



(12)发明专利申请

(10)申请公布号 CN 107560851 A

(43)申请公布日 2018.01.09

(21)申请号 201710750804.7

(22)申请日 2017.08.28

(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 汤杰

(74)专利代理机构 安徽省合肥新安专利代理有
限责任公司 34101

代理人 何梅生

(51) Int. Cl.

G01M 13/04(2006.01)

G06N 3/12(2006.01)

权利要求书2页 说明书7页 附图6页

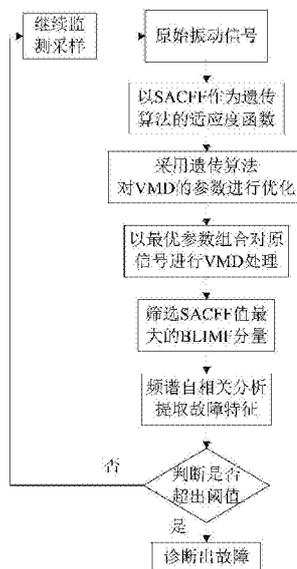
(54)发明名称

滚动轴承微弱故障特征早期提取方法

(57)摘要

本发明公开了一种滚动轴承微弱故障特征早期提取方法,利用传感器拾取运行工况下的滚动轴承振动信号作为待分析信号,以频谱自相关函数的频谱自相关特征因子SACFF为适应度函数,采用遗传算法优化搜索变分模态分解参数;选取遗传算法优化搜索得到的参数组合对待分析信号进行VMD处理,得到有限带宽本征模态函数,从中选择与局部极大频谱自相关特征因子相对应的分量进行频谱自相关分析,得到频谱自相关函数图;若频谱自相关函数图中故障特征频率或其倍频处峰值达到设定阈值,则表明滚动轴承发生了早期微弱故障。本发明结合VMD和频谱自相关分析的各自优点,突破频谱自相关分析方法在提取轴承微弱故障特征信息时的局限性,实现了滚动轴承微弱故障的更早诊断的目的。

CN 107560851 A



1. 滚动轴承微弱故障特征早期提取方法,其特征是按如下步骤进行:

步骤1、利用振动加速度传感器拾取运行工况下的滚动轴承振动信号作为待分析信号 $x(t)$, $t=1, 2, 3, \dots, T$, T 为信号长度;

步骤2、以频谱自相关函数的频谱自相关特征因子SACFF作为适应度函数,采用遗传算法优化搜索变分模态分解VMD参数;

步骤3、选取遗传算法优化搜索过程中储存的每代局部极大频谱自相关特征因子LMSACFF中最大值所对应的参数组合 (α_0, K_0, τ_0) 对待分析信号 $x(t)$ 进行VMD处理,得到 K_0 个有限带宽本征模态函数BLIMF,并从 K_0 个BLIMF中选择与局部极大频谱自相关特征因子LMSACFF相对应的分量 B_1 进行频谱自相关分析,得到分量 B_1 的频谱自相关函数图;

α_0 为VMD参数中惩罚因子最优值, K_0 为VMD参数中分解层数最优值, τ_0 为VMD参数中拉格朗日乘子更新步长最优值;

步骤4、判断所述频谱自相关函数图中故障特征频率或其倍频处峰值是否达到设定阈值 δ , $\delta=0.1$,若达到设定阈值 δ ,则表明滚动轴承发生了早期微弱故障。

2. 根据权利要求1所述的滚动轴承微弱故障特征早期提取方法,其特征是所述步骤2中频谱自相关特征因子SACFF定义为:

$$SACFF = \frac{RMS[|R_x(f_n)| - E(|R_x(v)|)]}{STD(|R_x(v)|)},$$

$R_x(v)$ 为待分析信号 $x(t)$ 的频谱自相关函数; $|R_x(v)|$ 为频谱自相关系数;

$f_n = f_0, 2f_0, 3f_0, \dots, Mf_0$; f_0 为滚动轴承故障特征频率, M 为故障特征频率的倍数;

$|R_x(f_n)|$ 为故障特征频率处的频谱自相关系数, $STD(|R_x(v)|)$ 为频谱自相关系数的标准差; $E(|R_x(v)|)$ 为频谱自相关系数的均值, $RMS[]$ 表达为求取有效值。

3. 根据权利要求1所述的滚动轴承微弱故障特征早期提取方法,其特征是:所述步骤2中采用遗传算法优化搜索VMD参数是按如下过程进行:

步骤2.1、种群初始化,针对VMD参数 (α, K, τ) 进行初始化编码,随机产生一群体个体数为 Q 的初始种群;初始化编码采用2进制8位编码,染色体长度为24位;

α 为VMD参数中惩罚因子, K 为VMD参数中分解层数, τ 为VMD参数中拉格朗日乘子更新步长, α 的搜索范围为500~1000, K 的搜索范围为5~15, τ 的搜索范围为0.1~1;

步骤2.2、使用初始种群中的每组参数分别对待分析信号 $x(t)$ 进行VMD处理,得到 Q 组若干有限带宽本征模态函数BLIMF;

步骤2.3、计算每组参数所对应的有限带宽本征模态函数BLIMF的SACFF值,以最大SACFF值所对应的BLIMF分量作为使用相应一组参数进行VMD处理后的最优分量,其最大SACFF值称为个体极大频谱自相关特征因子IMSACFF;每一代遍历完成后得到 Q 个IMSACFF值,筛选 Q 个IMSACFF值中最大值作为相应一代群体的最优值 I_{max} ,以最优值 I_{max} 为局部极大频谱自相关特征因子LMSACFF,存储LMSACFF值和相应的参数组合 (α, K, τ) ;

步骤2.4、按照遗传概率0.8选择IMSACFF值较大的个体,并直接遗传给下一代;以交叉概率0.75和变异概率0.1进行操作产生新的个体,将新的个体插入到上代种群中形成新种群;

步骤2.5、以步骤2.4获得的新种群替代步骤2.2的初始种群,重复步骤2.2-步骤2.4;当

遗传代数达到设定值N时停止迭代;得到N个LMSCAFF值和对应的N组参数组合 (α, K, τ) ,完成VMD参数的搜索。

4. 根据权利要求1所述的滚动轴承微弱故障特征早期提取方法,其特征是所述频谱自相关函数的定义为:

待分析信号 $x(t)$ 的傅里叶变换为 $X(f)$,即:
$$X(f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi ft} dt$$
, e 为自然常数, f 为分析频率, j 为虚数单位, π 为圆周率, dt 表示对时间轴的微分, $\int_{-\infty}^{+\infty}$ 表示从负无穷到正无穷积分;则待分析信号 $x(t)$ 的频谱自相关函数 $R_x(v)$ 为:

$$R_x(v) = \lim_{f_s \rightarrow \infty} \frac{2}{f_s} \int_0^{f_s/2} X(f)X(f+v)^* df,$$

其中: v 为频率延迟量, $X(f+v)^*$ 为 $X(f+v)$ 的共轭, $X(f+v)$ 表示对 $X(f)$ 频率延迟 v , f 为分析频率, $0 \leq f \leq f_s/2$, f_s 为采样频率, df 表示对频率轴的微分, $\int_0^{f_s/2}$ 表示0到 $f_s/2$ 的积分;由于频谱自相关函数 $R_x(v)$ 为复数,因此频谱自相关函数 $R_x(v)$ 的模为自相关系数,自相关系数越大信号间相关性越强。

滚动轴承微弱故障特征早期提取方法

技术领域

[0001] 本发明涉及滚动轴承微弱故障特征早期提取方法,更具体地说是一种基于参数优化变分模态分解和频谱自相关分析结合的滚动轴承微弱故障特征早期提取方法。

背景技术

[0002] 滚动轴承是机械设备重要的基础部件,其工作状态正常与否直接影响设备的运行安全;一般来说,滚动轴承在全寿命运行范围内总会经历正常运行,早期微弱故障,严重故障的过程;早期发现滚动轴承微弱机械故障特征并及时预报,可避免重大经济损失和人员伤亡。滚动轴承早期机械故障孕育期的特征信号具有微弱、继发的特点,加之受强背景噪声干扰,其故障特征往往表现得非常微弱甚至完全被干扰噪声淹没,故滚动轴承微弱故障特征早期提取一直是故障监测与诊断领域的研究难点和热点。

[0003] 近年来,针对滚动轴承微弱故障特征提取的问题,国内外学者进行了大量的研究;不少学者提出了很多有效的方法,以小波分解(Yan.Ruqiang,Gao.Robert X,Chen.Xuefeng.Wavelets for fault diagnosis of rotary machines:A review with applications[J].Signal Processing,2014,96:Part A:1-15),经验模态分解(EMD)(Huang Norden E,Shen Zheng,Long Steven R.et al.The empirical mode decomposition and Hilbert spectrum for non-linear and non-stationary time series analysis[J],Proc.R.Soc.Lond.A.1998,454(1971):903-995),局部均值分解(LMD)(J.S.Smith,The local mean decomposition and its application to EEG perception data[J].Journal of the Royal Society Interface[J],2005,2(5):443-445),变分模态分解(VMD)(Dragomiretskiy K,Zosso D.Variational mode decomposition[J].IEEE Transactions on signal processing,2014,62(3):531-544)为代表的自适应信号处理方法在滚动轴承微弱故障特征提取方面得到了广泛的应用。虽然这些理论和方法在故障诊断研究中取得了一定的进展,但其仍存在不足之处。其中,小波分解需要选取合适的小波基和分解层数,这使得小波分解难以取得较好的工程应用。EMD和LMD方法就其本质而言,均可看作是一个二进制滤波器组,其频带分割特性使得此类方法在处理轴承早期故障信号特征提取时存在的模态混叠、过包络、欠包络、边界效应等一系列问题难以从根本上得到解决。变分模态分解(Variational Mode Decomposition,简称VMD)是一种新颖的非递归、变分分解的信号处理方法,VMD将信号分解转化为非递归、变分分解的模式,因此能够缓解或避免EMD和LMD方法中存在的一系列不足;其实质是多个自适应维纳滤波器组,具有更好的噪声鲁棒性,能够从低信噪比原始信号中剥离出包含丰富特征信息的信号分量。但在VMD处理信号时需要事先设定VMD的参数,使得VMD在实际应用中存在一定的局限性。

[0004] 国内以VMD为基础的滚动轴承故障诊断的发明专利申请有:发明名称:基于变分模态分解和排列熵的滚动轴承故障诊断方法,申请号:2016103252978,公开号:CN105758644A,其是以VMD处理的各分量排列熵构建高维特征向量,利用高维特征向量训练

SVM进行特征识别；发明名称：基于变模态分解的滚动轴承故障诊断方法，申请号：2016103141640，公开号：CN106017926A，其利用预测滤波和变分模态分解进行滚动轴承故障诊断；发明名称：一种滚动轴承的VMD、谱峭度和平滑迭代包络分析方法，申请号：201610492446X，公开号：CN106198015A，其将变分模态分解，多重分形去趋势项，谱峭度滤波，平滑迭代包络分析相结合用于滚动轴承故障诊断。但在这些方法中均未考虑VMD参数设置对分解结果的影响，以及未涉及早期微弱故障特征提取的问题。

[0005] 频谱自相关分析(Spectrum Auto-correlation,简称SAC)是一种不同于解调原理的故障特征提取方法，是针对故障的冲击特征采取的有针对性的方法，特别适合于轴承点蚀、剥落等局部故障诊断。但相关研究表明频谱自相关分析在故障信号不占主导作用时存在局限性，即难以实现微弱故障特征的提取。

发明内容

[0006] 本发明是为避免上述现有技术所存在的不足，提供一种滚动轴承微弱故障特征早期提取方法，克服VMD参数选取困难和频谱自相关分析难以提取微弱故障特征的问题，将两者相结合实现滚动轴承微弱故障特征早期提取，达到更早诊断出微弱故障的目的。

[0007] 本发明为解决技术问题采用如下技术方案：

[0008] 本发明滚动轴承微弱故障特征早期提取方法的特点是按如下步骤进行：

[0009] 步骤1、利用振动加速度传感器拾取运行工况下的滚动轴承振动信号作为待分析信号 $x(t)$ ， $t=1,2,3,\dots,T$ ， T 为信号长度；

[0010] 步骤2、以频谱自相关函数的频谱自相关特征因子SACFF作为适应度函数，采用遗传算法优化搜索变分模态分解VMD参数；

[0011] 步骤3、选取遗传算法优化搜索过程中储存的每代局部极大频谱自相关特征因子LMSACFF中最大值所对应的参数组合 (α_0, K_0, τ_0) 对待分析信号 $x(t)$ 进行VMD处理，得到 K_0 个有限带宽本征模态函数BLIMF，并从 K_0 个BLIMF中选择与局部极大频谱自相关特征因子LMSACFF相对应的分量 $B1$ 进行频谱自相关分析，得到分量 $B1$ 的频谱自相关函数图；

[0012] α_0 为VMD参数中惩罚因子最优值， K_0 为VMD参数中分解层数最优值， τ_0 为VMD参数中拉格朗日乘子更新步长最优值；

[0013] 步骤4、判断所述频谱自相关函数图中故障特征频率或其倍频处峰值是否达到设定阈值 δ ， $\delta=0.1$ ，若达到设定阈值 δ ，则表明滚动轴承发生了早期微弱故障。

[0014] 本发明滚动轴承微弱故障特征早期提取方法的特点也在于：所述步骤2中频谱自相关特征因子SACFF定义为：

$$[0015] \quad \text{SACFF} = \frac{\text{RMS} \left[|R_x(f_n)| - E(|R_x(v)|) \right]}{\text{STD}(|R_x(v)|)},$$

[0016] $R_x(v)$ 为待分析信号 $x(t)$ 的频谱自相关函数； $|R_x(v)|$ 为频谱自相关系数；

[0017] $f_n = f_0, 2f_0, 3f_0, \dots, Mf_0$ ； f_0 为滚动轴承故障特征频率， M 为故障特征频率的倍数；

[0018] $|R_x(f_n)|$ 为故障特征频率处的频谱自相关系数， $\text{STD}(|R_x(v)|)$ 为频谱自相关系数的标准差； $E(|R_x(v)|)$ 为频谱自相关系数的均值， $\text{RMS}[\]$ 表达为求取有效值。

[0019] 本发明滚动轴承微弱故障特征早期提取方法的特点也在于：所述步骤2中采用遗

传算法优化搜索VMD参数是按如下过程进行：

[0020] 步骤2.1、种群初始化，针对VMD参数 (α, K, τ) 进行初始化编码，随机产生一群体个体数为Q的初始种群；初始化编码采用2进制8位编码，染色体长度为24位；

[0021] α 为VMD参数中惩罚因子，K为VMD参数中分解层数， τ 为VMD参数中拉格朗日乘子更新步长， α 的搜索范围为500~1000，K的搜索范围为5~15， τ 的搜索范围为0.1~1；

[0022] 步骤2.2、使用初始种群中的每组参数分别对待分析信号 $x(t)$ 进行VMD处理，得到Q组若干有限带宽本征模态函数BLIMF；

[0023] 步骤2.3、计算每组参数所对应的有限带宽本征模态函数BLIMF的SACFF值，以最大SACFF值所对应的BLIMF分量作为使用相应一组参数进行VMD处理后的最优分量，其最大SACFF值称为个体极大频谱自相关特征因子IMSACFF；每一代遍历完成后得到Q个IMSACFF值，筛选Q个IMSACFF值中最大值作为相应一代群体的最优值 I_{max} ，以最优值 I_{max} 为局部极大频谱自相关特征因子LMSACFF，存储LMSACFF值和相应的参数组合 (α, K, τ) ；

[0024] 步骤2.4、按照遗传概率0.8选择IMSACFF值较大的个体，并直接遗传给下一代；以交叉概率0.75和变异概率0.1进行操作产生新的个体，将新的个体插入到上代种群中形成新种群；

[0025] 步骤2.5、以步骤2.4获得的新种群替代步骤2.2的初始种群，重复步骤2.2-步骤2.4；当遗传代数达到设定值N时停止迭代；得到N个LMSACFF值和对应的N组参数组合 (α, K, τ) ，完成VMD参数的搜索。

[0026] 本发明滚动轴承微弱故障特征早期提取方法的特点也在于：所述频谱自相关函数的定义为：

[0027] 待分析信号 $x(t)$ 的傅里叶变换为 $X(f)$ ，即：
$$X(f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi ft} dt$$
， e 为自然常数， f 为分析频率， j 为虚数单位， π 为圆周率， dt 表示对时间轴的微分， $\int_{-\infty}^{+\infty}$ 表示从负无穷到正无穷积分；则待分析信号 $x(t)$ 的频谱自相关函数 $R_x(v)$ 为：

$$R_x(v) = \lim_{f_s \rightarrow \infty} \frac{2}{f_s} \int_0^{f_s/2} X(f)X(f+v)^* df,$$

[0029] 其中： v 为频率延迟量， $X(f+v)^*$ 为 $X(f+v)$ 的共轭， $X(f+v)$ 表示对 $X(f)$ 频率延迟 v ， f 为分析频率， $0 \leq f \leq f_s/2$ ， f_s 为采样频率， df 表示对频率轴的微分， $\int_0^{f_s/2}$ 表示0到 $f_s/2$ 的积分；由于频谱自相关函数 $R_x(v)$ 为复数，因此频谱自相关函数 $R_x(v)$ 的模为自相关系数，自相关系数越大信号间相关性越强。

[0030] 与已有技术相比，本发明有益效果体现在：

[0031] 1、本发明方法结合了VMD和频谱自相关分析各自的优点，突破频谱自相关分析方法在提取轴承微弱故障特征信息时的局限性，既抑制了噪声又充分突出了故障的冲击特性，能更早的提取微弱故障特征，实现更早诊断出滚动轴承微弱故障的目的。

[0032] 2、相对于已有技术中的包络分析，本发明采用频谱自相关分析是针对滚动轴承故障的冲击特征有针对性的方法，适合于轴承点蚀、剥落等局部故障诊断，其方法简单、效果明显，避免了包络分析时带通滤波器设计困难的问题。

[0033] 3、本发明采用变分模态分解对振动信号进行分解,有效避免了EMD和LMD方法处理信号时存在的模态混叠、过包络、欠包络、边界效应等缺点。

[0034] 4、本发明中所采用的以SACFF为适应度函数的遗传算法搜索VMD参数具有客观性,避免了人为选取的主观影响。

[0035] 5、本发明中根据SACFF最大原则选取的BLIMF分量包含较多的故障信息,有利于故障特征的提取。

附图说明

[0036] 图1为本发明方法流程图;

[0037] 图2为本发明方法实施中试验装置结构示意图;

[0038] 图3为本发明方法实施中滚动轴承全寿命运行范围内振动信号峭度变化的趋势图;

[0039] 图4为本发明方法实施中滚动轴承早期故障孕育期的原始振动信号,为图3中4200min时的采样信号;

[0040] 图5为本发明方法实施中原始振动信号的频谱自相关分析,为图4所示原始振动信号的频谱自相关分析;

[0041] 图6为本发明方法实施中遗传算法优化VMD参数过程中局部极大频谱自相关特征因子LMSACFF的变化;

[0042] 图7a、图7b、图7c、图7d、图7e、图7f、图7g、图7h、图7i、图7j和图7k为本发明方法实施中使用遗传算法优化搜索的参数组合对图3中的采样信号进行VMD处理得到的各BLIMF;

[0043] 图8为本发明方法实施中根据SACFF最大原则选取的BLIMF进行频谱自相关分析的结果即为图7中BLIMF10的频谱自相关分析。

具体实施方式

[0044] 参见图1,本实施例中滚动轴承微弱故障特征早期提取方法是按如下步骤进行:

[0045] 步骤1、利用振动加速度传感器拾取运行工况下的滚动轴承振动信号作为待分析信号 $x(t)$, $t=1, 2, 3, \dots, T$, T 为信号长度。

[0046] 步骤2、以频谱自相关函数的频谱自相关特征因子SACFF作为适应度函数,采用遗传算法优化搜索变分模态分解VMD参数,其中SACFF是指Feature Factor of Spectrum Auto-correlation, VMD是指Variational Mode Decomposition。

[0047] 步骤3、选取遗传算法优化搜索过程中储存的每代局部极大频谱自相关特征因子LMSACFF中最大值所对应的参数组合 (α_0, K_0, τ_0) 对待分析信号 $x(t)$ 进行VMD处理,得到 K_0 个有限带宽本征模态函数BLIMF,并从 K_0 个BLIMF中选择与局部极大频谱自相关特征因子LMSACFF相对应的分量B1进行频谱自相关分析,得到分量B1的频谱自相关函数图;LMSACFF是指Local Maximum Feature Factor of Spectrum Auto-correlation, LMSACFF的值越大意味着相应BLIMF中包含的故障信息越丰富,更有利于通过频谱自相关函数图提取故障特征; α_0 为VMD参数中惩罚因子最优值, K_0 为VMD参数中分解层数最优值, τ_0 为VMD参数中拉格朗日乘子更新步长最优值。

[0048] 步骤4、判断所述频谱自相关函数图中故障特征频率或其倍频处峰值是否达到设

定阈值 δ , $\delta=0.1$, 若达到设定阈值 δ , 则表明滚动轴承发生了早期微弱故障。

[0049] 具体实施中, 步骤2中频谱自相关特征因子SACFF定义为:

$$[0050] \quad \text{SACFF} = \frac{\text{RMS} [|R_x(f_n)| - E(|R_x(v)|)]}{\text{STD}(|R_x(v)|)},$$

[0051] $R_x(v)$ 为待分析信号 $x(t)$ 的频谱自相关函数; $|R_x(v)|$ 为频谱自相关系数;

[0052] $f_n = f_0, 2f_0, 3f_0, \dots, Mf_0$, f_0 为滚动轴承故障特征频率, M 为故障特征频率的倍数, 即 M 的取值是根据实际应用中所关注的特征频率谐波数目即特征频率倍数而设定; $|R_x(f_n)|$ 为故障特征频率处的频谱自相关系数, $\text{STD}(|R_x(v)|)$ 为频谱自相关系数的标准差, $E(|R_x(v)|)$ 为频谱自相关系数的均值, $\text{RMS}[\]$ 表达为求取有效值。

[0053] 步骤2中采用遗传算法优化搜索VMD参数是按如下过程进行:

[0054] 2.1、种群初始化, 针对VMD参数 (α, K, τ) 进行初始化编码, 随机产生一群体个体数为 Q 的初始种群; 初始化编码采用2进制8位编码, 染色体长度为24位; α 为VMD参数中惩罚因子, K 为VMD参数中分解层数, τ 为VMD参数中拉格朗日乘子更新步长, α 的搜索范围为500~1000, K 的搜索范围为5~15, τ 的搜索范围为0.1~1。

[0055] 2.2、使用初始种群中的每组参数分别对待分析信号 $x(t)$ 进行VMD处理, 得到 Q 组若干有限带宽本征模态函数BLIMF, BLIMF是指band-limited intrinsic mode Function。

[0056] 2.3、计算每组参数所对应的有限带宽本征模态函数BLIMF的SACFF值, 以最大SACFF值所对应的BLIMF分量作为使用相应一组参数进行VMD处理后的最优分量, 其最大SACFF值称为个体极大频谱自相关特征因子IMSACFF; 每一代遍历完成后得到 Q 个IMSACFF值, 筛选 Q 个IMSACFF值中最大值作为相应一代群体的最优值 I_{\max} , 以最优值 I_{\max} 为局部极大频谱自相关特征因子LMSACFF, 存储LMSACFF值和相应的参数组合 (α, K, τ) ; IMSACFF是指 Individual Maximum Feature Factor of Spectrum Auto-correlation。

[0057] 2.4、按照遗传概率0.8选择IMSACFF值较大的个体, 并直接遗传给下一代; 以交叉概率0.75和变异概率0.1进行操作产生新的个体, 将新的个体插入到上代种群中形成新种群。

[0058] 2.5、以步骤2.4获得的新种群替代步骤2.2的初始种群, 重复步骤2.2-步骤2.4; 当遗传代数达到设定值 N 时停止迭代; 得到 N 个LMSACFF值和对应的 N 组参数组合 (α, K, τ) , 完成VMD参数的搜索; 实际应用中种群个体数越大、遗传代数越大, 采样率越大, 所需的计算量也越大, 因此应合理设置 Q 和 N , 在综合考虑计算量和种群多样性的前提下, Q 取为20~30, N 取为5~10较为适宜。

[0059] 频谱自相关函数的定义为:

[0060] 待分析信号 $x(t)$ 的傅里叶变换为 $X(f)$, 即: $X(f) = \int_{-\infty}^{+\infty} x(t)e^{-j2\pi ft} dt$, e 为自然常数, f 为分析频率, j 为虚数单位, π 为圆周率, dt 表示对时间轴的微分, $\int_{-\infty}^{+\infty}$ 表示从负无穷到正无穷积分; 则待分析信号 $x(t)$ 的频谱自相关函数 $R_x(v)$ 为:

$$[0061] \quad R_x(v) = \lim_{f_s \rightarrow \infty} \frac{2}{f_s} \int_0^{f_s/2} X(f)X(f+v)^* df,$$

[0062] v 为频率延迟量, $X(f+v)^*$ 为 $X(f+v)$ 的共轭, $X(f+v)$ 表示对 $X(f)$ 频率延迟 v , f 为分析

频率, $0 \leq f \leq f_s/2$, f_s 为采样频率, df 表示对频率轴的微分, $\int_0^{f_s/2}$ 表示 0 到 $f_s/2$ 的积分; 由于频谱自相关函数 $R_x(v)$ 为复数, 因此频谱自相关函数 $R_x(v)$ 的模为自相关系数, 自相关系数越大信号间相关性越强。

[0063] VMD 的原理是在频域内迭代搜索变分约束问题的最优解, 最终将待分析信号 $x(t)$ 表示为 K 个有限带宽本征模态函数 BLIMF $u_k(t)$ 之和, 即 $\sum_{k=1}^K u_k(t) = x(t)$, $u_k(t)$ 表示第 k 个

BLIMF, $k=1, 2, \dots, K$; VMD 算法参考文献 (Dragomiretskiy K, Zosso D. Variational mode decomposition [J]. IEEE Transactions on signal processing, 2014, 62 (3) : 531-544); 采用 VMD 对待分析信号 $x(t)$ 进行处理, 避免了 EMD 和 LMD 处理信号时产生的模态混叠、过包络、欠包络、边界效应等确定, 更有利于提取故障特征。

[0064] 实验验证:

[0065] 实验验证数据采用美国辛辛那提大学 NSFI/UCR 智能维护系统中心的滚动轴承全寿命疲劳试验数据库的开放数据, 以便于和其它方法进行比较。

[0066] 图 2 所示为滚动轴承试验台, 在主轴上同时安装了四个轴承, 型号为 ZA-2115 双列滚珠轴承, 参数如表 1 所列; 其中一号轴承 1 和四号轴承 4 固定在机体上, 二号轴承 2 和三号轴承 3 通过杠杆机构向主轴施加大小为 $F=26695\text{N}$ 的恒定径向载荷, 传感器 6 采用 PCB353B33 振动加速度传感器, 设置电机 5 的转速为 2000r/min 。

[0067] 试验过程中, 以 20480Hz 的采样频率每隔 10min 采集一次振动信号, 采样时间 1s 。整个试验过程持续了 164h , 共得到 984 组信号, 每组信号包含 20480 个数据点, 试验结束后对轴承进行分析, 发现一号轴承 1 的外圈出现严重剥落, 对一号轴承基座上实测振动数据进行分析, 根据结构参数和电机转速计算外圈故障特征频率为 236.3Hz 。

[0068] 表 1

滚动轴承参数				
轴承 型号	轴承节 径/mm	滚动体 直径/mm	滚动体 个数	接触角/ $(^\circ)$
ZA2115	71.501	8.407	16	15.17

[0070] 轴承无故障运行时, 振动信号近似接近正态分布, 峭度指标 K 约等于 3。当轴承的滚动表面开始出现损伤时, 其振动信号概率密度增大, 信号幅值偏离正态分布, K 值增加较快。峭度指标的绝对值越大, 轴承故障越严重。根据有关研究结论, 轴承外圈故障对峭度较敏感。因此, 首先对整个试验过程获取的 984 组数据分析其峭度的变化, 以判断其不同时间内的运行状态。整个过程峭度变化趋势如图 3 所示; 图 3 中在 6460min 时采样数据的峭度值有微微增长趋势, 在 7000min 采样点处, 采样数据的峭度值发生了突变, 说明此时轴承运行状态发生了较大的变化, 在 7000min 以后峭度值呈上下波动状态, 直至 9760min 时达到最大, 说明在这个过程中轴承进入加速磨损阶段, 在 9760min 时达到寿命极限。选取 4200min 的采样数据作为滚动轴承早期故障孕育期的原始振动信号进行分析, 其波形如图 4 所示, 图 5 为原始振动信号的频谱自相关分析, 从图 5 中未发现任何与故障特征频率有关的突出成分。

[0071] 采用本发明方法对上述 4200min 的振动信号进行处理, 遗传算法优化 VMD 参数时,

设置二次项惩罚因子 α 的搜索范围为500~1000,分解层数K的搜索范围为5~15,拉格朗日乘子更新步长 τ 的搜索范围为0.1~1,遗传代数为 $N=10$,种群个体数 $Q=30$;遗传算法寻优过程中,每代对应的LMSACFF值的变化如图6,由图6可见在第8代时达到最大值9.25。

[0072] 选取第8代中LMSACFF值所对应的参数组合,即最优参数组合 $a_0=720$, $K_0=11$, $\tau_0=0.95$;对原信号进行VMD处理,其结果如图7a、图7b、图7c、图7d、图7e、图7f、图7g、图7h、图7i、图7j和图7k所示,各BLIMF所对应的SACFF值如表2所列。

[0073] 表2

各BLIMF分量的SACFF指标值	
BLIMF1	1.24
BLIMF2	0.69
BLIMF3	2.13
BLIMF4	2.22
BLIMF5	2.88
BLIMF6	1.81
BLIMF7	1.52
BLIMF8	1.63
BLIMF9	3.50
BLIMF10	9.25
BLIMF11	6.18

[0074]

[0075] 根据表2中SACFF值大小,可以看出BLIMF10即是第8代中LMSACFF所对应的最优BLIMF分量B1。对其进行频谱自相关分析结果如图8;对比图8和图5,可以看出:本发明方法能够有效提取轴承微弱故障特征,主要峰值频率在236.3Hz处,这与轴承外圈早期微弱故障特征频率相对应,该处的频谱自相关系数为0.25。同时,在2倍故障特征频率472.5Hz处呈献出明显尖峰,在3倍故障特征频率707.8Hz处亦能发现突峰;在4200min时采样信号峭度值无变化是由于此时属于早期故障的孕育期,单纯的频谱自相关分析并不能将特征提取出来,采用本发明方法极大提高早期故障诊断的准确率。

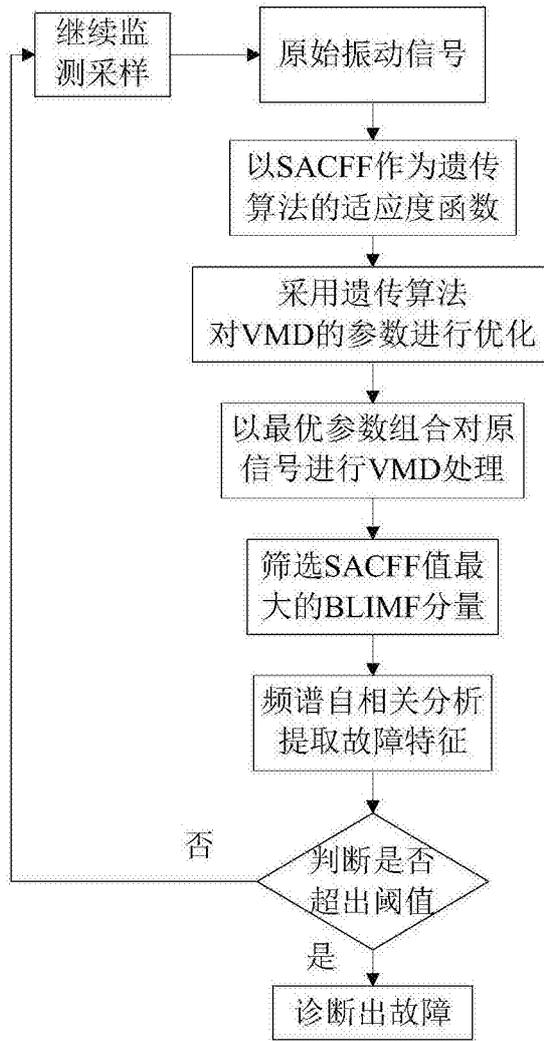


图1

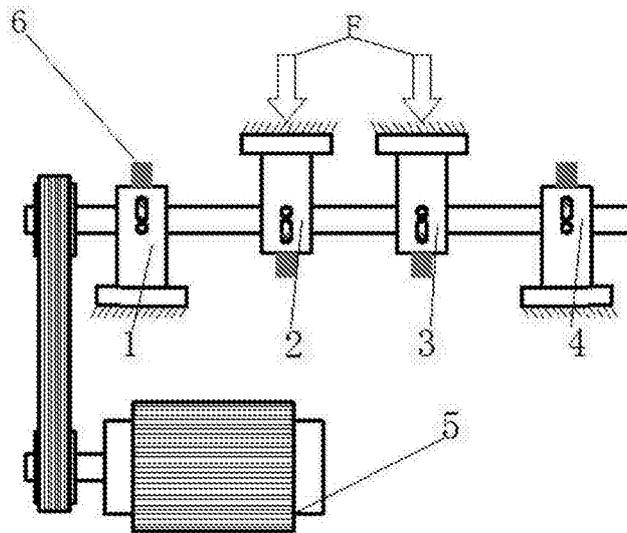


图2

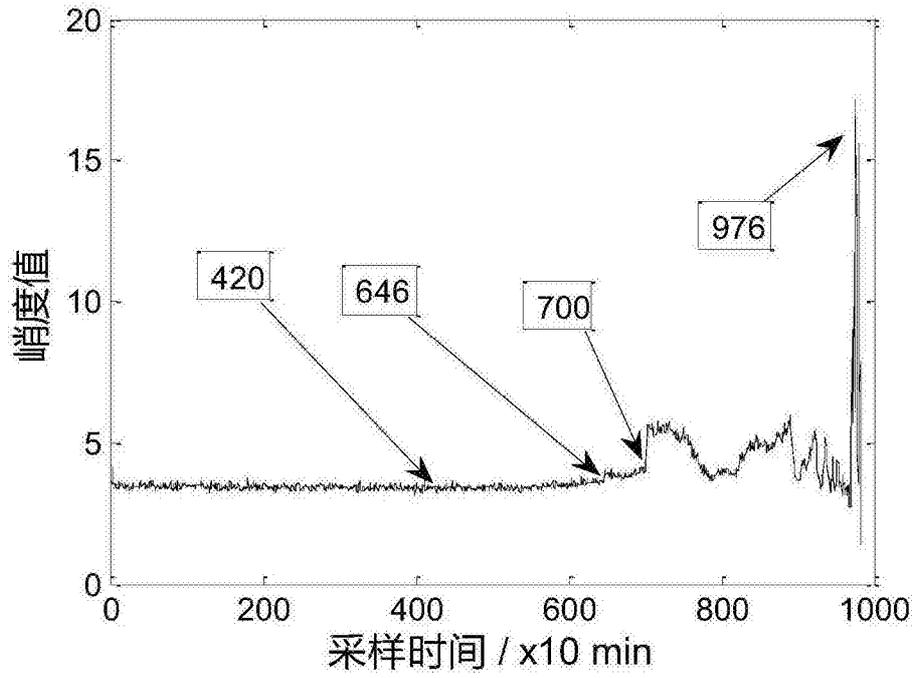


图3

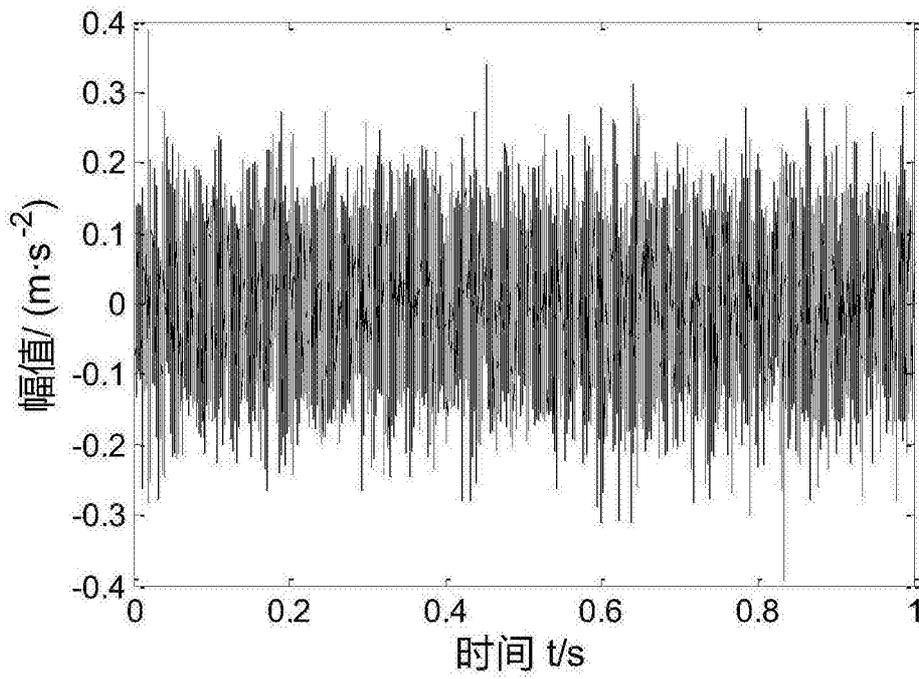


图4

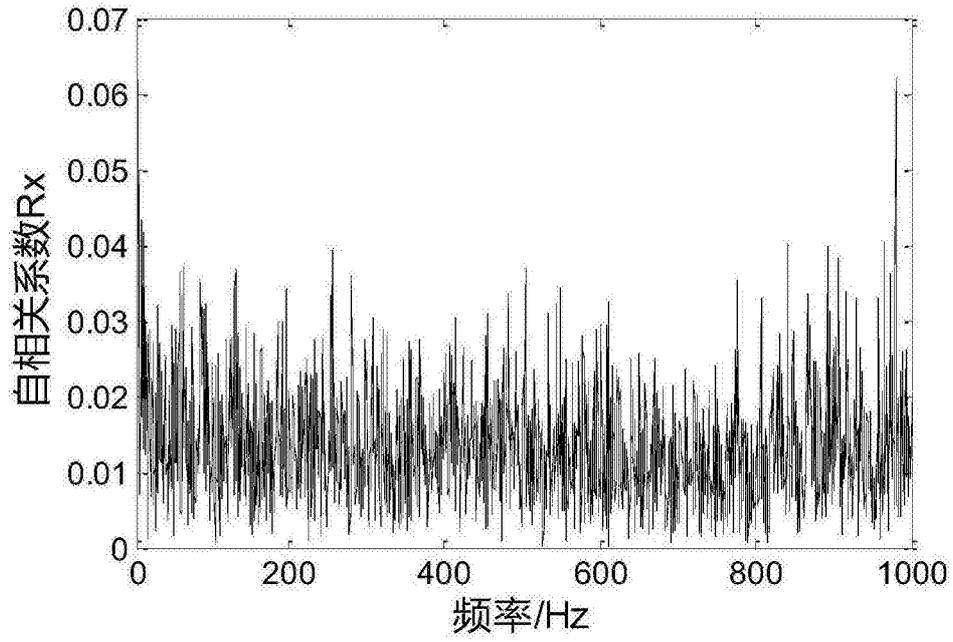


图5

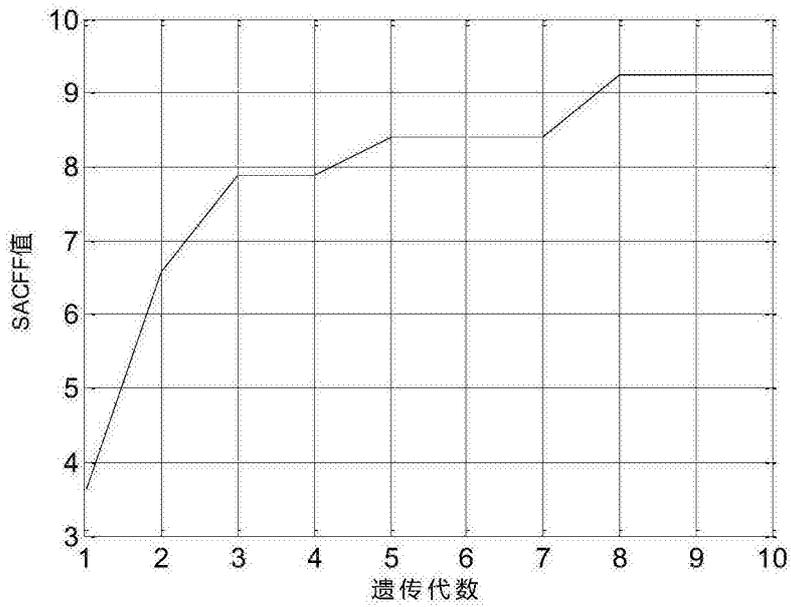


图6

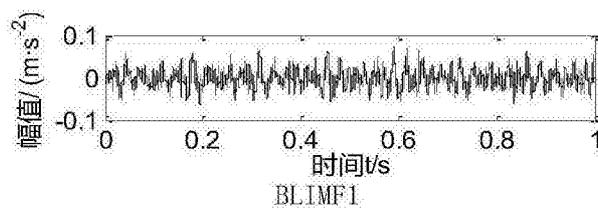


图7a

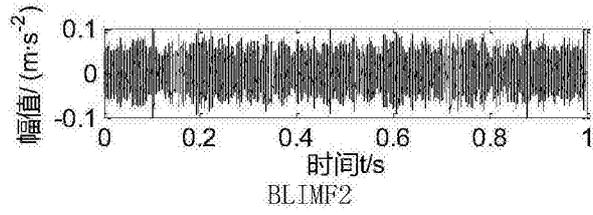


图7b

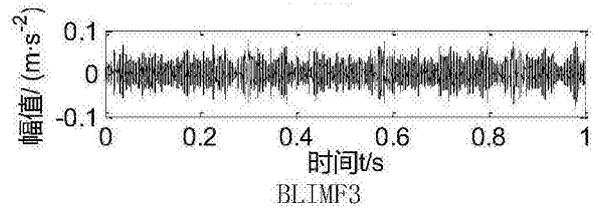


图7c

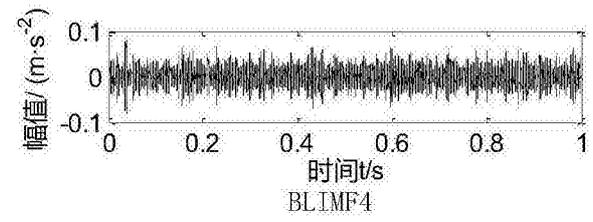


图7d

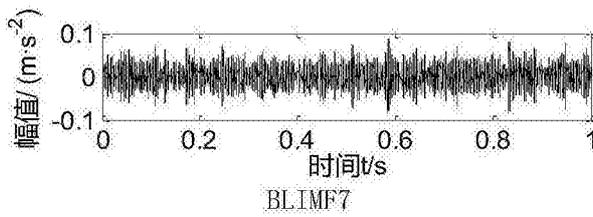


图7g

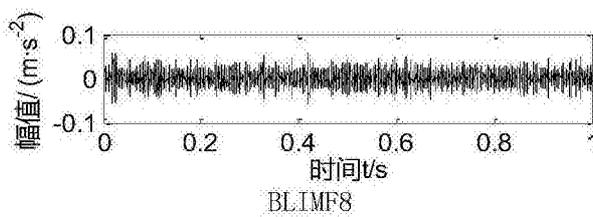


图7h

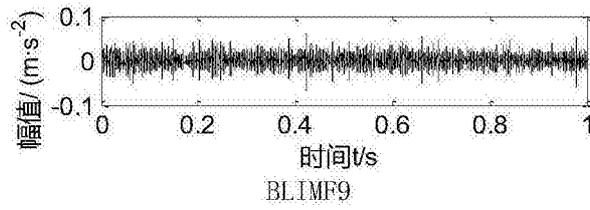


图7i

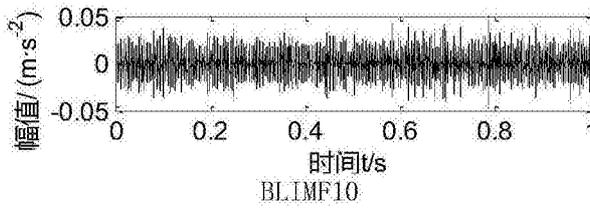


图7j

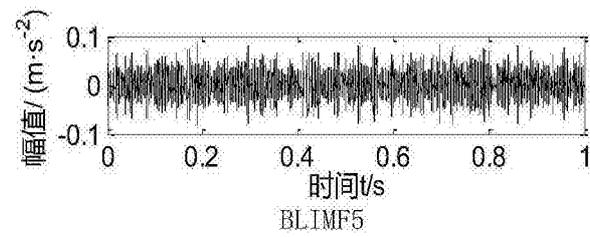


图7e

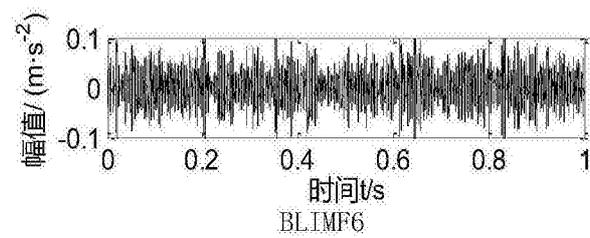


图7f

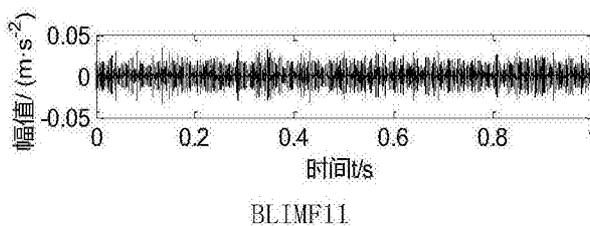


图7k

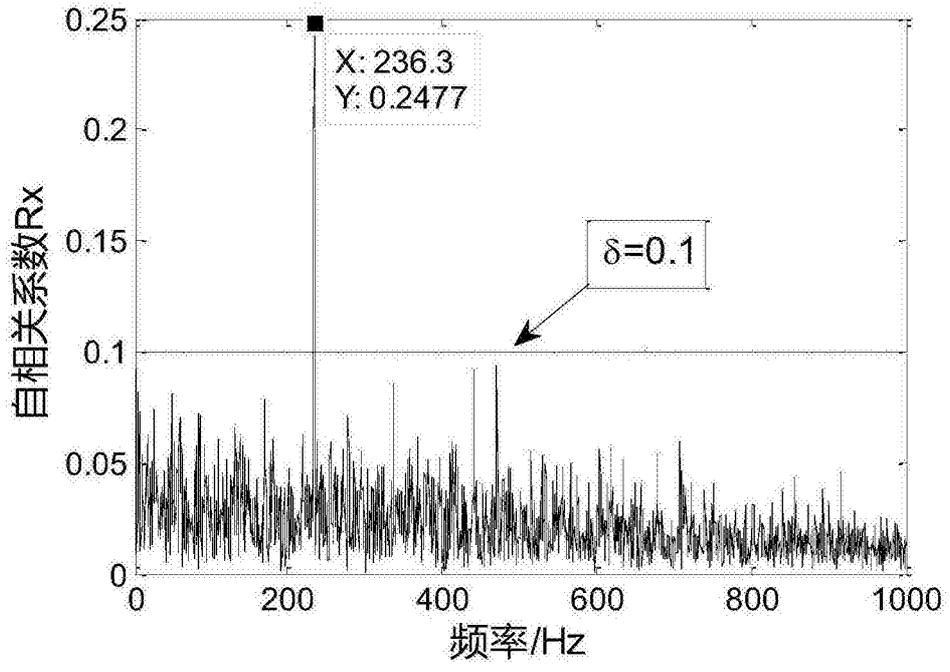


图8