所述优选降维训练数据中各个故障类型对应的均值和协方差矩阵;

[0097] 降维模块400,用于对实时接收的测试数据进行降维,得到降维测试数据;

[0098] 诊断模块500,用于根据所述均值和协方差矩阵计算所述降维数据在各个故障类型下的概率值,将概率值最大的故障类型作为轴承故障诊断的故障类型。

[0099] 作为本实施例的进一步改进,所述特征值包括振动位移、振动速度、振动加速度、高频加速度,所述故障类型包括磨损失效、疲劳失效、腐蚀失效。

[0100] 作为本实施例的进一步改进,所述确定模块200具体用于:

[0101] 利用LLE算法对所述训练数据进行降维,得到降维训练数据,并确定所述降维训练

数据的优选近邻数和优选故障维度；

[0102] 将所述优选近邻数和优选故障维度对应的降维训练数据作为优选降维训练数据。

[0103] 所述一种基于有监督LLE算法的轴承故障诊断装置可以运行于桌上型计算机、手机、笔记本、平板电脑及云端服务器等计算设备中。所述一种基于有监督LLE算法的轴承故障诊断装置，可运行的系统可包括，但不仅限于，处理器、存储器。本领域技术人员可以理解，所述例子仅仅是一种基于有监督LLE算法的轴承故障诊断装置的示例，并不构成对一种基于有监督LLE算法的轴承故障诊断装置的限定，可以包括比例子更多或更少的部件，或者组合某些部件，或者不同的部件，例如所述一种基于有监督LLE算法的轴承故障诊断装置还可以包括输入输出设备、网络接入设备、总线等。

[0104] 所称处理器可以是中央处理单元 (Central-Processing-Unit, CPU)，还可以是其他通用处理器、数字信号处理器 (Digital-Signal-Processor, DSP)、专用集成电路 (Application-Specific-Integrated-Circuit, ASIC)、现成可编程门阵列 (Field-Programmable-Gate-Array, FPGA) 或者其他可编程逻辑器件、分立门或者晶体管逻辑器件、分立硬件组件等。通用处理器可以是微处理器或者该处理器也可以是任何常规的处理器等，所述处理器是所述一种基于有监督LLE算法的轴承故障诊断装置运行系统的控制中心，利用各种接口和线路连接整个一种基于有监督LLE算法的轴承故障诊断装置可运行系统的各个部分。

[0105] 所述存储器可用于存储所述计算机程序和/或模块，所述处理器通过运行或执行存储在所述存储器内的计算机程序和/或模块，以及调用存储在存储器内的数据，实现所述一种基于有监督LLE算法的轴承故障诊断装置的各种功能。所述存储器可主要包括存储程序区和存储数据区，其中，存储程序区可存储操作系统、至少一个功能所需的应用程序 (比如声音播放功能、图像播放功能等) 等；存储数据区可存储根据手机的使用所创建的数据 (比如音频数据、电话本等) 等。此外，存储器可以包括高速随机存取存储器，还可以包括非易失性存储器，例如硬盘、内存、插接式硬盘，智能存储卡 (Smart-Media-Card, SMC)，安全数字 (Secure-Digital, SD) 卡，闪存卡 (Flash-Card)、至少一个磁盘存储器件、闪存器件、或其他易失性固态存储器件。

[0106] 尽管本公开的描述已经相当详尽且特别对几个所述实施例进行了描述，但其并非旨在局限于任何这些细节或实施例或任何特殊实施例，而是应当将其视作是通过参考所附权利要求，考虑到现有技术为这些权利要求提供广义的可能性解释，从而有效地涵盖本公开的预定范围。此外，上文以发明人可预见的实施例对本公开进行描述，其目的是为了提供有用的描述，而那些目前尚未预见的对本公开的非实质性改动仍可代表本公开的等效改动。




图1




图2




图3




图4