

DOI: 10.13382/j.jemi.2017.09.004

基于 VMD 与自相关分析的滚动轴承故障特征提取^{*}

张俊甲 马增强 王梦奇 阮婉莹

(石家庄铁道大学电气与工程学院 石家庄 050043)

摘要:滚动轴承故障信号多呈现非平稳、多分量调制特性,早期故障信号调制特性微弱、易受周围设备噪声干扰,导致轴承早期故障特征淹没在噪声信号中,故障特征难以提取。为此,提出一种变分模态分解(variational mode decomposition, VMD)与自相关分析相结合的轴承故障特征提取方法。首先利用自相关分析消除故障信号中噪声干扰,提取周期成分;然后再用VMD算法将消噪信号分解成若干本征模态分量(intrinsic mode function, IMF),运用能量算子对相关系数及峭度值较大分量进行解调分析;最后通过能量解调谱来判别滚动轴承故障类型。将该方法应用到滚动轴承仿真故障数据和实测数据中,结果表明,该方法可降低了噪声的干扰,有效提取故障特征频率,能够实现滚动轴承故障的精确诊断。

关键词:自相关分析;变分模态分解;降噪;滚动轴承;故障诊断

中图分类号: TN710.1; TH213.3 文献标识码: A 国家标准学科分类代码: 470.40

Rolling bearing fault feature extraction based on VMD and autocorrelation analysis

Zhang Junjia Ma Zengqiang Wang Mengqi Ruan Wanying

(School of Electronical and Electronics Engineering, Shijiazhuang Tiedao University, Shijiazhuang 050043, China)

Abstract: Early fault signal of rolling bearing usually presents non-stationary multi-component characteristics, early fault features of bearing submerged in the back-ground noise are difficult to identify because of the weak modulated characteristics and strong noise. Therefore, the fault diagnosis method based on variational mode decomposition (VMD) and autocorrelation analysis was proposed. At first, the noise was eliminated and the periodic components in signals were extracted by using autocorrelation analysis. Then VMD was used to decompose the denoised signal into many intrinsic mode functions and the IMFs of the biggest coefficient and kurtosis was selected and demodulated with Teager energy operator. At last, the bearing fault type was distinguished through the energy spectrum. The simulation experiments and practical engineering experiments have been carried out and the results show that this method is able to reduce the interference of noise and extract effectively the fault feature frequency, and realize accurate diagnosis for rolling bearing fault.

Keywords: autocorrelation analysis; variational mode decomposition (VMD); noise reduction; rolling bearing; fault diagnosis

0 引言

滚动轴承在旋转机械中有着广泛的应用,滚动轴承运行状态正常与否直接影响到旋转机械设备的安全性与使用寿命。因此对滚动轴承早期故障的分析与诊断具有重要的实际意义和应用价值^[1-2]。

轴承故障诊断的关键是能够有效提取故障特征信息^[3],经验模态分解(EMD)将信号分解成若干从高到低不同频率的模态分量进而转化成平稳信号。该方法广泛应用于滚动轴承故障特征的提取^[4-6]。局部均值分解(LMD)算法能将复杂信号自适应分解为若干乘积函数分量(PF),每个PF分量都是包络信号与纯调频信号的乘积。孙伟等人^[7]利用小波包变换消除了信号中噪声干

扰,并对 LMD 分解后的 PF 分量进行功率谱分析实现了滚动轴承的故障特征提取。程军圣等人^[8]将 LMD 与能量算子解调相结合,实现了旋转机械的故障诊断,王建国等人^[9]利用自相关分析提取了信号周期成分,结合共振解调技术对 LMD 分解后 PF 分量进行包络分析,通过实验分析证明了在轴承故障诊断上的有效性。

EMD 或者 LMD 被广泛地应用在故障特征提取方面,然而两者都属于递归“筛选”模态,存在端点效应和模态混叠等问题,导致 IMFs 频率不能完全分离,且受采样频率影响,分解误差较大。变分模态分解 (variational mode decomposition, VMD) 是 Dragomiretskiy 等人^[10]在 2014 年提出一种非递归、变分的自适应模态分解方法,摈弃了 EMD 和 LMD 递归模态分解模式,有效避免了信号分解时的模态混叠及端点效应,通过合理控制收敛条件,其采样效应也远小于 EMD 和 LMD^[11]。

滚动轴承是一个周期性旋转部件,由于受到设备本身及载荷影响其振动信号表现为非平稳多分量调制信号,在轴承早期故障阶段受复杂背景噪声以及其他干扰源影响,导致故障信号非常微弱,然而在强烈背景噪声影响下 VMD 往往不能很好的实现信号各个模态分量的有效分离,因而故障特征难以精确地提取出来^[12-14]。

自相关分析能有效消除信号中的随机噪声及非周期成分,且在消噪过程中不丢失信号中有用成分。在滚动轴承早期故障中,振动信号中的周期脉冲被淹没在背景噪声中,对早期故障信号进行自相关分析能有效消除噪声干扰,保留周期成分,有效提高了信噪比^[9,15]。基于以上分析本文提出了一种基于 VMD 与自相关分析相结合的滚动轴承早期故障诊断方法,并该方法应用于仿真信号及实测数据中,实现了滚动轴承早期故障状态下故障特征频率的提取,证明了该方法在轴承早期故障诊断上的有效性及准确性。

1 VMD 算法原理

VMD 是基于经典 Wiener 滤波、Hilbert 变换和频率混频的变分问题求解过程,该方法通过迭代搜寻变分模型最优解从而确定每个 (intrinsic mode function, IMF) 的中心频率和带宽,实现信号频域及各个 IMFs 的自适应剖分,同时还有具体的稀疏特性^[9]。

经 VMD 处理后的信号被分解为若干 IMF,每个 IMF 都是一个单分量的调幅-调频 $u_k(t)$ 信号,其表达式为:

$$u_k(t) = A_k(t) \cos(\phi_k(t)) \quad (1)$$

式中: $A_k(t)$ 为 $u_k(t)$ 的瞬时幅值, $A_k(t) \geq 0$; $\omega_k(t)$ 为 $u_k(t)$ 的瞬时频率, $\omega_k(t) = \dot{\phi}_k(t)$ 且 $\omega_k(t) \ll A_k(t)$ 及 $\omega_k(t)$ 的变化速度较为缓慢,远不及 $\phi_k(t)$ 的变化速度。在 $[t - \delta, t + \delta]$ 的时间内 $u_k(t)$ 可以看做 $A_k(t)$ 、

$u_k(t)$ 的谐波信号,其中 $\delta = 2\pi/\phi'_k(t)$ 。

VMD 分解是寻求 K 个估计带宽之和最小的模态函数 $u_k(t)$, $k \in \{1, 2, \dots, K\}$, 约束条件为各模态之和等于输入信号,为估计每个 IMF 带宽。可通过以下步骤确定每个模态函数的带宽。

约束变分模型表达式为:

$$\begin{cases} \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} \quad \sum_k u_k = f \end{cases} \quad (2)$$

式中: $\{u_k\} = \{u_1, \dots, u_k\}$ 代表分解得到的 K 个 IMF 分量; $\{\omega_k\} = \{\omega_1, \dots, \omega_k\}$ 表示各分量的中心频率; $\sum_k := \sum_{k=1}^K$ 表示所有模态分量的求和。

为了求取上述变分约束模型最优解,引入二次惩罚因子 α 与 Lagrange 乘法算子 $\lambda(t)$,其中 α 为足够大的正数,可在高斯噪声存在的情况下保证信号的重构精度,Lagrange 算子使得约束条件保持严格性,扩展的 Lagrange 表达式如下:

$$\begin{aligned} & L(\{u_k(t)\}, \{\omega_k(t)\}, \lambda(t)) = \\ & \alpha \sum_{k=1}^K \left\| \frac{\partial [(\delta(t) + \frac{j}{\pi t}) \cdot u_k(t)]}{\partial t} e^{-j\omega_k t} \right\|_2^2 + \\ & \|f(t) - \sum_{k=1}^K u_k(t)\|_2^2 + \langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \rangle \end{aligned} \quad (3)$$

利用交替方向乘子算法 (alternate direction method of multipliers, ADMM) 求取以上变分问题,并通过交替更新 $u_k^{n+1}(t)$ 、 $\omega_k^{n+1}(t)$ 和 $\lambda^{n+1}(t)$ 求取扩展的 Lagrange 表达式的‘鞍点’具体实现步骤如下:

1) 初始化 $\{\hat{u}_k^1\}$, $\{\omega_k^1\}$, $\hat{\lambda}^1$ 和 $n=0$ 。

2) 设定 $n=n+1$, $k=k+1$ 执行循环过程。对所有 $\omega \geq 0$ 更新 $u_k(t)$ 和 $\omega_k(t)$, 达到预设分解数 K 时,结束循环。

模态分量及中心频率更新公式如下:

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i < k} \hat{u}_i^{n+1}(\omega) - \sum_{i > k} \hat{u}_i^n(\omega) + \frac{\hat{\lambda}^n(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k^n)^2} \quad (4)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (5)$$

3) 按以下公式更新 λ :

$$\hat{\lambda}^{n+1}(\omega) \leftarrow \hat{\lambda}^n(\omega) + \tau (\hat{f}(\omega) - \sum_k \hat{u}_k^{n+1}(\omega)) \quad (6)$$

4) 返回步骤 2), 重复上述过程, 直至满足设定 ε 为 10^{-6} 的迭代停止条件:

$$\sum_k \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2 / \|\hat{u}_k^n\|_2^2 < \varepsilon \quad (7)$$

结束迭代,得到 K 个 IMF 分量。

2 基于自相关分析与 VMD 的滚动轴承故障特征提取

由于滚动轴承早期故障诊断中故障冲击特征微弱且故障振动信号受噪声影响较大^[16],单独使用 VMD 算法对信号进行处理可能导致故障特征信息不能被完全提取出来。首先对滚动轴承早期故障振动信号进行自相关分析,用以消除随机噪声干扰,然后利用 VMD 算法将消噪信号分解为若干个本征模态分量,对相关系数及峭度值最大的分量进行能量算子解调分析,最后通过包络谱判别滚动轴承工作状态及故障类型。

2.1 自相关分析

自相关函数描述的是同一信号在不同时刻的相互关系^[16],定义为:

$$R_x(\tau) = \frac{1}{T} \lim_{T \rightarrow \infty} \int_0^T x(t)x(t + \tau) dt \quad (8)$$

式中: τ 为自相关函数时延, T 为信号周期。

设调制信号为:

$$S(t) = s(t) + n(t) = Ae^{j2\pi f_1 t} e^{j2\pi f_2 t} + n(t) \quad (9)$$

式中: A 为振幅, f_1, f_2 分别为调制和载波频率, $n(t)$ 为噪声信号。

$$R_s(\tau) = \frac{1}{T} \lim_{T \rightarrow \infty} \int_0^T s(t)s(t + \tau) dt + R_n(\tau) = A^2 e^{j2\pi f_1 t} e^{j2\pi f_2 t} \quad (10)$$

由此可以看出,随着时间的延长噪声信号自相关函数值将很快衰减至 0,调制信号的自相关函数仍为调制和载波频率不变的调制信号。因此将其用于滚动轴承早期故障诊断中,可有效消除噪声干扰,提高信噪比。

2.2 基于 VMD 和自相关分析的滚动轴承故障特征提取

针对滚动轴承早期故障难以有效提取故障特征信息的问题,本文提出了一种基于 VMD 与自相关分析的滚动轴承故障特征提取方法,具体流程如图 1 所示。

1) 采集原始数据,经自相关分析消除噪声干扰,增强信号周期性。

2) 初始化模态数 $K=2$,惩罚因子 α 和带宽 τ 使用默认值: $\alpha=2000, \tau=0$ 。

3) 以步骤 2) 的参数对信号进行 VMD 分解,得到若干本征模态分量。

4) 分别计算每个 IMF 分量的相关系数与峭度值,选择两者都较大的分量进行重构。

5) 对步骤 4) 中得到的信号进行能量算子解调分析,得到信号的能量谱。

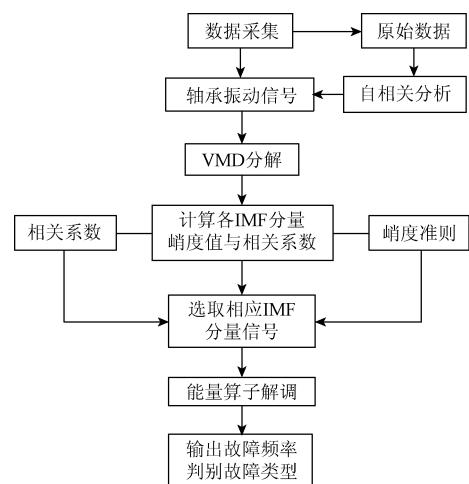


图 1 滚动轴承故障诊断流程

Fig. 1 Flow chart of rolling bearing fault diagnosis

6) 与故障特征频率进行匹配,判别故障类型。

3 仿真信号分析

为验证本文算法的有效性和准确性,使用单位周期脉冲序列,并向其添加强烈白噪声来模拟滚动轴承的单点故障,仿真信号如下:

$$\begin{cases} x(t) = \sum_i s(t - i/f_r - \sum_{i=-M}^M \tau_i) + n(t) \\ s(t) = Ae^{-Kt} \sin(\omega_r t) u(t) \end{cases} \quad (11)$$

式中: $A=1$,衰减系数 K 为 800,系统共振频率 $\omega_r=2\times\pi\times1000$, $u(t)$ 为单位阶跃函数,设定信号的故障特征频率 $f_r=128$, τ_i 为 $0.01/f_r \sim 0.02/f_r$ 的随机数。采样频率为 25 600 Hz, $n(t)$ 为白噪声,加入信噪比为 -20 dB 的白噪声。

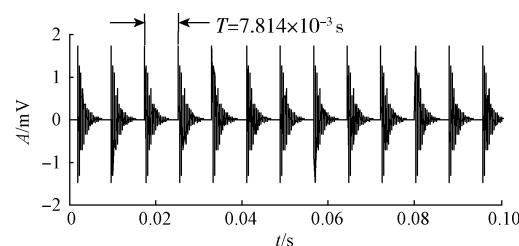


图 2 未加噪声信号时域

Fig. 2 The simulated signal without noise

从图 2 可以看出未加噪声信号是一个周期 $T=7.814 \times 10^{-3}$ 脉冲序列,图 3(a)加入噪声后脉冲信息完全淹没于噪声中。现采用自相关分析对仿真信号进行消噪,得到的时域波形及频域波形如图 3(b)所示。可以看出强烈白噪声得到有效抑制,时域信号中调制、周期特性

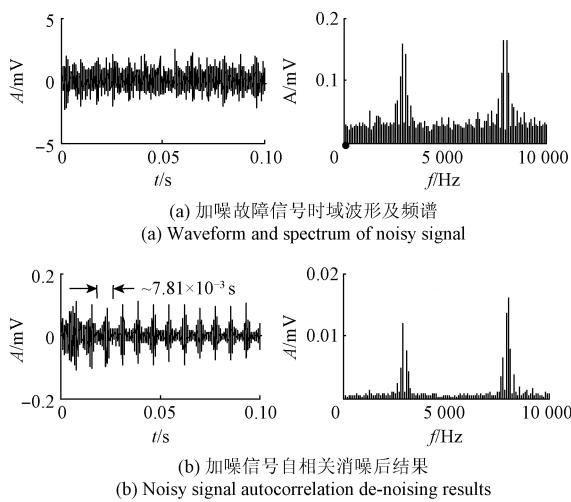
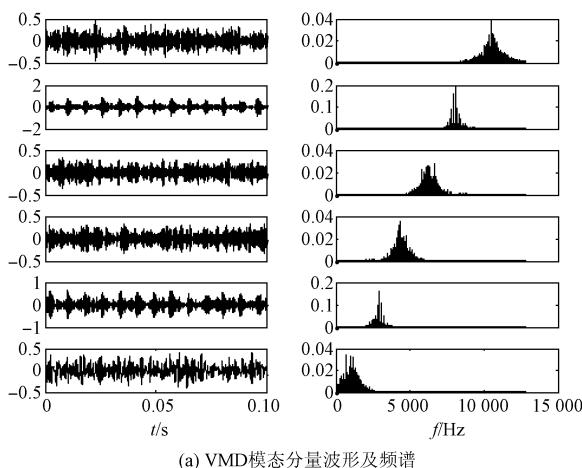


图 3 仿真信号时域及频域

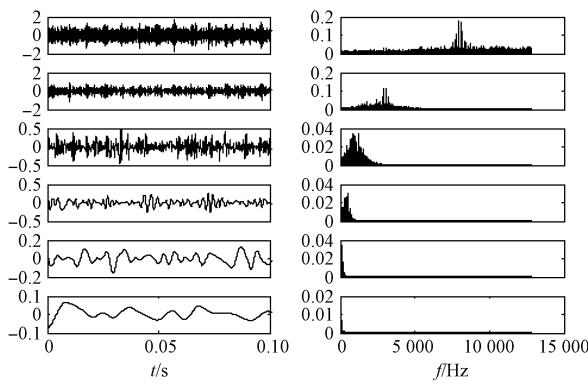
Fig. 3 Waveform and spectrum of simulated signals

被清楚显示出来,脉冲周期约为 7.81×10^{-3} s,频域信号杂频分量明显减小,故障谱线比较清晰。

为了对比分析,验证本文方法的优势,对经自相关消噪后的仿真信号进行 VMD 和 LMD 分解,如图 4 所示。通过比较图 4(a)、(b)可以看出,VMD 分解后各 IMF 呈现比较规范的模态,彼此间没有模态混叠现象,各个频段



(a) Waveform and spectrum of VMD IMFs EMD K= 7



(b) Waveform and spectrum of LMD IMFs

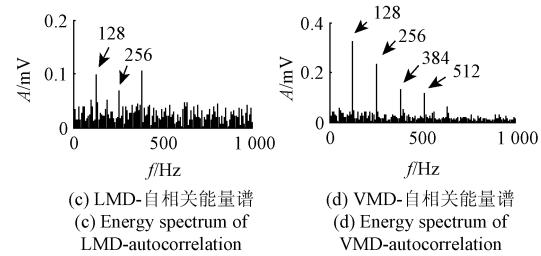


图 4 仿真信号分解及解调结果
Fig. 4 Decomposition and demodulation results of simulation signals

分离效果较好。LMD 分解效果并不理想,IMF1 几乎出现在整个频率范围内,产生了严重模态混叠。由表 1 可知 VMD 分解的 IMF1 和 IMF2 相关系数及峭度值最大,说明其包含原始信号最多的冲击成分,因此选择 IMF1 和 IMF2 进行信号重构。

表 1 仿真信号分解的相关系数、峭度值和峰值因子

Table 1 Correlation coefficient, kurtosis value and peak factor of simulation signal decomposition

IMF	相关系数	峭度值	峰值因子
1	0.66	10.32	7.59
2	0.72	8.58	4.83
3	0.43	2.91	5.74
4	0.28	4.35	4.16
5	0.23	4.49	3.71
6	0.34	3.55	3.87

通过对重构信号进行能量算子解调分析,得到重构信号能量谱如图 4(c)、(d)所示。可以看出经 LMD 分解重构信号的解调效果欠佳,虽能观察到 1 倍频(128 Hz)及部分倍频,但干扰谱线过多。本文方法中 1 倍频(128 Hz)2 倍频(256 Hz)和倍频及幅值都非常明显,杂频分量明显减小,频谱图比较规则,证明了该方法的有效性及准确性。

4 实测信号分析

通过 QPZZ-II 旋转机械故障试验台采集滚动轴承早期故障信号,用实际轴承外圈故障信号对本文所提方法进行验证,以表明该方法在轴承故障特征提取上的有效性和精准性。实验测试参数及轴承技术参数如表 2 所示,根据轴承特征频率理论计算公式可得到外圈故障频率 $f = 36$ Hz。

滚动轴承早期故障信号采自 QPZZ-II 旋转机械故障试验台,传感器的安装位置如图 5 所示,由图 6 外圈故障信号时域波形及频谱可以看出,时域波形中有明显的冲

击成分、受噪声的干扰严重,频谱比较杂乱,频率并未集中在某区域,而是在一定频带范围普遍存在。对比图6和7可以看出,经自相关处理后原始信号的周期特性并未改变,调制特性较为明显。在频域图中保留了原信号主要成分,减少了随机噪声干扰,自相关后信的频域谱线更加清晰,具有明显的降噪效果。

表2 轴承测试参数与技术参数

Table 2 Bearing test parameters and technical parameters

中径	滚子直径	接触角	滚子个数z	转速/(r·min ⁻¹)	采样频率f _s /Hz
D/mm	d/mm	α/(°)	13	407	25 600



图5 QPZZ-II旋转机械故障试验平台及传感器安装图

Fig. 5 Fault simulation platform of QPZZ-II and Sensor's installation location

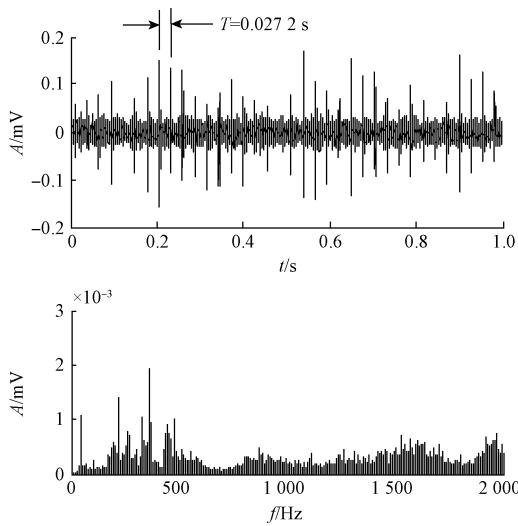


图6 外圈故障信号时域波形及频谱

Fig. 6 Waveform and spectrum of the bearing outer fault

作为对比,利用VMD对原始故障振动信号进行分解,并对自相关消噪信号进行VMD和LMD分解,根据相关系数-峭度最大原则对相应IMFs进行能量算子解调,分析结果如图8所示。可以看到直接对滚动轴承早期故障信号进行VMD分解、解调分析,图8(a) VMD模态分量能量谱受噪声干扰较大,故障特征基频及倍频并不明

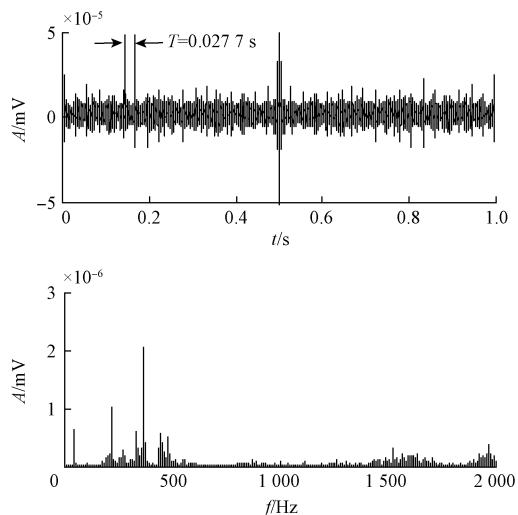


图7 自相关消噪后时域波形及频谱

Fig. 7 Waveform and spectrum after autocorrelation denoising

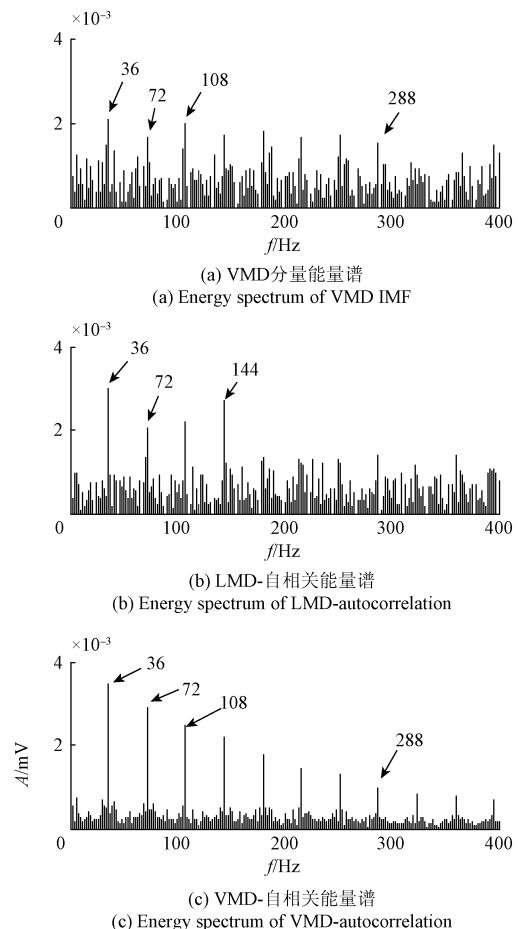


图8 外圈故障信号解调能量谱

Fig. 8 Energy spectrum of the outer fault signals demodulation

显;图8(b) LMD-自相关能量谱特征频率及倍频幅值较低,高次谐波频率并不明显;在图8(c)中可以看出本文

方法噪声干扰较少谱线故障特征十分明显,能够清晰看到故障特征频率 36 Hz 及其倍频 72、108 Hz,且幅值依次衰减。故障特征频率与实际计算值对比,能够有效判断故障类型。

5 结 论

通过对仿真信号及实际故障信号分析,证明了采用 VMD 和自相关分析对滚动轴承故障诊断的可行性。

1) 滚动轴承早期故障信号调制微弱,且存在较大噪声干扰,经自相关分析后能在保留故障信号周期、调制特性的基础上有效抑制噪声成分,降低了噪声对信号分解的干扰。

2) 在对信号分解上,相对于 LMD 方法,VMD 可有效克服由冲击信号造成的模态混叠,各模态分量能有效分离。

3) 仿真信号及实测故障信号分析结果表明,相比直接对信号进行 VMD 方法与 LMD-自相关方法,基于 VMD 与自相关分析相结合的方法在滚动轴承早期微弱故障特征提取上,效果更加有效、准确,具有明显优势。

参考文献

- [1] 李舜酩,郭海东,李殿荣.振动信号处理方法综述[J].
仪器仪表学报,2013,34(8):1907-1915.
- [2] LI SH M, GUO H D, LI D R. Review of vibration signal processing methods [J]. Chinese Journal of Scientific Instrument, 2013, 34(8): 1907-1915.
- [3] 马增强,谷朝健,李延忠,等.改进型共振解调器在轴承故障诊断中的应用[J].电子测量与仪器学报,2016,30(12):1925-1932.
MA Z Q, GU CH J, LI Y ZH, et al. Application of improved resonance demodulator in rolling bearing fault diagnosis [J]. Journal of Electronic Measurement and Instrumentation, 2016, 30(2): 1925-1932.
- [4] 陈勇旗,赵一鸣,陈杨.陈杨基于固有时间尺度分解的滚动轴承故障诊断[J].电子测量与仪器学报,2015,29(11):1677-1682.
CHEN Y Q, ZHAO Y M, CHEN Y. Fault diagnosis of roller bearing based on intrinsic time-scale decomposition [J]. Journal of Electronic Measurement and Instrumentation, 2015, 29(11): 1677-1682.
- [5] 杨望灿,张培林,吴定海,等.基于 EMD 和增强功率谱分析的滚动轴承故障诊断方法[J].现代制造工程,2013(12):116-120.
YANG W C, ZHANG P L, WU D H, et al. Fault diagnosis of roller bearings based on EMD and enhanced power spectrum analysis [J]. Modern Manufacturing Engineering, 2013(12):116-120.
- [6] 武哲,杨绍普,刘永强.基于多元经验模态分解的旋转机械早期故障诊断方法[J].仪器仪表学报,2016,37(2):241-248.
WU ZH, YANG SH P, LIU Y Q. Rotating machinery early fault diagnosis method based on multivariate empirical mode decomposition [J]. Chinese Journal of Scientific Instrument, 2016, 37(2): 241-248.
- [7] 孙伟,熊邦书,黄建萍,等.小波包降噪与 LMD 相结合的滚动轴承故障诊断方法[J].振动与冲击,2012,31(18):153-156.
SUN W, XIONG B SH, HUANG J P, et al. Fault diagnosis of a rolling bearing using Wavelet packet denoising and LMD [J]. Journal of Vibration and Shock, 2012, 31(18): 153-156.
- [8] 程军圣,杨怡,杨宇.基于 LMD 的谱峭度方法在齿轮故障诊断中的应用[J].振动与冲击,2012, 31(18): 20-23.
CHENG J SH, YANG Y, YANG Y. Application of spectral kurtosis approach based on local mean decomposition (LMD) in gear fault diagnosis [J]. Journal of Vibration and Shock, 2012, 31(18): 20-23.
- [9] 王建国,吴林峰,秦绪华.基于自相关分析和 LMD 的滚动轴承振动信号故障特征提取[J].中国机械工程,2014,25(2):186-190.
WANG J G, WU L F, QIN X H. Rolling bearing vibration signal fault feature extraction based on autocorrelation analysis and LMD [J]. China Mechanical Engineering, 2014, 25(2): 186-191.
- [10] DRAGOMIRETSKIY K, ZOSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62 (3): 531-544.
- [11] 刘长良,武英杰,甄成刚.基于变分模态分解和模糊 C 均值聚类的滚动轴承故障诊断[J].中国电机工程学报,2015,35(13):3358-3365.
LIU CH L, WU Y J, ZHEN CH G. Rolling bearing fault diagnosis based on variational mode decomposition and fuzzy C means clustering [J]. Proceedings of the Chinese Society of Electrical Engineering, 2015, 35 (13): 3358-3365.
- [12] 江星星,李舜酩.多共振频带自适应检测的轴承微弱故障诊断方法[J].电子测量与仪器学报,2016,

- 30(4):526-533.
- JIANG X X, LI SH M. Bearing weak fault diagnosis method based on adaptive detection of multi-resonance bands [J]. Journal of Electronic Measurement and Instrumentation, 2016, 30(4):526-533.
- [13] 高红玮, 张丽荣, 侯少杰. 基于变分模态分解改进方法的滚动轴承故障特征提取[J]. 图学学报, 2016, 37(6):862-867.
- GAO H W, ZHANG L R, HOU SH J. Rolling bearing fault feature extraction based on improved variational mode decomposition [J]. Journal of Graphics, 2016, 37(6):862-867.
- [14] 马增强, 李亚超, 刘政, 等. 基于变分模态分解和Teager能量算子的滚动轴承故障特征提取[J]. 振动与冲击, 2016, 35(13): 134-139.
- MA Z Q, LI Y CH, LIU ZH, et al. Rolling bearings' fault feature extraction based on variational mode decomposition and teager energy operator [J]. Journal of Vibration and Shock, 2016, 35(13): 134-139.
- [15] 郭玉杰, 杜新定, 石峰, 等. 滚动轴承故障的自相关函数包络分析[J]. 轴承, 2013(6):55-58.
- GUO Y J, DU X D, SHI F, et al. Envelope analysis on auto correlation function for rolling bearing fault [J]. Bearing, 2013(6):55-58.
- [16] LEI Y G, HE Z J, ZI Y Y. EEMD method and WNN for fault diagnosis of locomotive roller bearings [J]. Expert Systems with Applications, 2011, 38(6) : 7334-7341.

作者简介



张俊甲, 1990 年出生, 石家庄铁道大学在读研究生, 主要研究方向为信号处理与滚动轴承故障诊断。

Zhang Junjia was born in 1990, M. Sc. candidate in Shijiazhuang Railway University, His main research field is the signal processing and Rolling bearing fault diagnosis.



马增强(通讯作者), 分别在 1998 年、2001 年于河北工业大学获得学士学位和硕士学位, 2011 年于北京交通大学获得博士学位, 现为石家庄铁道大学教授, 主要研究方向为机车车辆状态监测与故障诊断。

E-mail: mzqlunwen@126. com

Ma Zengqiang (Corresponding author) received B. Sc. and M. Sc. both from Hebei University of Technology in 1998 and 2001, and Ph. D. from Beijing Jiaotong University in 2011, respectively. Now he is a professor in Shijiazhuang Tiedao University. His main research derivation is vehicle status monitor and fault diagnosis.