



(12) 发明专利

(10) 授权公告号 CN 109855875 B

(45) 授权公告日 2020.12.22

(21) 申请号 201910036750.7

审查员 朱天

(22) 申请日 2019.01.15

(65) 同一申请的已公布的文献号

申请公布号 CN 109855875 A

(43) 申请公布日 2019.06.07

(73) 专利权人 沈阳化工大学

地址 110142 辽宁省沈阳市经济技术开发
区11号

(72) 发明人 张义民 高淑芝 张思选

(74) 专利代理机构 沈阳技联专利代理有限公司

21205

代理人 张志刚

(51) Int.Cl.

G01M 13/045 (2019.01)

权利要求书1页 说明书5页

(54) 发明名称

一种滚动轴承运行可靠度预测方法

(57) 摘要

一种滚动轴承运行可靠度预测方法,涉及一种轴承运行可靠度的预测方法,本发明基于流形学习和非齐次布谷鸟搜索-最小二乘支持向量机(NoCuSa-LSSVM)的滚动轴承运行可靠度预测。首先利用等距映射(ISOMAP)算法对轴承振动信号的时域、频域、时频域特征组成的高维特征集进行维数约减,将融合的特征指标作为轴承的性能退化状态特征输入到逻辑回归模型,建立滚动轴承的可靠度模型。然后将轴承的性能退化状态特征作为非齐次布谷鸟搜索-最小二乘支持向量机模型的输入,获取特征预测结果,并将该结果嵌入到已建立的可靠度模型中,从而预测出轴承运行可靠度。

1. 一种滚动轴承运行可靠度预测方法,所述的方法包括:特征提取,从滚动轴承振动数据中提取时域特征,时频域特征,以及频域特征,构成高维的特征向量集;其特征在于,所述方法为一种基于流行学习和NoCuSa-LSSVM的滚动轴承运行可靠度预测方法,包括以下步骤:

步骤一:等距映射ISOMAP降维,采用ISOMAP算法对高维特征向量集进行降维处理,将降维结果作为轴承退化趋势特征向量;

步骤二:可靠性模型,将趋势特征向量作为逻辑回归模型的输入,输出为可靠度;

通过极大似然法求解回归系数,建立可靠度模型;

步骤三:趋势特征向量预测,选取趋势特征向量作为LSSVM的训练样本,并通过NoCuSa算法优化LSSVM的参数选取,建立预测模型,预测出一定步长的趋势特征向量;

步骤四:可靠度预测,趋势特征向量预测结果嵌入到可靠度模型中,得到一定步长的可靠度预测结果;

所述的提取时域特征为九个,分别为,峰峰值、整流平均值、标准差、峭度、方差、均方根、波形因子、脉冲因子、裕度因子,通过傅里叶变换后对信号进行频域上的特征提取,提取十个频域特征,结合小波包分解与信息熵理论得到小波包能谱熵和小波包奇异值熵,利用db5小波对原始振动信号进行三层分解,提取出振动信号的时频域特征。

一种滚动轴承运行可靠度预测方法

技术领域

[0001] 本发明涉及一种轴承运行的预测方法,特别是涉及一种滚动轴承运行可靠度预测方法。

背景技术

[0002] 滚动轴承是关键机械基础件之一,是旋转机械必不可少的一部分,其可靠性直接影响设备的安全稳定运行。滚动轴承传统的可靠度计算基于轴承的寿命分布函数,需要大样本失效数据和失效分布。对于实时运行的轴承采用这种方法是不适宜的,从现场获得很难获得大量轴承失效寿命数据,失效寿命数据一般来自寿命试验,而轴承实际运行时的载荷、转速等往往是多变且不确定的,实际工况与实验条件差异较大。传统的依赖大样本和概率统计的可靠度计算,得到的是一批设备的平均可靠度,对单个具体设备的指导意义不强。因此为避免因轴承失效引起的机械设备故障,预测滚动轴承在下一阶段的运行可靠度就十分重要。

发明内容

[0003] 本发明的目的在于提供一种滚动轴承运行可靠度预测方法,该方法为基于流行学习和非齐次布谷鸟搜索-最小二乘支持向量机(NoCuSa-LSSVM)的滚动轴承运行可靠度预测方法。

[0004] 本发明的目的是通过以下技术方案实现的:

[0005] 本发明是一种滚动轴承运行可靠度预测方法,采用流行学习和NoCuSa-LSSVM相结合的方法来实现滚动轴承的运行可靠度预测,首先利用等距映射算法对轴承振动信号的时域、频域、时频域特征组成的高维特征集进行维数约减,将融合的特征指标作为轴承的性能退化状态特征输入到逻辑回归模型,建立滚动轴承的可靠度模型。然后将轴承的性能退化状态特征作为NoCuSa-LSSVM模型的输入,获取特征预测结果,并将该结果嵌入到已建立的可靠度模型中,从而预测出轴承运行可靠度。

[0006] 一种滚动轴承运行可靠度预测方法,所述方法包括以下步骤:

[0007] 步骤一:特征提取,从滚动轴承振动数据中提取时域特征,时频域特征,以及频域特征,构成高维的特征向量集;

[0008] 步骤二:等距映射(ISOMAP)降维,采用ISOMAP算法对高维特征向量集进行降维处理,将降维结果作为轴承退化趋势特征向量;

[0009] 步骤三:可靠性模型,将趋势特征向量作为逻辑回归模型的输入,输出为可靠度。通过极大似然法求解回归系数,建立可靠度模型;

[0010] 步骤四:趋势特征向量预测,选取趋势特征向量作为LSSVM的训练样本,并通过NoCuSa算法优化LSSVM的参数选取,建立预测模型,预测出一定步长的趋势特征向量;

[0011] 步骤五:可靠度预测,趋势特征向量预测结果嵌入到可靠度模型中,得到一定步长的可靠度预测结果。

[0012] 本发明的优点与效果是：

[0013] 1. 本发明通过对滚动轴承振动信号进行多域的特征提取，得到的高维特征向量集更准确的反映的轴承当前的运行状态。

[0014] 2. 本发明采用一种流形学习的方法—等距映射 (ISOMAP) 利用其非线性和考虑全局的特性，对滚动轴承的高维特征集进行降维处理，再输入到逻辑回归模型中，更准确地建立了轴承的运行可靠度模型。

[0015] 3. 本发明在可靠度预测过程中，采用NoCuSa算法优化LSSVM的参数选取，得到了更高的预测精度。

具体实施方式

[0016] 下面结合实施例对本发明进行详细说明。

[0017] 一、本发明首先对轴承振动信号进行多域的特征提取。本文共提取九个时域特征分别为，峰峰值、整流平均值、标准差、峭度、方差、均方根、波形因子、脉冲因子、裕度因子。通过傅里叶变换后对信号进行频域上的特征提取，提取十个频域特征，特征计算公式如表1。结合小波包分解与信息熵理论得到小波包能谱熵和小波包奇异值熵，利用db5小波对原始振动信号进行三层分解，提取出振动信号的时频域特征。

表1 频域特征

特征表达式	特征表达式	特征表达式
$f_{pd1} = \frac{\sum_{k=1}^K s(k)}{K}$	$f_{pd2} = \frac{\sum_{k=1}^K (s(k) - f_{pd1})^2}{K-1}$	$f_{pd3} = \frac{\sum_{k=1}^K (s(k) - f_{pd1})^3}{K (\sqrt{f_{pd2}})^3}$
$f_{pd4} = \frac{\sum_{k=1}^K (s(k) - f_{pd1})^4}{K f_{pd2}^2}$	$f_{pd5} = \frac{\sum_{k=1}^K f_k s(k)}{\sum_{k=1}^K s(k)}$	$f_{pd6} = \sqrt{\frac{\sum_{k=1}^K f_k^2 s(k)}{\sum_{k=1}^K s(k)}}$
$f_{pd7} = \sqrt{\frac{\sum_{k=1}^K f_k^4 s(k)}{\sum_{k=1}^K f_k^2 s(k)}}$	$f_{pd8} = \frac{\sum_{k=1}^K f_k^2 s(k)}{\sqrt{\sum_{k=1}^K s(k) \sum_{k=1}^K f_k^4 s(k)}}$	$f_{pd9} = \frac{\sum_{k=1}^K (f_k - f_{pd5})^3 s(k)}{K f_{pd5}^3}$
$f_{pd10} = \frac{\sum_{k=1}^K (f_k - f_{pd5})^{\frac{1}{2}} s(k)}{K f_{pd6}^3}$		

[0019] 二、本发明通过ISOMAP对多域的高维特征向量集降维，将融合的特征向量作为逻辑回归模型的输入，建立可靠度模型。ISOMAP降维算法与可靠度模型描述如下：

[0020] ISOMAP降维算法：

[0021] (1) 构造近邻图G。对于高维空间数据集X的所有采样点 x_i 和 x_j ($i, j = 1, 2, \dots, n$)

,n为采样点个数),计算采样点 x_i 和 x_j 的欧式距离记为 $d_F(x_i, x_j)$ 。选取每个样本点距离最近的K个点为该样本点的近邻点,将各近邻点连接起来,边长赋值为 $d_F(x_i, x_j)$ 。对所有采样点执行上述步骤,即可得到一个以采样点为节点、以欧氏距离为边的邻域图G。

[0022] (2) 计算所有点对之间的测地距离矩阵D。任意两采样点 x_i 和 x_j 的测地距离为 $d_g(x_i, x_j)$,在邻域图G中采用两采样点间的最短路径 $d_g(x_i, x_j)$ 来近似测地距离。最短路径的以Floyd算法实现。如果两个采样点 x_i 和 x_j 在邻域图G有边,那么距离 $d_g(x_i, x_j) = d_F(x_i, x_j)$,否则, $d_g(x_i, x_j) = \infty$,然后设置i为1,2,3,...,n,任意两个点之间的最短路为

$d_g(x_i, x_j) = \min \{d_g(x_i, x_k) + d_g(x_k, x_j), d_g(x_i, x_j)\}$ 。得到测地距离矩阵D。

[0023] (3) 用MDS算法构建d维向量。将测地距离矩阵D带入MDS算法计算 $\tau D = (-HSH) / 2$,其中H为中心化矩阵, $H = I - ee^T / N$,S为平方距离矩阵, $S = D^2_{x_i, x_j}$ 。对矩阵 τD 进行特征值分解,设 $\Lambda = \text{diag}(\lambda_1, \lambda_2 \Lambda \lambda_d)$ 为特征值构成的对角矩阵,其中 $\lambda_1 \geq \lambda_2 \Lambda \geq \lambda_d$ 。对应的特征向量矩阵为 $V = (\mu_1, \mu_2 \Lambda \mu_d)$ 。

则降维后的数据 $Z = \sqrt{\Lambda} V^T$ 。

[0024] 可靠度模型:

[0025] 通过对滚动轴承的特征提取以及降维,最终得到可以反映滚动轴承运行状态的特征向量集。设t时刻i维特征向量集 $X_j(t) = (x_1(t), x_2(t) \Lambda x_j(t))$,轴承在t时刻正常运行表示为 $y(t) = 1$,失效表示为 $y(t) = 0$ 。根据可靠性定义,将 X_j 作为因变量输入到sigmoid函数,轴承可靠度函数表示为:

$$R(t | X_j) = P(\mathcal{Y}_j = 1 | X_j) = \frac{\exp(\beta_0 + \beta_1 x_1(t) + \beta_2 x_2(t) + \Lambda + \beta_j x_j(t))}{1 + \exp(\beta_0 + \beta_1 x_1(t) + \beta_2 x_2(t) + \Lambda + \beta_j x_j(t))} \quad (1)$$

[0026] 式中 $\beta_0, \beta_1, \Lambda, \beta_j$ 为模型回归系数。设 $g[X(t)]$ 为sigmoid函数的对数变换式,可表示为:

$$g[X(t)] = \ln \frac{P(\mathcal{Y}_j = 1 | X_j)}{1 - P(\mathcal{Y}_j = 1 | X_j)} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \Lambda + \beta_j x_j \quad (2)$$

[0028] 逻辑回归模型为非线性模型,回归系数可通过极大似然估计求得,设

$B = \beta_0, \beta_1, \Lambda, \beta_i$, 对数似然方程如下:

$$[0029] \quad \ln L(B) = \sum [y_j Bx(t) - \ln(1 + \exp(Bx(t)))] \quad (3)$$

[0030] 通过梯度下降法求解似然方程即可得到回归系数, 建立可靠度模型。

[0031] 三、本发明的可靠度预测过程:

[0032] 采用最小二乘支持向量机 (LSSVM) 进行预测。在LSSVM模型中, 正则化参数 γ , 径向基核函数宽度 σ^2 、嵌入维数 m 的选择都对预测效果有很大影响, 参数选取常用的交叉验证法需要大量的试验, 粒子群算法容易陷入局部最优, 导致模型参数选取不准确。本文采用NoCuSa算法同时对lssvm的三个参数 γ 、 σ^2 、 m 进行寻优。选用均方根误差来评价预测效果, 并作为NoCuSa算法的适应度函数, 表达式函数为

$$[0033] \quad f_{RMSE} = \sqrt{\frac{\sum_{i=1}^p (y_i - \hat{y}_i)^2}{p}} \quad (4)$$

[0034] NoCuSa算法步骤如下:

[0035] (1) 随机生成初始宿主巢。设置最大迭代次数 K 。在 D 维空间生成 N 个个体, 其矢量形式为 $X_i = \{x_i^1, \Lambda, x_i^D\}$, $i = 1, \Lambda, N$, 个体生成规则如下:

$$[0036] \quad x_i^j = x_{\min}^j + rand(0,1) \cdot (x_{\max}^j - x_{\min}^j), \quad j = 1, 2, \Lambda, D \quad (5)$$

[0037] (2) 计算适应度值。根据适应度函数 f 计算每个巢的适应度值 f_i , 确定全局最优的巢 g 。

[0038] (3) 更新巢。根据莱维飞行和量子机制定义更新规则, 由式(6)产生新的巢, 并计算每个巢的适应度值 $f(X_i)$ 。

$$[0039] \quad X_{i,k+1} = \begin{cases} X_{i,k} + \frac{\alpha \cdot U}{|v|^\beta} [X_{i,k} - g_k] & sr \in (\frac{2}{3}, 1] \\ \bar{X}_{i,k} + L[\bar{X}_k - X_{i,k}] & sr \in (\frac{1}{3}, \frac{2}{3}] \\ X_{i,k} + \varepsilon[g_k - X_{i,k}] & otherwise \end{cases} \quad (6)$$

[0040] 式中 k 表示当前迭代次数, α 是一个常数。 U 和 v 是服从期望为0, 标准差分别为 σ_u 和 σ_v 的正态分布随机数, 其中 $\sigma_v = 1$, σ_u 由式(7)定义。

$$[0041] \quad \sigma_{\beta} = \left[\frac{\sin(\pi\beta/2)\Gamma(1+\beta)}{2^{(\beta-1)/2}\beta\Gamma(\frac{1+\beta}{2})} \right]^{1/\beta} \quad (7)$$

[0042] 式中 β 是一个常数, $\Gamma(\cdot)$ 是gamma函数。在式(6)中, $\bar{X}_{i,x}$ 是当前迭代过程中所有巢 $X_{i,x}$ 位置的平均值, $L = \delta \ln(1/\eta)$, $\varepsilon = \delta \exp(\eta)$ 其中 δ 是一个定值, η 和sr是服从区间为[0,1]均匀分布的随机数。

[0043] (4) 选择被抛弃的巢。通过发现概率 P_a 代替被主鸟遗弃的巢,更新规则如式(8)。

$$[0044] \quad X_{i,x+1} = \begin{cases} X_{i,x} + r(x_j - x_j) & \text{if } P > P_a \\ X_{i,x} & \text{else} \end{cases} \quad (8)$$

[0045] 式中 X_i , X_j 是从当前代中随机选择的巢,P和r都是区间[0,1]中的随机数。计算被发现巢的适应度值 f' ,若新的适应度值 $f' < f_j$ 则用 $X_{i,x+1}'$ 代替 $X_{i,x+1}$ 。确定当前迭代过程中全局最优的巢g。

[0046] (5) 进入迭代过程,重复执行步骤(3)~(4),直至达到最大迭代次数。

[0047] 通过NoCuSa算法的到LSSVM的最优模型参数,完成可靠度预测。