

改进 MOMEDA 方法及其在滚动轴承故障特征增强中的应用*

IMPROVED MOMEDA METHOD AND ITS APPLICATION TO FAULT FEATURE ENHANCEMENT OF ROLLING ELEMENT BEARINGS

陈丙炎** 宋冬利*** 张卫华 程尧

(西南交通大学 牵引动力国家重点实验室, 成都 610031)

CHEN BingYan SONG DongLi ZHANG WeiHua CHENG Yao

(State Key Laboratory of Traction Power, Southwest Jiaotong University, Chengdu 610031, China)

摘要 针对多点最优最小熵解卷积调整 (Multipoint Optimal Minimum Entropy Deconvolution Adjusted, MOMEDA) 方法在增强轴承故障特征时无法自动识别故障脉冲周期及解卷积信号长度减少的不足, 提出一种改进的 MOMEDA (Improved MOMEDA, IMOMEDA) 方法。采用振动信号的平方包络的自相关谱自适应地识别故障脉冲周期, 根据识别的脉冲周期对振动信号解卷积以增强周期性脉冲特征; 然后利用信号波形延拓方法对解卷积信号延拓使其长度与原始信号保持一致; 最后对已获得的解卷积信号再进行一定次数的解卷积以有效增强原始信号中的周期性特征。轴承故障仿真信号和铁路轴承实验信号的分析结果及与 Kurtogram 方法的对比结果表明: 改进的 MOMEDA 方法能够自动识别故障脉冲周期并有效增强滚动轴承的故障特征。

关键词 特征增强 故障诊断 铁路轴承 多点最优最小熵解卷积调整 自相关函数

中图分类号 TH17 TH133.3

Abstract Aiming at the shortcomings of multipoint optimal minimum entropy deconvolution adjusted (MOMEDA) method, which cannot automatically identify the fault impulse period and shorten the length of deconvolved signal when enhancing bearing fault features, an improved MOMEDA (IMOMEDA) method is proposed. The autocorrelation spectrum of square envelope of the vibration signal is used to adaptively identify the fault period, and the estimated impulse period is used to deconvolve the vibration signal to enhance the periodic impulse features. Then the signal waveform extension method is used to extend the deconvolved signal to make its length consistent with the original signal. Finally, the obtained filtered signal is deconvolved for a certain number of times to effectively enhance the periodic features of the original signal. The analysis results of simulated bearing fault signal and railway bearing experiment signals and the comparisons with Kurtogram method show that the improved MOMEDA method can automatically identify the fault impulse period and effectively enhance the fault characteristics of rolling bearing.

Key words Feature enhancement; Fault diagnosis; Railway bearings; Multipoint optimal minimum entropy deconvolution adjusted; Autocorrelation function

Corresponding author: SONG DongLi, E-mail: sdl.cds@163.com

The project supported by the Research and Development Project of China Railway Corporation (No.K2018J018).

Manuscript received 20190930, in revised form 20191110.

引言

滚动轴承广泛应用于铁路机车车辆的轮对、齿轮箱和牵引电机等关键部件, 其健康状态对于铁路列车的长期安全运行至关重要。随着高速铁路的跨越式发展, 轨道交通装备的故障诊断和健康管理日益受到高度重视^[1]。轴承早期故障特征提取与诊断一直是旋转机械故障诊断研究的重点和难点, 解卷积方法因其

优异的脉冲增强能力是目前滚动轴承故障诊断的常用方法之一。解卷积利用目标函数法构造逆滤波器对脉冲特征进行增强, 其典型代表是最小熵解卷积^[2] (Minimum Entropy Deconvolution, MED) 方法。采用峭度为目标函数, 通过反复迭代构造一个逆滤波器, 使解卷积信号的峭度最大, 从而增强原始信号中的脉冲特征。然而, 在强非高斯噪声存在的情况下, MED 的解卷积效果容易受到单个脉冲或与故障无关的强随机脉

* 20190930 收到初稿, 20191110 收到修改稿。中国铁路总公司科技研究开发计划项目 (K2018J018) 资助。

** 陈丙炎, 男, 1994 年 1 月生, 河南南阳人, 汉族, 西南交通大学博士研究生。主要研究方向为旋转机械状态监测和故障诊断。

*** 宋冬利, 女, 1971 年 11 月生, 贵州沿河人, 汉族, 西南交通大学高级实验师, 博士。主要研究方向为机车车辆故障诊断和健康预测。

冲的影响,不利于旋转机械的故障诊断。

为了提取旋转机械零部件故障激起的周期性脉冲特征,借助故障周期信息的解卷积方法相继被提出。其典型代表为最大相关峭度解卷积^[3](Maximum Correlated Kurtosis Deconvolution, MCKD)方法,采用相关峭度来度量由旋转机械局部损伤激起的周期性脉冲。MCKD 是一种有效的周期性脉冲增强方法,已在旋转机械的故障诊断中取得了显著的效果^[4-5]。但是, MCKD 需要准确的故障周期作为脉冲特征增强的前提条件,并且由反复迭代构造的逆滤波器只是局部最优解。为了克服 MCKD 存在的迭代过程而获得一个最优的解卷积滤波器, McDonald G L 等^[6]⁴⁶¹⁻⁴⁷⁷提出了多点最优最小熵解卷积调整 (Multipoint Optimal Minimum Entropy Deconvolution Adjusted, MOMEDA) 方法,基于矩阵运算直接获得最优解卷积滤波器。MOMEDA 已被成功应用于齿轮和滚动轴承的故障诊断^[7-8]。然而, MOMEDA 仍然需要借助先验的故障周期来增强周期性脉冲特征,极大限制了其应用范围。虽然通过观察解卷积信号的多点峭度 (Multipoint Kurtosis, MKurt) 谱能够识别故障脉冲周期,但由于实际应用中环境噪声的影响,一些非故障周期对应的 MKurt 往往大于真正故障周期及其整数倍对应的 MKurt,严重干扰了真正故障周期的识别。因此,低信噪比时 MKurt 谱不能准确识别脉冲周期,且获得 MKurt 谱的过程耗费过多的计算时间。MOMEDA 的另一个不足是滤波信号的长度减少问题,为了克服解卷积的端点效应,滤波信号减少了与滤波器长度相等的样本点。因此, MOMEDA 的滤波信号随着滤波器长度的增加而不断缩短,在一定程度上严重影响信号特征的完整性。

针对 MOMEDA 存在的不足,本文提出一种改进的 MOMEDA (Improved MOMEDA, IMOMEDA) 方法。利用振动信号的平方包络的自相关函数自适应地确定故障脉冲周期,根据识别的故障周期对振动信号解卷积;然后利用信号波形延拓方法对滤波信号延拓使其长度与原始信号保持一致;最后对已得到的解卷积信号再进行一定次数的解卷积运算,增强原始信号中的周期性脉冲特征。分别采用滚动轴承故障仿真信号和实验信号对 IMOMEDA 方法进行了验证,分析结果与 Kurtogram 方法进行了对比,证明了该方法的有效性和优越性。

1 MOMEDA 方法

MOMEDA 方法以多点 D 范数 (Multi D-norm, MDN) 为目标函数来构造一个最优解卷积滤波器 ($f = [f_1, f_2, \dots, f_L]$, L 为滤波器长度),使解卷积信号 y 的

MDN 最大。其目标函数为^[6]⁴⁶¹⁻⁴⁷⁷

$$\text{MDN}(\mathbf{y}, \mathbf{t}, \mathbf{f}) = \max_f \frac{\mathbf{t}^T \mathbf{y}}{\|\mathbf{y}\|} \quad (1)$$

式中, $\mathbf{t}$ 是与解卷积信号 $\mathbf{y}$ 等长度的目标向量,决定了待解卷积脉冲的位置和权重。计算 MDN 对滤波器系数 $\mathbf{f}$ 的导数

$$\frac{d}{d\mathbf{f}} \left(\frac{\mathbf{t}^T \mathbf{y}}{\|\mathbf{y}\|} \right) = \frac{d}{d\mathbf{f}} \left(\frac{t_1 y_1}{\|\mathbf{y}\|} \right) + \dots + \frac{d}{d\mathbf{f}} \left(\frac{t_{N-L} y_{N-L}}{\|\mathbf{y}\|} \right) \quad (2)$$

式中, N 为原始信号 x 的长度。用矩阵表示式 (2) 并令其等于零向量,得到

$$\begin{cases} \|\mathbf{y}\|^{-1} \mathbf{X}_0 \mathbf{t} - \|\mathbf{y}\|^{-3} \mathbf{t}^T \mathbf{y} \mathbf{X}_0 \mathbf{y} = 0 \\ \frac{\mathbf{t}^T}{\|\mathbf{y}\|^2} \mathbf{X}_0 \mathbf{y} = \mathbf{X}_0 \mathbf{t} \end{cases} \quad (3)$$

根据 $\mathbf{y} = \mathbf{X}_0^T \mathbf{f}$, 并假设 $(\mathbf{X}_0 \mathbf{X}_0^T)^{-1}$ 存在,即可得到最优解卷积滤波器系数

$$\mathbf{f} = (\mathbf{X}_0 \mathbf{X}_0^T)^{-1} \mathbf{X}_0 \mathbf{t} \quad (4)$$

$$\mathbf{X}_0 = \begin{bmatrix} x_L & x_{L+1} & \dots & x_N \\ x_{L-1} & x_L & \dots & x_{N-1} \\ \vdots & \vdots & \ddots & \vdots \\ x_1 & x_2 & \dots & x_{N-L+1} \end{bmatrix}_{L \times (N-L+1)}$$

为了有效识别故障周期并提取出周期性故障脉冲特征,通过对给定的一个周期搜索范围进行离散化得到一系列假定周期 $T_1, T_2, \dots, T_m$, 根据式 (5) 构造一系列目标矢量 $\mathbf{t}_1, \mathbf{t}_2, \dots, \mathbf{t}_m$

$$\mathbf{t}_m = \delta_{\text{round}(T_m)} + \delta_{\text{round}(2T_m)} + \dots + \delta_{\text{round}(sT_m)} \quad (5)$$

式中, δ_n 表示在位置 n 处的一个脉冲,非整数周期 T_m 应取最接近的整数值。

根据式 (6) 可计算得到一系列解卷积信号 $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_m$, 并计算解卷积信号的 MKurt, 然后根据 MKurt 谱识别真正的故障周期,进而确定最优解卷积信号

$$[\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_m] = (\mathbf{X}_0 \mathbf{X}_0^T)^{-1} \mathbf{X}_0 [\mathbf{t}_1, \mathbf{t}_2, \dots, \mathbf{t}_m] \quad (6)$$

$$\text{MKurt} = \frac{\left(\sum_{n=1}^{N-L} t_n^2 \right)^2 \sum_{n=1}^{N-L} (t_n y_n)^4}{\sum_{n=1}^{N-L} t_n^8 \left(\sum_{n=1}^{N-L} y_n^2 \right)^2} \quad (7)$$

MOMEDA 克服了传统解卷积方法通过反复迭代构造最优解卷积滤波器的不足,但是需要准确的故障周期作为脉冲特征增强的前提条件,且存在滤波信号的长度减小问题,极大削弱了其在周期性脉冲特征提取中的优势。

2 改进 MOMEDA 方法

为克服 MOMEDA 方法的不足,提出一种基于故障周期自适应识别和信号波形延拓的改进 MOMEDA 方法用于滚动轴承故障特征增强。

2.1 故障周期识别

自相关 (Autocorrelation, AC) 函数是一种检测信

号周期性的有效工具,已被成功应用于滚动轴承的故障诊断^[9-10]。基于 Hilbert 变换的包络解调能够有效凸显旋转机械的故障特征信息^[11]。因此,提出采用平方包络信号的 AC 函数来识别滚动轴承故障脉冲成分的重叠周期。基于 Hilbert 变换计算振动信号的平方包络信号 $a(t)$

$$a(t) = \left| x(t) + i \left(\frac{1}{\pi} \int_{-\infty}^{\infty} \frac{x(\tau)}{t - \tau} d\tau \right) \right| \quad (8)$$

进一步可计算出自相关函数 $R_a(\tau)$

$$R_a(\tau) = \int a(t) a(t + \tau) dt \quad (9)$$

式中, τ 为时间延迟。根据式(9), 当 $a(t)$ 是周期信号时, 自相关函数 $R_a(\tau)$ 也是周期信号, 且在信号周期及其整数倍处取得极大值。因此, 自相关函数能够检测信号的周期性。

为了说明自相关函数的特点, 图 1 展示了一个由周期性脉冲和白噪声混合而成的仿真信号(信噪比为 -6.35 dB, 脉冲周期 T 为 80 个采样点)及其平方包络的 MKurt 谱和 AC 谱。从图 1a 中可以看出一系列微弱的脉冲特征。图 1b 表明 MKurt 易受噪声干扰, 导致时间延迟较小时 MKurt 远大于真正的故障周期及其整数倍对应的 MKurt, 严重影响周期识别效果。图 1c 表明 AC 函数能够有效检测脉冲信号的周期, 当延迟为脉冲周期及其整数倍时, AC 函数都取得局部极大值, 且幅值有逐渐减小的趋势。因此, 可以通过 AC 函数取得最大值时对应的延迟来确定故障脉冲周期 T 。

考虑到实际应用中的滚动轴承的故障周期通常在一定的范围以内, 因此可以在一定的延迟范围内通过寻找 AC 函数的最大值来估计脉冲周期 T 。实际应用中, 延迟范围可以取 30~800, 也可视具体情况对其适当放大或缩小。

2.2 信号波形延拓

解卷积信号的波形延拓主要根据解卷积信号的自身特征进行延拓, 结合图 2 说明其主要步骤:

(1) 识别信号的极值点: 找出信号的所有极值点(包括极大值点和极小值点)及其位置。

(2) 确定对称中心: 如图 2 所示, a 、 b 和 c 分别表示信号的第一个样本点、第一个和第二个极值点。如果 $a \geq c > b$, 以过 a 点的垂线为对称中心, 如图 2a; 如果 $c > a \geq b$, 以过 b 点的垂线为对称中心, 如图 2b; 如果 $b > a \geq c$, 以过 b 点的垂线为对称中心, 如图 2c; 如果 $b > c \geq a$, 以过 a 点的垂线为对称中心, 如图 2d。

(3) 信号波形延拓: 选择对称中心后面一定数量的样本点为对象, 然后以对称中心做镜像即得到延拓后的信号波形, 如图 2 中的粗实线所示。




图 1 仿真信号的 MKurt 谱和 AC 谱

Fig.1 MKurt and AC spectra of simulated signal




图 2 信号波形延拓原理

Fig.2 Principle of signal waveform extension

2.3 IMOMEDA 方法

如前所述, IMOMEDA 在选择延迟范围内通过寻找 AC 函数的最大值自动识别旋转机械的故障脉冲周期。考虑到 IMOMEDA 是非迭代方法以及背景噪声的干扰, 初次识别的脉冲周期可能并不准确, 致使单次解卷积的结果可能并不能达到最优的脉冲增强效果, 因此提出对 IMOMEDA 解卷积后的信号再进行一定次数的解卷积, 从而实现增强周期性故障脉冲特征的目标, 并选择识别的故障周期连续不发生改变一定次数作为算法的终止条件以保证故障周期识别的准确性。图 3 为 IMOMEDA 方法的流程图, 算法的主要步骤如下:

- (1) 针对原始振动信号 x , 确定解卷积滤波器长度 L 、周期搜索(延迟)范围 $[\tau_1, \tau_2]$ 和终止条件 $Iter$ 。
- (2) 计算振动信号的平方包络的 AC 函数, 在选

定的延迟范围内通过寻找 AC 函数的最大值来确定故障周期 T , 并初始化 $i=0$ 。

(3) 根据识别的周期 T 构造解卷积的目标向量 t , 并计算振动信号的样本矩阵 X_0 。

(4) 由式(4)计算最优解卷积滤波器系数 f , 根据 $y=X_0^T f$ 得到解卷积信号 y , 并对其进行波形延拓。

(5) 由滤波信号更新脉冲周期 T 并判断周期 T 是否改变, 若改变, 则重置 $i=0$, 并执行下一步; 若未改变, 则更新参数 $i=i+1$, 并判断 i 是否满足终止条件 $Iter$, 若满足, 则信号 y 即可视为最优解卷积信号, 否则执行下一步。

(6) 把已得到的滤波信号视为新的待解卷积信号, 并重复步骤(3)、(4)和(5)。




图3 IMOMEDA 方法流程图

Fig.3 Flowchart of the IMOMEDA method

2.4 算法参数选择

IMOMEDA 算法的参数包括滤波器长度 L 、终止条件 $Iter$ 和周期搜索范围 $[\tau_1, \tau_2]$ 。滤波器长度 L 过小时脉冲增强效果不明显, 增大滤波器长度 L 能够提高解卷积效果, 但是滤波器长度 L 过大时增加计算时间。根据文献[6]⁴⁶¹⁻⁴⁷⁷的研究结果, 本文中滤波器长度 L 取为 300。此外, 为了获得较好的脉冲增强效果, 可以取较大的终止条件 $Iter$, 但计算时间会随着 $Iter$ 的增大而增加。根据试验结果, 取 $Iter=5$ 即可获得较好的效果, 也可视具体情况对其适当放大。结合实际应用中滚动轴承的故障特征频率范围, 提取滚动轴承故障特征信息时, 延迟范围取 30~800 比较合适, 也可视具体情况对其适当放大或缩小。

3 仿真验证

3.1 轴承内圈故障仿真模型

采用滚动轴承内圈故障仿真模型初步验证改进方法在增强周期性脉冲特征方面的有效性, 故障仿真信号 $x(t)$ 由周期性故障脉冲 $e(t)$ 、离散谐波 $h(t)$ 、随机干扰脉冲 $r(t)$ 和环境噪声 $n(t)$ 混合而成

$$x(t) = e(t) + h(t) + r(t) + n(t) \quad (10)$$

$$e(t) = \sum_{i=1}^{97} 0.5 [1 - \cos(2\pi \times 10t)] e^{-1000(t-i/97-\tau_i)} \cos[2\pi \times 2400(t-i/97-\tau_i)] \quad (11)$$

$$h(t) = \sum_{j=1}^2 B_j \sin(2\pi f_j t + \beta_j) \quad (12)$$

$$r(t) = \sum_{k=1}^3 C_k e^{-800(t-T_k)} \cos[2\pi \times 1700(t-T_k)] \quad (13)$$

式中, τ_i 表示由相对滑动引起的时间延迟, 通常为故障周期的 1%~2%^[12]; B_j 、 f_j 和 β_j 分别为离散谐波的幅值、频率和相位, 取值如表 1 所示; C_k 和 T_k 为随机脉冲的幅值和发生时间, 分别服从正态分布 $0.5N(1.2, 1)$ 和均匀分布 $U(1, 8192)/8192$, 其中 8192 为采样长度。

环境噪声 $n(t)$ 采用高斯白噪声, 仿真信号的信噪比为 -12.45 dB。设置采样频率为 12 800 Hz, 内圈故障特征频率 f_i 为 97 Hz, 故障周期 T_i 约为 132 个采样点。

表 1 离散谐波仿真参数

Tab.1 Parameters of the simulated discrete harmonic

参数 Parameter	$B_1=B_2$	f_1/Hz	f_2/Hz	β_1	β_2
数值 Value	0.025	7	13	$\pi/6$	$-\pi/3$

3.2 轴承内圈故障仿真结果

仿真的轴承内圈故障信号及其包络谱如图 4 所示。由于强烈背景噪声的影响, 时域波形中无法识别周期性脉冲, 且在包络谱中特征频率 f_i 及其倍频不明显。

为了增强周期性脉冲特征, 图 5 给出了 MOMEDA 的解卷积信号及其包络谱。在图 5a 所示的解卷积信号中, 信号长度明显缩短且能观察到微弱的周期性脉冲特征; 包络谱中可以观察到前 6 阶特征频率对应的谱峰, 如图 5b 所示。为了说明 IMOMEDA 的有效性, 图 6 给出了 $Iter=1$ 时 IMOMEDA 的解卷积结果。虽然滤波信号长度保持不变, 但时域和频域结果均表明周期性脉冲特征未被有效增强, 可知 $Iter=1$ 时 IMOMEDA 未能准确识别故障脉冲的周期。图 7 为 $Iter=5$ 时 IMOMEDA 的解卷积结果, 滤波后信号长度不变, 周期性脉冲特征和内圈故障特征频率分别清晰可见, 且解卷积效果明显优于使用理论故障周期的 MOMEDA。作为对比, 图 8 给出了目前轴承故障特征增强常用的 Kurtogram 方法的滤波结果, 显然, 周期性脉冲特征未被有效增强。因此, IMOMEDA 能够有效克服原始方法的不足, 且在增强周期性脉冲特征方面更具优势。




图 4 内圈故障仿真信号及其包络谱

Fig.4 Simulated inner race fault signal and its envelope spectrum




图 7 IMOMEDA 解卷积结果 (Iter=5)

Fig.7 Deconvolution results of IMOMEDA method (Iter=5)




图 5 MOMEDA 解卷积结果

Fig.5 Deconvolution results of MOMEDA method




图 8 Kurtogram 方法滤波结果

Fig.8 Filtering results of Kurtogram method




图 6 IMOMEDA 解卷积结果 (Iter=1)

Fig.6 Deconvolution results of IMOMEDA method (Iter=1)

4 试验结果

为了进一步验证 IMOMEDA 在滚动轴承故障特征增强方面的有效性,利用图 9 所示的铁路滚动轴承试

验台分别采集轴箱轴承外圈轻微故障和滚动体轻微故障的振动加速度信号。实验用轴箱轴承的尺寸参数如表 2 所示。振动信号的采样频率和采样长度分别为 12 800 Hz 和 8 192 个采样点。经计算,轴箱外圈故障特征频率 f_o 为 107.8 Hz,故障周期 T_o 约为 119 个采样点;滚动体故障特征频率 f_b 为 46.8 Hz,故障周期 T_b 约为 273 个采样点。




图 9 铁路滚动轴承试验台

Fig.9 Railway rolling bearing test rig

表 2 实验轴承尺寸参数

Tab.2 Parameters of experimental bearings

轴承节圆直径 Bearing pitch diameter/mm	滚动体直径 Roller diameter/mm	接触角 Contact angle/(°)	滚动体数量 Number of rollers
185	26.68	12.083	17

4.1 轴承外圈故障分析

轴承外圈故障信号及其包络谱如图 10 所示。由于环境噪声的影响,故障脉冲很难从时域波形中观察到,并且在包络谱中外圈故障特征频率及其倍频不明显。

图 11 为 MOMEDA 的解卷积信号及其包络谱。在图 11a 中滤波信号的长度明显缩短且很难观察到周期性故障脉冲,在图 11b 中除 1 阶故障特征频率 f_o 外其他倍频不明显。因此, MOMEDA 未能有效增强轴承外圈故障特征。图 12 为 Iter=1 时 IMOMEDA 的解卷积结果,故障脉冲特征依然淹没在干扰噪声中但外圈故障特征频率 $3f_o$ 明显。




图 10 外圈故障实验信号及其包络谱

Fig.10 Experimental signal of outer race fault and its envelope spectrum




图 11 MOMEDA 解卷积结果

Fig.11 Deconvolution results of MOMEDA method

图 13 为 Iter=5 时 IMOMEDA 的解卷积结果,滤波后信号的长度保持不变且周期性脉冲特征非常明显,包络谱中可以清楚地观察到外圈故障特征频率及其倍频对应的谱峰。可知, Iter=5 时 IMOMEDA 准确识别出了故障脉冲的周期并有效增强了故障特征。图 14 为 Kurtogram 方法的滤波结果,时域和频域结果均未能发现有效反映轴承外圈故障的特征信息。




图 12 IMOMEDA 解卷积结果 (Iter=1)

Fig.12 Deconvolution results of IMOMEDA method (Iter=1)




图 13 IMOMEDA 解卷积结果 (Iter=5)

Fig.13 Deconvolution results of IMOMEDA method (Iter=5)

4.2 轴承滚动体故障分析

轴承滚动体故障信号及其包络谱如图 15 所示,由于强烈环境噪声的影响,周期性故障脉冲不明显,且滚动体故障特征频率及其倍频对应的谱线受到相邻谱线的严重干扰。

为了增强与滚动体故障相关的周期性脉冲特征,图 16 是 MOMEDA 的解卷积结果。图 16a 中可以观察到微弱的周期性脉冲特征,但是滤波后信号的长度明显减少,图 16b 所示的包络谱中只能观察到前 2 阶滚动体故障特征频率。由此可知,借助理论故障周期的 MOMEDA 未能有效增强滚动体故障特征。图 17 为 Iter=1 时 IMOMEDA 的解卷积结果,在图 17a 中滤波信号的长度不变且同样显示出微弱的周期性故障脉




图 14 Kurtogram 方法滤波结果

Fig.14 Filtering results of Kurtogram method

冲,但是在图 17b 所示的包络谱中滚动体故障特征频率及其倍频对应的谱峰明显。Iter = 5 时 IMOMEDA 的解卷积结果如图 18 所示,滤波信号的长度保持不变且呈现出明显的周期性脉冲特征,包络谱中可以清楚地观察到前 7 阶滚动体故障特征频率对应的谱峰。图 19 所示的滤波结果表明 Kurtogram 方法未能有效增强滚动体故障特征。对比可知,改进的方法准确识别出了滚动体故障周期,从而有效增强了轴承的故障脉冲特征。




图 15 滚动体故障实验信号及其包络谱

Fig.15 Experimental signal of rolling element fault and its envelope spectrum

5 结论

本文提出一种改进的 MOMEDA 方法,采用自相关谱自适应识别轴承故障信号的脉冲周期,并根据信号的自身特点对解卷积信号进行波形延拓保证其完整性,仿真和实验结果表明:

1) 平方包络信号的自相关谱在抵抗噪声干扰方面明显优于多点峭度谱,能够在一定的周期搜索范围内自动识别故障周期,并且周期识别的准确性明显优




图 16 MOMEDA 解卷积结果

Fig.16 Deconvolution results of MOMEDA method




图 17 IMOMEDA 解卷积结果 (Iter = 1)

Fig.17 Deconvolution results of IMOMEDA method (Iter = 1)




图 18 IMOMEDA 解卷积结果 (Iter = 5)

Fig.18 Deconvolution results of IMOMEDA method (Iter = 5)

于多点峭度谱,是一种有效的周期检测工具。

2) IMOMEDA 方法克服了 MOMEDA 方法存在的不足,能够自适应识别故障周期且保持了解卷积信号的完整性,通过进行多次解卷积能够显著增强周期性故障脉冲特征,极大地拓展了 MOMEDA 方法的应用范围,且在周期性脉冲特征增强方面比 Kurtogram 方




图 19 Kurtogram 方法滤波结果

Fig.19 Filtering results of Kurtogram method

法更具优势。

3) IMOMEDA 方法已在滚动轴承故障特征提取中得到了验证,下一步应将该方法应用于齿轮、转子等旋转机械零部件的故障特征提取,并推广到工程实际应用中。

参考文献 (References)

- [1] 刘志亮, 潘 登, 左明健, 等. 轨道车辆故障诊断研究进展 [J]. 机械工程学报, 2016, 52(14): 134-146.
LIU ZhiLiang, PAN Deng, ZUO MingJian, et al. A review on fault diagnosis for rail vehicles [J]. Journal of Mechanical Engineering, 2016, 52(14): 134-146 (In Chinese).
- [2] Wiggins R A. Minimum entropy deconvolution [J]. Geoprospection, 1978, 9(16): 21-35.
- [3] McDonald G L, Zhao Q, Zuo M J. Maximum correlated kurtosis deconvolution and application on gear tooth chip fault detection [J]. Mechanical Systems and Signal Processing, 2012(33): 237-255.
- [4] 冷军发, 荆双喜, 王志阳, 等. MCKD 最佳故障周期搜索的齿轮箱故障特征提取 [J]. 机械科学与技术, 2018, 37(1): 36-42.
LENG JunFa, JING ShuangXi, WANG ZhiYang, et al. Optimum fault period searching of MCKD algorithm for fault feature extraction of gearbox [J]. Mechanical Science and Technology for Aerospace Engineering, 2018, 37(1): 36-42 (In Chinese).
- [5] 孙 伟, 李新民, 金小强, 等. 基于 MCKD 和 LMD 的滚动轴承早期故障诊断方法 [J]. 机械强度, 2018, 40(4): 790-795.
SUN Wei, LI XinMin, JIN XiaoQiang, et al. An incipient fault diagnosis method for rolling bearing based on MCKD and LMD [J]. Journal of Mechanical Strength, 2018, 40(4): 790-795 (In Chinese).
- [6] McDonald G L, Zhao Q. Multipoint optimal minimum entropy deconvolution and convolution fix: Application to vibration fault detection [J]. Mechanical Systems and Signal Processing, 2016(82): 461-477.
- [7] 武 超, 孙虎儿, 梁晓华. 基于 Momeda 和包络谱的齿轮微弱故障特征提取 [J]. 机械传动, 2018, 42(3): 164-168.
WU Chao, SUN HuEr, LIANG XiaoHua. Feature extraction of weak fault for gear based on MOMEDA and envelope spectrum [J]. Journal of Mechanical Transmission, 2018, 42(3): 164-168 (In Chinese).
- [8] 祝小彦, 王永杰. 基于 Momeda 与 Teager 能量算子的滚动轴承故障诊断 [J]. 振动与冲击, 2018, 37(6): 104-110.
ZHU XiaoYan, WANG YongJie. Fault diagnosis of rolling bearings based on the MOMEDA and Teager energy operator [J]. Journal of Vibration and Shock, 2018, 37(6): 104-110 (In Chinese).
- [9] Xu X Q, Zhao M, Lin J, et al. Periodicity-based kurtogram for random impulse resistance [J]. Measurement Science and Technology, 2015(26): 085011.
- [10] Miao Y H, Zhao M, Lin J, et al. Application of an improved maximum correlated kurtosis deconvolution method for fault diagnosis of rolling element bearings [J]. Mechanical Systems and Signal Processing, 2017(92): 173-195.
- [11] 巩晓赞, 韩 捷, 陈 宏. 矢 Hilbert 解调及其在齿轮故障诊断中的应用 [J]. 机械强度, 2010, 32(6): 1008-1011.
GONG XiaoYun, HAN Jie, CHEN Hong. Vector-Hilbert demodulation and its application in gear failure diagnosis [J]. Journal of Mechanical Strength, 2010, 32(6): 1008-1011 (In Chinese).
- [12] Cheng Y, Zhou N, Zhang W H, et al. Application of an improved minimum entropy deconvolution method for railway rolling element bearing fault diagnosis [J]. Journal of Sound and Vibration, 2018(425): 53-69.