

DOI: 10.13382/j.jemi.B2103931

基于 ACMD 和脊检测的滚动轴承非平稳故障诊断*

刘 奇^{1,2} 王衍学^{1,2}

(1. 北京建筑大学 机电与车辆工程学院 北京 100044; 2. 北京建筑大学 城市轨道交通车辆
服役性能保障重点实验室 北京 100044)

摘 要:针对非平稳状况滚动轴承振动信号易受速度波动、幅值或频率调制、噪声和其他无关分量的干扰,导致生成的时频面复杂,难以识别滚动轴承故障特征频率等问题,提出一种新的基于自适应调频模式分解和脊检测相结合的方法。所提出的方法构建了高分辨率的时频表示,提升了诊断的准确度,而且具有非常强的自适应性。通过对不同健康状况滚动轴承振动信号分析发现,所提方法非常适合于变工况下的滚动轴承故障诊断,且诊断效果优于最新发展的时频分析方法。

关键词: 自适应调频模式分解;非平稳;滚动轴承;故障诊断;时频分析

中图分类号: TH133.3 **文献标识码:** A **国家标准学科分类代码:** 460.40

Fault diagnosis of non-stationary rolling bearing based on adaptive chirp mode decomposition and ridge detection

Liu Qi^{1,2} Wang Yanxue^{1,2}

(1. School of Mechanical-Electronic and Vehicle Engineering, Beijing University of Civil Engineering and Architecture, Beijing 100044, China; 2. Beijing Key Laboratory of Performance Guarantee on Urban Rail Transit Vehicles, Beijing University of Civil Engineering and Architecture, Beijing 100044, China)

Abstract: In view of the fact that the vibration signal of rolling bearing under non-stationary conditions is vulnerable to the interference of velocity fluctuation, amplitude or frequency modulation, noise and other irrelevant components, which leads to the complexity of the generated time-frequency plane, and makes it difficult to identify the fault characteristic frequency of rolling bearing. A novel method based on adaptive chirp mode decomposition and ridge detection is proposed. The proposed method constructs a high-resolution time-frequency representation, improves the accuracy of diagnosis, and has very strong adaptability. Through the analysis of the vibration signals of rolling bearing with different health conditions, it is found that the proposed method is very suitable for fault diagnosis of rolling bearing under variable speed conditions, and the diagnosis effect is better than the newly developed time-frequency analysis method.

Keywords: adaptive chirp mode decomposition; non-stationary; rolling bearing; fault diagnosis; time-frequency analysis

0 引 言

滚动轴承是旋转机械非常重要的部件,它的故障是导致机器停机的主要原因之一^[1-5]。变工况、重负载等因素使得滚动轴承极易发生故障。另外,由于变转速、幅值和频率调制、噪声和其他分量的干扰,给滚动轴承的故障诊断带来了巨大挑战。因此,变工况下的滚动轴承故障诊断具有非常重要的意义。

一些学者和研究机构对平稳状况下的滚动轴承故障诊断进行了充分研究。钟先友等^[6]首先使用迭代滤波对振动信号进行自适应分解,然后基于快速谱峭度方法确定了信号的最佳滤出频带,最终成功提取了滚动轴承的微弱特征。徐可等^[7]对经验模态分解(EMD)方法进行改进,并将其与粒子群优化算法(PSO)优化的支持向量机(SVM)结合,成功实现滚动轴承的智能故障诊断。杜冬梅等^[8]提出基于峭度-歪度的局部均值分解筛分方法,并与增强包络谱相结合,发现该方法可以有效对信号进

收稿日期:2021-01-24 Received Date: 2021-01-24

* 基金项目:国家自然科学基金(51875032,61463010,51475098)、北京建筑大学2021年度研究生创新项目资助

行降噪,实现轴承的特征增强。Zhang 等^[9]利用变分模态分解(VMD)方法开发了一种用于去噪和非平稳特征提取的新型混合故障诊断方法,通过仿真和实际轴承振动信号的分析验证了所提方法的优异性能。在平稳工况下,这些方法优势明显,易实现轴承的故障诊断。然而,机器运行过程中,难免会出现升速或降速等非平稳工况,从而导致以上方法的失效。

对于变工况滚动轴承故障诊断,大致可以通过两个途径进行。1)利用阶次跟踪技术将时域的变速信号重采样为角度域下的等速信号,以消除速度波动,然后使用平稳工况的诊断方法进行分析。Wang 等^[10]利用计算阶次跟踪技术在角域下对非平稳振动信号进行重采样,然后使用变分模态分解方法对重采样信号进行分解,实验结果表明所提方法可以很好地检测变速条件下的轴承故障。然而,基于阶次跟踪技术的方法不仅需要转速作为参考,而且还会在不同域的转换过程中引入插值误差,这极大限值了该方法的使用。2)使用时频分析方法生成待分析信号的时频表示,并在时频结果中提取轴承故障特征频率,确定故障类型。传统的时频分析方法,短时傅里叶变换(short time Fourier transform, STFT)由于海森堡不确定原理导致需要在时间和频率分辨率之间进行取舍;魏格纳维尔分布则遭受了严重的外部 and 内部干扰。时频分布后处理技术的发展解决了其中一部分问题。同步挤压变换(synchrosqueezing transform, SST)^[11]由于不仅能增强时频能量聚集性,而且很容易重构信号,因此被广泛应用于机械设备的故障诊断。同步提取变换(synchroextracting transform, SET)^[12]是为解决 SST 噪声鲁棒性差而提出的又一种后处理方法。随后,Tu 等^[13]将该方法推导至二阶形式,并将其成功应用于变速状况的轴承故障诊断。通过实验发现,与传统的 SST 相比,所提的方法能得到更好的效果。然而,由于幅值和频率调制、其他无关分量和噪声等干扰,基于时频分析方法生成的时频图,存在时频分辨率低等问题,这大大增加了误判和错判的概率。

最近,Chen 等^[14]提出了非线性调频模式分解方法。利用解调技术,该方法可以将宽带的非线性调频信号转化为窄带信号。通过求解优化问题,可以同时提取信号的所有分量。然而,仍存在一些问题需要被解决,如所有分量及对应的瞬时频率(instantaneous frequency, IF)需提前被提供、带宽系数无法自适应更新、算法不稳定等。因此,自适应调频模式分解(adaptive chirp mode decomposition, ACMD)^[15-16]方法被发展,有效解决了存在的问题。更令人鼓舞的是,ACMD 可以获取各分量信号的 IF、瞬时幅值(instantaneous amplitude, IA)等信息,因此可以构建高分辨率的时频表示,这对机械设备的故障诊断具有重要意义。

针对变工况下的滚动轴承故障诊断,提出一种全新的基于 ACMD 和脊线检测算法相结合的方法。脊检测算法用于提供分解信号时所需的初始 IF 信息,从而避免人为干扰。利用获取到的初始 IF,ACMD 可将该分量从原始信号中分离出来。将前一次提取的分量从原始信号中去除可得到剩余信号,随后把剩余信号当作原始信号继续下个分量的分解。经 K 次循环后,ACMD 可以分解出 K 个信号分量。最后,基于各分量信号的 IF 和 IA,可以构建高分辨率的理想时频分布。该时频图只包含与轴承故障相关的信息,其他无关分量和噪声都被排除在外。因此,所提方法可以极大提升诊断的准确度。通过对不同健康状况的变速滚动轴承振动信号分析发现,与最新发展的时频分析方法相比,本文所提方法更加适合于变工况下的滚动轴承故障诊断。

1 基本理论

1.1 自适应调频模式分解

一个非平稳的振动信号可以被建模为幅值调制和频率调制的信号,且一个信号中往往包含多个分量。因此,含 m 个分量的非平稳信号 $y(t)$ 可被建模为^[15]:

$$y(t) = \sum_{i=1}^m y_i(t) = \sum_{i=1}^m A_i(t) \cos(2\pi \int_0^t f_i(\tau) d\tau + \theta_i) \quad (1)$$

式中: A_i 、 f_i 和 θ_i 分别为第 i 个分量的 IA、IF 和初始相位。经解调技术,一个宽带信号可以被转化为窄带信号。对式(1)使用解调技术,结果为:

$$y(t) = \sum_{i=1}^m p_i(t) \cos(2\pi \int_0^t \tilde{f}_i(\tau) d\tau) + q_i(t) \sin(2\pi \int_0^t \tilde{f}_i(\tau) d\tau) \quad (2)$$

且:

$$p_i(t) = A_i(t) \cos(2\pi \int_0^t (f_i(\tau) - \tilde{f}_i(\tau)) d\tau + \theta_i) \quad (3)$$

$$q_i(t) = -A_i(t) \sin(2\pi \int_0^t (f_i(\tau) - \tilde{f}_i(\tau)) d\tau + \theta_i) \quad (4)$$

式中: $\cos(2\pi \int_0^t (\tilde{f}_i(\tau)) d\tau)$ 和 $\sin(2\pi \int_0^t (\tilde{f}_i(\tau)) d\tau)$ 为两个解调算子; $\tilde{f}_i(t)$ 为解调算子的频率函数; $p_i(t)$ 和 $q_i(t)$ 为解调后的信号,他们被用于恢复各分量信号的 IA。

$$A_i(t) = \sqrt{p_i^2(t) + q_i^2(t)} \quad (5)$$

由式(3)和(4)可知,当 $f_i(\tau) = \tilde{f}_i(\tau)$ 时, $p_i(t)$ 和 $q_i(t)$ 将变成两个具有最窄频带的纯幅值调制信号。ACMD 通过最小化 $p_i(t)$ 和 $q_i(t)$ 的带宽来提取目标分量,并估计该分量的 IF,此过程为:

$$\min_{\{p_i(t), \{q_i(t)\}, \{\tilde{f}_i(t)\}} \{ \|p_i''(t)\|_2^2 + \|q_i''(t)\|_2^2 + \alpha \|y(t) - y_i(t)\|_2^2 \}$$

$$\text{s. t. } y_i(t) = p_i(t) \cos(2\pi \int_0^t \tilde{f}_i(\tau) d\tau) +$$

$$q_i(t) \sin(2\pi \int_0^t \tilde{f}_i(\tau) d\tau) \quad (6)$$

式中: $y(t)$ 表示输入的信号; $y_i(t)$ 为提取的目标分量; $\|\cdot\|_2$ 表示 l2 范数; $\|y(t) - y_i(t)\|_2^2$ 为去除估计分量后剩余的能量; α 为权重因数。考虑计算机可以处理的信号形式, 在离散时间 $t = t_0, \dots, t_{N-1}$ 下对测得的信号进行采样, N 为采样数量。因此, 式(6)改写为:

$$\min_{\{p_i, \{q_i\}, \{\tilde{f}_i\}} \{ \|\Theta v_i\|_2^2 + \alpha \|y - G_i v_i\|_2^2 \} \quad (7)$$

式中: $\Theta = \begin{bmatrix} \Omega & 0 \\ 0 & \Omega \end{bmatrix}$, Ω 为二阶差分矩阵, $v_i = [p_i^T, q_i^T]^T$, $y = [y(t_0), \dots, y(t_{N-1})]^T$, $G_i = [C_i, S_i]$ 。其中, $C_i = \text{diag}[\cos(\varphi_i(t_0)), \dots, \cos(\varphi_i(t_{N-1}))]$, $S_i = \text{diag}[\sin(\varphi_i(t_0)), \dots, \sin(\varphi_i(t_{N-1}))]$, 且 $\varphi_i(t) = 2\pi \int_0^t \tilde{f}_i(\tau) d\tau$ 。

迭代算法可以用于交替更新程序执行过程中产生的每个中间变量, 最终实现对优化问题式(7)的求解。经过 j 次迭代后, 第 i 个分量信号的 IF 被更新为:

$$f_i^{j+1} = f_i^j + (\frac{1}{\beta} \Omega^T \Omega + I)^{-1} \Delta f_i^j \quad (8)$$

式中: $f_i^j = [\tilde{f}_i^j(t_0), \dots, \tilde{f}_i^j(t_{N-1})]^T$, Δf_i^j 为频率增量矩阵, I 为单位矩阵, β 为惩罚系数。提取信号第 i 个分量 $\tilde{y}_i(t)$ 后, 基于递归思想, 使用原始信号减去 $\tilde{y}_i(t)$, 然后将剩余信号 $R_i = y(t) - \tilde{y}_i(t)$ 作为原始信号, 可进行下个分量的提取。经 K 次分解后, 信号 $y(t)$ 被分解为:

$$y(t) = \sum_{i=1}^K \tilde{y}_i(t) + R_K(t) \quad (9)$$

综上所述可知, ACMD 只需输入某个待分解分量的 IF, 而不需要在一开始就提供所有分量的 IF, 因此使用起来更加灵活, 更加具有适应性, 算法也更为稳定。下面将介绍使用脊线检测算法以获取某个待分解分量的 IF。

1.2 脊检测

不同于原始 ACMD 使用希尔伯特变换对信号分量进行 IF 初始化, 本文将使用基于时频分布的脊线检测算法实现信号分量的 IF 估计。脊线检测算法可以更为准确地估计信号的 IF, 这有利于 ACMD 对信号分量进行分解。学者们对基于时频分布的脊线检测方法进行了大量研究, 文献[17]通过寻找时频表示中的最大值来检测信号的 IF, 该方法实施简单但极易受到噪声或其他分量的干扰。文献[12]则通过计算特定函数的局部最大值来同时提取信号所有分量, 但是分量个数需提前确定。在实际振动信号中, 由于不同分量和噪声的干扰, 确定分量个数极为困难。且该方法同时估计所有分量, 容易造成

算法不稳定, 所提取的 IF 也很容易出错, 因此难以在实际中进行应用。另外, ACMD 并不需要在最开始就提供所有分量的 IF, 只需提供待分解的某个分量的 IF 信息即可。因此, 本文将使用文献[18]的脊线检测方法。该方法可以估计出多分量信号中具有最高能量的分量的 IF 信息, 这与 ACMD 的递归分解思想相符合。算法具体步骤如下:

1) 确定时频分布的最大能量位置 (t_0, f_0) 。

2) 令 $t_r = t_0 + 1/fs$, $t_l = t_0 - 1/fs$, $f_l = f_0$, $f_r = f_0$, 其中 fs 为采样频率。

3) 计算 t_l 和 t_r 处的 IF, 即 $IF(t_l) = \tilde{f}_l$, $IF(t_r) = \tilde{f}_r$, 其中 $\tilde{f}_l$ 和 $\tilde{f}_r$ 分别为在 $(t_l, f_l - \Delta f) \sim (t_l, f_l + \Delta f)$ 和 $(t_r, f_r - \Delta f) \sim (t_r, f_r + \Delta f)$ 的最大能量位置的频率, Δf 为最大容许频率变化。

4) 将 $(t_r, f_r - \Delta f) \sim (t_r, f_r + \Delta f)$ 和 $(t_l, f_l - \Delta f) \sim (t_l, f_l + \Delta f)$ 值设置为 0。

5) 令 $t_r = t_r + 1/fs$, $t_l = t_l - 1/fs$ 。

6) 重复步骤 3)~5) 直至找到该分量的所有边界。

由以上分析可知, 该方法只需输入信号的时频表示和最大容许频率变化, 因此实施起来非常简单。为了证明该脊线检测方法和本文所提方法的有效性, 将使用时频能量聚集性较差的 STFT 生成信号的时频表示。信号 $y \in L^2(R)$ 关于窗函数 g 的 STFT 被定义为:

$$V_y^g(\omega, t) = \langle y, g_{\omega, t} \rangle = \int_R y(\tau) g(-t) e^{-2i\pi\omega(\tau-t)} d\tau \quad (10)$$

1.3 理想时频分布

由于 ACMD 可以估计分解出的各分量信号的 IF 和 IA, 因此可构建一个高分辨率的理想时频表示, 能极大提升故障诊断的精准度。包含 K 个分量信号的理想时频表示被定义为^[19]:

$$ITFR(t, \omega) = \sum_{i=1}^K A_i(t) \cdot \delta(\omega - \varphi_i'(t)) \quad (11)$$

式中: $A_i(t)$ 和 $\varphi_i'(t)$ 分别为某个分量信号的 IA 和 IF; δ 为狄利克雷函数。

2 本文方法

基于 ACMD 和脊检测算法, 本文提出一种新的时变工况滚动轴承故障诊断方法, 该方法的流程图如图 1 所示。其中, $IFCF_o$ 和 $IFCF_i$ 分别为瞬时外圈故障特征频率和瞬时内圈故障特征频率, IF_i 为经脊检测算法得到的第 i 个分量的 IF。所提方法具体步骤如下:

1) 使用包络解调技术将掩埋在高频噪声中的低频故障信号提取出来, 得到包络信号。

2) 使用 STFT 对包络信号进行分析, 得到包络信号

的时频表示。基于包络信号的 STFT 分布,可以判断该轴承是否存在故障。若不存在故障,则该轴承为健康轴承,流程结束;若存在故障,则进入下一流程。

3) 使用 1.2 节给出的脊检测方法提取第 i 个分量的 IF,以满足 ACMD 分离分量的需要。

4) 使用 ACMD 对包络信号进行分解,得到第 i 个分量信号及其 IF、IA 等信息。

5) 使用包络信号减去提取的第 i 个分量得到剩余信号,并将剩余信号作为原始包络信号。

6) 确定是否停止分解。若不停止,则重复执行步骤 2)~5),最终提取出信号的 K 个分量。对于分解的停止条件,本文使用剩余信号和原始信号的能量比作为判断依据。当能量比小于一个较小的阈值(一般选取为 $0.05 \sim 0.15^{[15]}$)时,则停止分解。另外,还可以根据肉眼查看 STFT 结果来确定分量个数,但是这种方法受人的主观意识的影响。

7) 构建分解出的所有分量的理想时频表示并叠加。基于得到的理想时频表示和滚动轴承参数,定位滚动轴承故障部位。若存在与 $IFCF_o$ 相关的时频脊线,则该轴承外圈存在故障;若存在与 $IFCF_i$ 相关的时频脊线,则该轴承内圈存在故障。




图 1 变工况滚动轴承故障诊断流程

Fig. 1 The flow chart of fault diagnosis of rolling bearing under non-stationary conditions

3 实验验证

为了验证本文所提方法的有效性,考虑对不同健康状况的变速轴承振动信号进行分析,并与最新发展的时频分析方法进行对比。试验台^[20]布局如图 2 所示。AC 电机用于控制轴承转速,加速度计用于收集振动数据,ER16 K 球轴承用于支撑轴。实验过程中使用两个轴承,一个健康轴承和一个实验轴承。轴承参数如表 1 所示。

由表 1 可知,该轴承的外圈和内圈故障特征系数 (FCC_o 和 FCC_i) 分别为 3.57 和 5.43,这两个参数可以用于确定轴承的故障特征频率。设置采样频率为 200 kHz,采样时间为 10 s。




图 2 MFS-PK5M 试验台

Fig. 2 The test rig of MFS-PK5M

表 1 ER16 K 轴承参数

Table 1 The parameters of ER16 K bearing

节圆直径	滚动体直径	滚动体数量	FCC_o	FCC_i
38.52 mm	7.94 mm	9	3.57	5.43

3.1 正常信号

使用健康轴承作为实验轴承,控制轴承转速从 28.6 Hz 逐渐减小至 13.9 Hz。由加速度计收集到的振动信号波形如图 3(a) 所示。由图 3(a) 可知,随着转速降低,振动信号的幅值也逐渐减小,说明脉冲幅值会跟随转速的变化而变化。然而,仅从时域波形无法判断轴承是否存在故障。使用本文所提方法对该信号进行进一步处理,原始信号经包络解调后得到的包络信号如图 3(b) 所示,图 3(c) 为包络信号的 STFT 分布。由图 3(c) 可知,信号能量在时频面中分布散乱,无法确定一些主导的时频脊线。若轴承存在故障,则时频面中应该存在与 $IFCF_o$ 或 $IFCF_i$ 相关的时频脊线。根据图中结果,可以确定该轴承为健康轴承。

3.2 轴承外圈故障信号

使用外圈存在故障的轴承作为实验轴承,控制轴承转速从 25.5 Hz 缓慢减小至 15.0 Hz 后再增加至 19.6 Hz。图 4(a) 为测得振动信号的波形,由图 4(a) 可知,可以进一步验证前面的结论,即信号脉冲幅值随着转速变化而变化,转速升高,幅值增大;反之亦然。图 4(b) 和 (c) 分别为包络信号和包络信号的 STFT 分布。图 4(c) 出现了一些能量集中的时频脊线,且发现这些脊线与转频存在一定关系。然而,由于该分布的时频分辨率极差,直接使用该分布确定轴承故障特征频率很容易






图 3 正常信号
Fig. 3 The normal signal

出现错判或误判的现象。使用本文所提方法进行进一步处理,首先脊线检测算法从 STFT 分布中提取信号第 i 个分量的 IF,然后 ACMD 分解出该信号分量。使用包络信号减去该分量得到剩余信号,将剩余信号作为原始包络信号继续提取下个分量,直至剩余信号与原始信号的能量比小于设定阈值(0.15)时停止。经检查,算法共循环了 6 次,分解出了 6 个分量,这些分量信号的时域波形如图 4(d)所示。最后基于 ACMD 分解得到的各分量信号的 IF 和 IA,构建了叠加的理想时频表示,结果如图 4(e)

所示。由图 4(e) 可知,该分布具有极高的时频分辨率,





(e) 构建的理想时频表示

(e) The constructed ideal time-frequency representation

图 4 外圈故障信号


Fig. 4 The outer ring fault signal

并且很容易确定这 6 个分量分别为 $1.5F_r$ 、 $2F_r$ 、 $IFCF_0$ 、 $2IFCF_0$ 、 $IFCF_0 + 1.5F_r$ 、 $IFCF_0 + 2F_r$ ，且 $IFCF_0$ 和 $2F_r$ 有最高的时频能量。根据以上分析，可以确定该轴承外圈存在故障。

为了体现本文所提方法的优势，分别使用最新发展的 SST 和 SET 对包络信号进行处理，结果如图 5(a) 和 (b) 所示。经时频分布的后处理技术，时频表示的能量聚集性有了较大提升。SST 将信号能量沿着时间方向进行重分以提高能量聚集性，从图 5 也可以找到一些与 $IFCF_0$ 相关的时频分量，然而其他无关分量和噪声的干扰严重影响诊断的准确性。SET 则通过保留时频脊线上最中间的信息来提高时频聚集性。与 SST 结果相同，SET 结果也遭受噪声和其他分量的严重干扰。必须指出，这些方法单纯地考虑提高时频分布的能量聚集性来提升诊断的效果，但却对实际状况下的机械故障诊断帮助不大。想要提高诊断的准确度，时频分辨率显然更为重要。


3.3 轴承内圈故障信号

对内圈故障振动信号进行分析，轴承转速从 25.8 Hz 缓缓下降至 12.0 Hz。所得振动信号和包络信号分别如图 6(a) 和 (b) 所示。由图 6(a) 可知，转速减小，振动信号幅值也随着减小。使用 STFT 处理包络信号后结果如图 6(c) 所示，从图 6 可以观察到一些规律变化的时频脊线，其变换规律与转频相似。使用本文所提方法进行进一步处理，ACMD 递归分解出了 5 个分量，其对应的时域波形如图 6(d) 所示。最终，利用得到的各分量信号的 IF 和 IA 等信息，构建出了高分辨的理想时频表示，结果如图 6(e) 所示。结合轴承参数，发现这 5 个分量分别为 F_r 、 $1.5F_r$ 、 $2.5F_r$ 、 $IFCF_i$ 和 $IFCF_i + F_r$ ，其中 $IFCF_i$ 和 F_r 的时频能量最大。基于以上分析，确定用于实验的轴承内圈存在故障，这与实际情况相符合。



(a) 包络信号的 SST 结果

(a) SST result of envelope signal




(b) 包络信号的 SET 结果

(b) SET result of envelope signal


图 5 时频分析方法结果

Fig. 5 The results of time-frequency analysis methods



(a) 时域波形

(a) Time waveform



(b) 包络信号

(b) Envelope signal




图 6 内圈故障信号

Fig. 6 The inner ring fault signal

与外圈故障案例相同, SST 和 SET 被用于比较, 所得结果如图 7(a) 和 (b) 所示。从图 7 可知, 虽然这两个方法的时频能量聚集性有了提升, 但他们仍然存在噪声和其他无关分量的巨大干扰。另外, 时频分辨率这个问题仍旧未被解决, 这与本文所提方法形成了鲜明对比。综合以上 3 个案例的结果发现, 本文所提方法更加适合于变工况下的滚动轴承故障诊断。




图 7 时频分析方法结果

Fig. 7 The results of time-frequency analysis methods

4 结 论

为了实现变工况下的滚动轴承故障诊断, 本文提出了一种全新的基于 ACMD 和脊检测相结合的方法。通过实验发现, 本文所提出的方法可以解决传统方法无法避免的受速度波动、噪声、幅值和频率调制、其他无关分量等干扰的问题; 可以构建高分辨的理想时频表示, 并且该表示中只包含与轴承故障相关的信息, 极大提升了诊断的准确度; 通过与其他的时间频分析方法 (SST 和 SET) 结果比较发现, 本文所提方法诊断效果更优。

参考文献

- [1] 尹鹏. 改进的 FEWT 及其在滚动轴承故障诊断中的应用[J]. 电子测量与仪器学报, 2020, 34(5): 181-189.
YIN P. Modified fast empirical wavelet transform and its application in fault diagnosis of rolling bearings [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(5): 181-189.
- [2] LIU Q, WANG Y X, XU Y G. Synchrosqueezing

- extracting transform and its application in bearing fault diagnosis under non-stationary conditions [J]. Measurement, 2021, 173: 108569.
- [3] 尚雪梅, 徐远纲. PSO 优化的最大峭度熵反褶积齿轮箱故障诊断[J]. 电子测量与仪器学报, 2020, 34(7): 64-72.
- SHANG X M, XU Y G. Maximum kurtosis entropy deconvolution gearbox fault diagnosis based on PSO [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(7): 64-72.
- [4] 刘奇, 王衍学. 基于同步挤压提取变换的滚动轴承故障诊断研究[J]. 机械传动, 2021, 45(1): 123-128.
- LIU Q, WANG Y X. Research on Fault Diagnosis of Rolling Bearing based on Synchrosqueezing Extracting Transform [J]. Journal of Mechanical Transmission, 2021, 45(1): 123-128.
- [5] 施杰, 伍星, 刘韬. 基于 MPDE-EEMD 及自适应共振解调的轴承故障特征提取方法[J]. 电子测量与仪器学报, 2020, 34(9): 47-54.
- SHI J, WU X, LIU T. Method of bearing fault feature extraction based on MPDE-EEMD and adaptive resonance demodulation technique [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(9): 47-54.
- [6] 钟先友, 田红亮, 赵春华, 等. 基于迭代滤波和快速峭度图的滚动轴承微弱故障特征提取[J]. 振动与冲击, 2018, 37(9): 190-195.
- ZHONG X Y, TIAN H L, ZHAO CH H, et al. Fault feature extraction for rolling bearings' weak faults based on iterative filtering and fast kurtogram [J]. Journal of vibration and shock, 2018, 37(9): 190-195.
- [7] 徐可, 陈宗海, 张陈斌, 等. 基于经验模态分解和支持向量机的滚动轴承故障诊断[J]. 控制理论与应用, 2019, 36(6): 915-922.
- XU K, CHEN Z H, ZHANG CH B, et al. Rolling bearing fault diagnosis based on empirical mode decomposition and support vector machine [J]. Control Theory & Applications, 2019, 36(6): 915-922.
- [8] 杜冬梅, 张昭, 李红, 等. 基于 LMD 和增强包络谱的滚动轴承故障分析[J]. 振动. 测试与诊断, 2017, 37(1): 92-96, 201.
- DU D M, ZHANG ZH, LI H, et al. Fault diagnosis for roller bearing based on local mean decomposition and enhanced envelope spectrum [J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(01): 92-96, 201.
- [9] ZHANG S F, WANG Y X, HE S L, et al. Bearing fault diagnosis based on variational mode decomposition and total variation denoising [J]. Measurement Science and Technology, 2016, 27(7): 075101.
- [10] WANG Y X, YANG L, XIANG J W, et al. A hybrid approach to fault diagnosis of roller bearings under variable speed conditions [J]. Measurement Science and Technology, 2017, 28(12): 125104.
- [11] DAUBECHIES I, LU J, WU H T. Synchrosqueezed wavelet transforms: An empirical mode decomposition-like tool [J]. Applied and computational harmonic analysis, 2011, 30(2): 243-261.
- [12] YU G, YU M J, XU C Y. Synchroextracting Transform [J]. IEEE Transactions on Industrial Electronics, 2017, 64(10): 8042-8054.
- [13] TU X T, HE Z J, HU Y, et al. The Second order synchroextracting transform with application to bearing fault diagnosis under variable speed condition [C]. Asia Pacific Conference of the Prognostics and Health Management, 2019.
- [14] CHEN S Q, DONG X J, PENG Z K, et al. Nonlinear Chirp Mode Decomposition: A Variational Method [J]. IEEE Transactions on Signal Processing, 2017, 65(22): 6024-6037.
- [15] CHEN S Q, YANG Y, PENG Z K, et al. Adaptive chirp mode pursuit: Algorithm and applications [J]. Mechanical Systems & Signal Processing, 2019, 116: 566-584.
- [16] CHEN S Q, YANG Y, PENG Z K, et al. Detection of rub-impact fault for rotor-stator systems: A novel method based on adaptive chirp mode decomposition [J]. Journal of Sound and Vibration, 2019, 440: 83-99.
- [17] STANKOVIC L, DJUROVIC I, STANKOVIC S, et al. Instantaneous frequency in time-frequency analysis: Enhanced concepts and performance of estimation algorithms [J]. Digital Signal Processing, 2014, 35: 1-13.
- [18] KHAN N A, BOASHASH B. Instantaneous frequency estimation of multicomponent nonstationary signals using multiview time-frequency distributions based on the adaptive fractional spectrogram [J]. IEEE Signal Process. Lett, 2013, 20(2): 157-160.
- [19] LIU Q, WANG Y, WANG X. Two-step adaptive chirp mode decomposition for time-varying bearing fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-10.
- [20] HUANG H, BADDOUR N. Bearing vibration data collected

under time-varying rotational speed conditions [J]. Data in Brief, 2018, 21: 1745-1749.

作者简介



刘奇, 2019 年于广东技术师范大学获得学士学位, 现为北京建筑大学硕士研究生, 主要研究方向为故障诊断、信号处理与特征提取。

E-mail: lewis9710@ 163. com

Liu Qi received his B. Sc. degree from Guangdong Polytechnic Normal University in 2019. Now he is a M. Sc. candidate in Beijing University of Civil Engineering and Architecture. His main research interests include fault diagnosis, signal processing and feature extracting.



王衍学, 2009 年于西安交通大学获得博士学位, 2010–2011 年加拿大渥太华大学博士后, 现为北京建筑大学教授、博导, 主要研究方向为装备故障诊断与智能维护、剩余寿命与健康管理及信号处理与特征提取等。

E-mail: wyx1999140@ 126. com

Wang Yanxue received his Ph. D. from Xi'an Jiaotong University in 2009 and postdoctoral fellow at the University of Ottawa in Canada from 2010 to 2011. Now he is a professor and doctoral director of Beijing University of Architecture. His main research interests include equipment fault diagnosis and intelligent maintenance, RUL prognosis and health management, signal processing and feature extraction etc.