

基于平均自相关和优化 VMD 的轴箱轴承故障诊断*

陈春俊^{1,2}, 周林春¹, 杨露¹

(1. 西南交通大学机械工程学院 成都, 610031)

(2. 轨道交通运维技术与装备四川省重点实验室 成都, 610031)

摘要 针对动车组运行过程中轴箱轴承振动加速度信号非平稳特性以及较大的背景噪声导致故障特征难以提取的问题,提出一种平均自相关结合参数优化变分模态分解(variational mode decomposition,简称VMD)的轴箱轴承故障诊断方法。首先,利用平均自相关对原始信号进行降噪,增强故障周期性冲击信息;其次,以故障特征频率能量比相反数为适应度函数,利用 Harris 鹰优化算法(Harris hawks optimization,简称HHO)优化VMD的模态分量数和二次惩罚系数,实现对降噪信号的自适应分解并提取出最佳模态分量;最后,计算其平方包络谱进行故障诊断分析。仿真和试验结果表明:该方法能够有效地降低背景噪声的影响,稳定地提取出周期性故障冲击成分,实现轴箱轴承故障的准确诊断。

关键词 动车组;轴箱轴承;故障诊断;平均自相关;变分模态分解;Harris 鹰优化算法

中图分类号 TH133.33

引言

轴箱轴承作为动车组的重要旋转零部件,其健康状况直接影响动车组的运行可靠性和安全性。随着近年来动车组运行速度的不断提高、运营里程的不断增加及其服役年限的增长,轴承电蚀、疲劳磨损及剥落等故障发生的几率也在增加。因此,实现动车组轴箱轴承的在线故障诊断十分必要。

当轴承各部件(内圈、外圈、滚子及保持架)在运行过程中出现局部故障时,将产生周期性的冲击信号,对应的冲击频率即为故障特征频率。基于此,已有许多学者提出了有效的轴承故障诊断方法,如采用经验模态分解(empirical mode decomposition,简称EMD)^[1-2]、局部均值分解(local mean decomposition,简称LMD)^[3]及经验小波变换(empirical wavelet transform,简称EWT)^[4]等信号分解算法结合包络谱分析的故障诊断方法。其中:EMD和LMD均属于递归模态分解方法,缺乏数学理论支撑并有端点效应和模态混叠现象;EWT则需要预先定义滤波器组边界,自适应性较差。VMD^[5]是一种自适应非递归的信号分解算法,能有效避免EMD和LMD算法存在的端点效应和模态混叠现象,在滚动轴承故障诊断领域已得到了较好的应用。Zhao等^[6]提出VMD结合Teager能量算子的方法,实现了风机轴

承的故障诊断。Krishna等^[7]提出一种基于VMD和SVM的轴承故障分类诊断方法,具有较高的诊断准确率。在VMD算法中,模态分量数和二次惩罚因子对分解结果的影响较大,因此选取最佳参数组合尤为重要。针对VMD参数选取问题,已有学者进行了相关研究。王奉涛等^[8]提出的基于能量的VMD模态数选取方法能有效地避免信号的过分解和分解不足。张俊等^[9]提出的利用粒子群优化算法(particle swarm optimization,简称PSO)同时优化VMD和最大相关峭度解卷积(maximum correlated kurtosis deconvolution,简称MCKD)相关参数的方法实现了参数的自适应选取,并在风机轴承故障诊断上取得了较好的诊断效果。Heidari等^[10]提出一种HHO算法,其是一种模拟Harris鹰协同捕食行为的启发式优化算法,具有较强的全局搜索能力和较快的收敛速度,已在许多优化问题中得到应用。

动车组轴箱轴承所处工作环境恶劣,激振源较多,轴承发生故障时的冲击信号往往淹没在较大的背景噪声中,且轴承滚子打滑以及轴的转速发生微小变化均会导致故障冲击周期在小范围内波动,即产生随机的相位误差,因此采用合适的降噪算法对振动信号进行降噪并突出周期性冲击特征尤为重要。目前,在轴承振动信号处理中,已有学者提出了有效的降噪算法,如小波包变换(wavelet packet

* 国家自然科学基金资助项目(51975487);四川省自然科学基金资助项目(2022NSFSC0395)

收稿日期:2020-09-21;修回日期:2021-01-31

transform, 简称 WPT)^[2]、奇异值分解(singular value decomposition, 简称 SVD)^[11]及最小熵解卷积(minimum-entropy deconvolution, 简称 MED)^[12]等。其中:WPT小波基没有标准的选择方法且小波包系数的去噪阈值不易确定;SVD中重构矩阵的有效秩较难确定;MED方法鲁棒性欠佳。自相关作为一种利用信号周期性和噪声随机性特点的降噪算法,通过对信号自身进行延时自相关运算即可达到减小信号中随机噪声并突出周期性成分的目的^[13-14]。Xu等^[15]在自相关运算基础上提出平均自相关算法,能够有效地滤除随机噪声,并通过平均的方式降低随机相位误差的影响,在轴承故障诊断任务中得到了很好的验证。

笔者提出一种平均自相关结合参数优化VMD的高速列车轴箱轴承故障诊断方法,并通过数值仿真信号、轴箱轴承台架试验的外圈人工故障数据以及轴箱轴承寿命试验台产生的轴承外圈实际故障数据验证算法性能并对比分析所提方法的优势。

1 算法理论

1.1 平均自相关

平均自相关^[15]算法通过将信号拆解成有重叠的若干信号段,再计算各信号段的自相关序列并求其平均值,可以有效地抑制噪声、消除由于轴承滚子随机滑动导致的非周期性,算法主要步骤如下。

1) 将长度为 N 的离散信号 x 按照每段信号长度 l 和重叠量 $l-k+1$ 拆分为 m 段, m 可由式(1)计算得出

$$m = \text{floor}((N-l)/(k-1)) \quad (1)$$

其中:floor为向下取整函数。

拆分后的信号可表示为

$$\begin{cases} \mathbf{x}_d^{l \times m} = [\mathbf{x}_d^1 \cdots \mathbf{x}_d^i \cdots \mathbf{x}_d^m] \\ \mathbf{x}_d^i = \begin{bmatrix} x[k+(i-2)(k-1)] \\ \vdots \\ x[k+(i-1)(k-1)] \\ \vdots \\ x[l+(i-1)(k-1)] \end{bmatrix} \end{cases} \quad (2)$$

其中: $\mathbf{x}_d^{l \times m}$ 表示由 m 个长度为 l 的列向量 \mathbf{x}_d^i 组成的矩阵; \mathbf{x}_d^i 为每段原始信号。

2) 信号的自相关计算方法为

$$\mathbf{R}_{xx}(\tau) = E\{x(n)x(n+\tau)\} \quad (3)$$

其中: E 为求期望运算符。

分别对每段原始信号 \mathbf{x}_d^i 进行自相关计算时,设定自相关延迟 τ 的取值范围为 $[\tau_s+1, \tau_e]$ (仅保留延时大于 τ_s 的自相关结果可避免自相关开始时的极值影响),得到大小为 $(\tau_e - \tau_s) \times m$ 的信号自相关矩阵 $\mathbf{R}_{xx}^{(\tau_e - \tau_s) \times m}$,即

$$\begin{cases} \mathbf{R}_{xx}^{(\tau_e - \tau_s) \times m} = [\mathbf{R}_{xx}^1 \cdots \mathbf{R}_{xx}^i \cdots \mathbf{R}_{xx}^m] \\ \mathbf{R}_{xx}^i = [\mathbf{R}_{xx}^i(\tau_s+1) \quad \mathbf{R}_{xx}^i(\tau_s+2) \quad \cdots \quad \mathbf{R}_{xx}^i(\tau_e)]^T \end{cases} \quad (4)$$

其中: \mathbf{R}_{xx}^i 为每段信号的自相关。

3) 对自相关矩阵 $\mathbf{R}_{xx}^{(\tau_e - \tau_s) \times m}$ 按行求平均得到大小为 $(\tau_e - \tau_s) \times 1$ 的列向量 $\mathbf{R}_{xx}^{(\tau_e - \tau_s) \times 1}$,即

$$\mathbf{R}_{xx}^{(\tau_e - \tau_s) \times 1} = E(\mathbf{R}_{xx}^{(\tau_e - \tau_s) \times m}) \quad (5)$$

在进行平均自相关计算时,参数的设置需满足:

- 1) 为了保证自相关运算的精度,每段信号长度 l 应为 τ_e 的2倍;
- 2) 为了保证后续包络谱分析能够有较高的频率分辨率,延时 τ 需要有足够宽的范围,即 $\tau_e - \tau_s$ 足够大。

1.2 VMD

VMD算法是一种自适应模态分解算法,其通过搜寻约束变分模型的最优解来将信号 $x(t)$ 分解为 K 个有限带宽的分量信号 u_k ,信号 $x(t)$ 的约束变分模型为

$$\begin{aligned} \min_{\{u_k\}, \{\omega_k\}} & \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 \right\} \\ \text{s.t.} & \sum_{k=1}^K u_k = x \end{aligned} \quad (6)$$

其中: u_k 为信号的第 k 个本征模态函数(intrinsic mode function, 简称 IMF); ω_k 为 u_k 的中心频率。

为了求解式(6),引入二次惩罚因子 α 和拉格朗日乘子 $\lambda(t)$ 将其变为无约束优化模型,即

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| x(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \left\langle \lambda(t), x(t) - \sum_{k=1}^K u_k(t) \right\rangle \end{aligned} \quad (7)$$

采用交替方向乘子算法不断地迭代更新 $u_k^{n+1}, \omega_k^{n+1}, \lambda_k^{n+1}$ 来寻找式(7)的“鞍点”。 $u_k^{n+1}, \omega_k^{n+1}, \lambda_k^{n+1}$ 的更新表达式为

$$\left\{ \begin{aligned} \hat{u}_k^{n+1}(\omega) &= \frac{\hat{x}(\omega) - \sum_{i=1, i \neq k}^K \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \\ \omega_k^{n+1} &= \frac{\int_0^\infty \omega |\hat{u}_k(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k(\omega)|^2 d\omega} \\ \hat{\lambda}^{n+1}(\omega) &= \hat{\lambda}^n(\omega) + \tau \left(\hat{x}(\omega) - \sum_{k=1}^K \hat{u}_k^{n+1}(\omega) \right) \end{aligned} \right. \quad (8)$$

其中: τ 为更新率。

具体迭代更新步骤如下:

- 1) 初始化 $\{\hat{u}_k^1\}, \{\omega_k^1\}, \hat{\lambda}^1, n = 0$;
- 2) $n = n + 1$, 开始循环;
- 3) 根据式(8)更新 \hat{u}_k, ω_k 和 $\hat{\lambda}_k$;
- 4) 判断是否满足如式(9)所示的收敛条件, 若

满足则停止迭代, 否则返回步骤 2。

$$\sum_{k=1}^K \|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2 / \|\hat{u}_k^n\|_2^2 < \epsilon \quad (9)$$

1.3 HHO 优化 VMD 方法

模态数 K 和二次惩罚系数 α 是影响 VMD 分解效果的 2 个重要参数, 对于实测信号, 采用人为选取参数的方式往往需要进行大量的尝试才能达到理想的分解效果。为解决此问题, 笔者采用哈里斯鹰优化算法对 $[K, \alpha]$ 进行寻优以实现参数的自适应选取。

HHO 算法是一种模拟哈里斯鹰协同捕食行为的启发式优化算法^[16], 其主要由搜索和开发两部分组成。

在搜索阶段, 每只哈里斯鹰的位置均按照其他成员和猎物(兔)的位置随机更新, 即

$$\mathbf{X}_{\text{hawks}}^{t+1} = \begin{cases} \mathbf{X}_{\text{rand}}^t - r_1 |\mathbf{X}_{\text{rand}}^t - 2r_2 \mathbf{X}_{\text{hawks}}^t| & (q \geq 0.5) \\ (\mathbf{X}_{\text{rabbit}}^t - \mathbf{X}_m^t) - r_3 (L_B + r_4 (U_B - L_B)) & (q < 0.5) \end{cases} \quad (10)$$

其中: 上标 t 和 $t + 1$ 分别代表当前迭代周期和下一个迭代周期; $\mathbf{X}_{\text{hawks}}$ 为鹰的位置; $\mathbf{X}_{\text{rabbit}}$ 为兔的位置; \mathbf{X}_{rand} 为随机选取的某个鹰的位置; L_B, U_B 分别为参数的下限和上限; r_1, r_2, r_3, r_4 和 q 是范围为 $[0, 1]$ 的随机数; \mathbf{X}_m 为鹰的平均位置。

HHO 算法通过猎物的逃逸能量 E 来进行搜寻和开发阶段中各种围攻策略之间的转换, 当 $|E_t| \geq 1$ 时进入搜寻阶段, 当 $|E_t| < 1$ 时进入开发阶段。随着追捕时间增加, 逃逸能量逐渐减少, 其定义为

$$E_t = 2E_0 \left(1 - \frac{t}{T_E}\right) \quad (11)$$

其中: t 为当前迭代次数; T_E 为最大迭代次数; E_0 为初始能量, 其为 $[-1, 1]$ 之间的随机数且每次迭代时自动更新。

开发阶段可分为软围攻、硬围攻、渐进式快速俯冲软围攻和渐进式快速俯冲硬围攻 4 种策略。

假设猎物成功逃脱的概率为 p , 当 $p \geq 0.5$ 且 $|E_t| \geq 0.5$ 时, 采用式(12)所示策略对鹰的位置进行更新, 即

$$\begin{cases} \mathbf{X}_{\text{hawks}}^{t+1} = \Delta \mathbf{X}^t - E_t |J \mathbf{X}_{\text{rabbit}}^t - \mathbf{X}_{\text{hawks}}^t| \\ \Delta \mathbf{X}^t = \mathbf{X}_{\text{rabbit}}^t - \mathbf{X}_{\text{hawks}}^t \end{cases} \quad (12)$$

其中: J 是范围为 $[0, 2]$ 的随机数。

当 $p \geq 0.5$ 且 $|E_t| < 0.5$ 时, 采用式(13)所示策略对鹰的位置进行更新, 即

$$\mathbf{X}_{\text{hawks}}^{t+1} = \mathbf{X}_{\text{rabbit}}^t - E_t |\Delta \mathbf{X}^t| \quad (13)$$

当 $p < 0.5$ 时, 根据 $|E_t|$ 的取值, 分别采用式(14)~(17)所示策略对鹰的位置进行更新, 即

$$\mathbf{X}_{\text{hawks}}^{t+1} = \begin{cases} \mathbf{Y} & (F(\mathbf{Y}) < F(\mathbf{X}_{\text{hawks}}^t)) \\ \mathbf{Z} & (F(\mathbf{Z}) < F(\mathbf{X}_{\text{hawks}}^t)) \end{cases} \quad (14)$$

其中: F 为适应度函数。

$$\mathbf{Y} = \begin{cases} \mathbf{X}_{\text{rabbit}}^t - E_t |J \mathbf{X}_{\text{rabbit}}^t - \mathbf{X}_{\text{hawks}}^t| & (|E_t| \geq 0.5) \\ \mathbf{X}_{\text{rabbit}}^t - E_t |J \mathbf{X}_{\text{rabbit}}^t - \mathbf{X}_m^t| & (|E_t| < 0.5) \end{cases} \quad (15)$$

其中: J 是范围为 $[0, 2]$ 的随机数。

$$\mathbf{Z} = \mathbf{Y} + \mathbf{S} \times L_F(D) \quad (16)$$

其中: D 为待优化参数的维度, 即鹰的位置向量长度; \mathbf{S} 是大小为 $1 \times D$ 、范围为 $[0, 1]$ 的向量; L_F 为函数。

$$\left\{ \begin{aligned} L_F(d) &= 0.01 \frac{u\sigma}{|v|^\beta} \\ \sigma &= \left(\frac{\Gamma(1+\beta) \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1+\beta}{2}\right) \beta 2^{\left(\frac{\beta-1}{2}\right)}} \right)^{\frac{1}{\beta}} \end{aligned} \right. \quad (17)$$

其中: d 为待优化参数的维度, 取值为 $1, 2, \dots, D$; u, v 是范围为 $[0, 1]$ 的随机数; β 为常数, 通常取 1.5。

采用 HHO 优化 VMD 的过程中需要确定一个适应度函数来评价优化结果的优劣。考虑到轴承故障诊断的核心问题是识别信号中是否包含由于轴承局部损伤产生的周期性冲击成分, 而周期性冲击在信号包络谱中以故障频率及其倍频体现, 因此笔者采用特征频率能量比相反数 $R_f^{[17-18]}$ 作为适应度函数

来定量描述优化结果的优劣, R_f 值越小故障特征频率越明显, 其表达式为

$$R_f = - \frac{\sum_{i=1}^4 \max(E_s(if-2, if-1, \dots, if+2))}{\text{sum}(E_s)} \quad (18)$$

其中: E_s 为频谱能量序列; $\text{sum}(E_s)$ 为计算频谱总能量; $E_s(if-2, if-1, \dots, if+2)$ 表示频率 $if-2$ 到 $if+2$ 之间的频谱能量序列; \max 表示求该序列的最大值, 目的是容许理论与实际故障特征频率之间的误差, 此处容许误差值设为 ± 2 Hz。

1.4 平方包络谱

轴承故障振动信号的平方包络谱(square envelope spectrum, 简称 SES)能够较好地体现轴承故障频率及其倍频成分^[19], 可表示为

$$\text{SES}(f) = \mathcal{F}[\text{SE}(x(t))] \quad (19)$$

其中: $x(t)$ 为待分析时域信号; \mathcal{F} 为傅里叶变换函数; $\text{SE}(x(t))$ 为 $x(t)$ 平方包络信号, 其通过对 $x(t)$ 计算希尔伯特包络再平方得到。

2 故障诊断方法流程

笔者提出的故障诊断方法包含 2 个阶段:

1) 对采集到的振动加速度信号进行平均自相关计算, 以滤除信号中的随机噪声并初步提取周期性故障冲击成分;

2) 利用参数优化 VMD 对降噪后的信号进行自适应分解, 并得到最佳 IMF, 然后计算最佳 IMF 的平方包络谱进行故障诊断分析。

$$\begin{cases} x_1 = A_1 e^{-\beta_1(t-mT_1-\tau_1)} \sin[2\pi f_{n1}(t-mT_1-\tau_1)] s(t-mT_1-\tau_1) \\ x_2 = A_2 e^{-\beta_2(t-mT_2-\tau_2)} \sin[2\pi f_{n2}(t-mT_2-\tau_2)] s(t-mT_2-\tau_2) \\ x_3 = B \sin(2\pi f_1 t) + C \sin(2\pi f_2 t) \\ x = x_1 + x_2 + x_3 + x_n \end{cases} \quad (20)$$

其中: A 为脉冲信号调制幅值; β 为脉冲衰减阻尼系数; T 为脉冲时间间隔; f_n 为共振频率; τ 为滚子随机滑动值; s 为以 0 为分界点的阶跃函数; B, C 和 f_1, f_2 分别为 2 个谐波的幅值和频率。

笔者所构造的仿真信号中, 故障冲击信号和随机冲击信号的主要参数分别如表 1, 2 所示, 谐波信号的幅值 B, C 均为 0.2, 频率 f_1, f_2 分别为 15 和 30, 添加的高斯白噪声信噪比为 -20 dB。仿真信号如图 2 所示。由图可见, 时域图中仿真信号 x_n 含有大量噪声, 无法直接观察到冲击信号 x_1 , 且包络谱中没

故障诊断方法流程如图 1 所示。

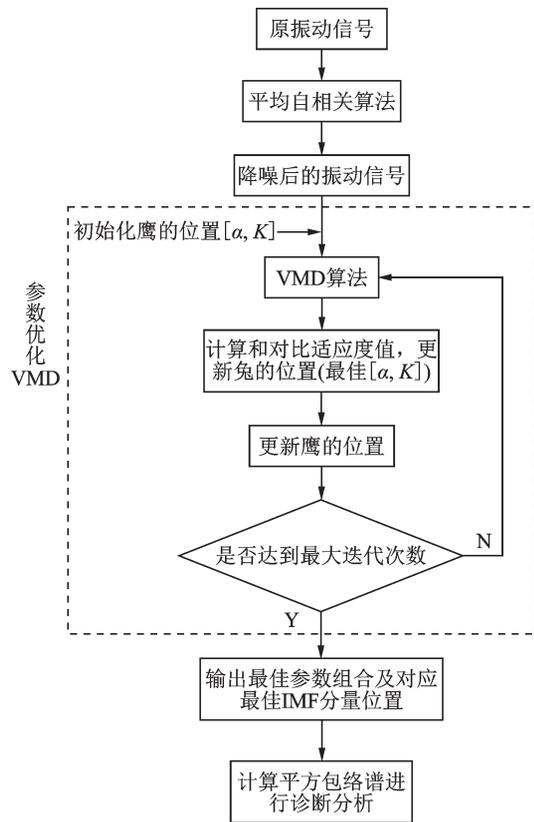


图 1 故障诊断方法流程

Fig.1 Fault diagnosis method flow

3 数值仿真信号验证

笔者构造如式(20)所示的数值仿真信号来验证所提方法的有效性。仿真信号由轴承故障冲击信号 x_1 、随机冲击信号 x_2 、周期性谐波干扰 x_3 和高斯白噪声 x_n 共 4 部分组成^[20-21], 即

有出现明显的故障特征频率。

表 1 故障冲击信号主要参数

Tab.1 Main parameters of fault shock signal

A_1	β_1	T_1	f_{n1}	τ_1
0.8	2 000	1/175	3 000	$[0.01, 0.02] T$

表 2 随机冲击信号主要参数

Tab.2 Main parameters of random shock signal

A_2	β_2	T_2	f_{n2}	τ_2
3	500	1/10	2 000	$[1, 2] T$

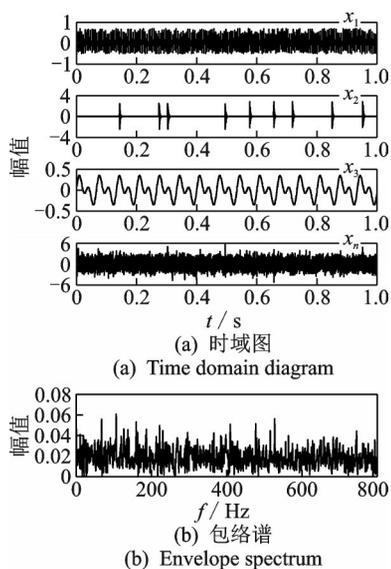


图 2 仿真信号

Fig.2 Simulated signal

采用笔者所提方法对仿真信号进行分析,信号的采样频率 $f_s=10\text{ kHz}$ 。设定平均自相关计算中 $l=24\ 000$, $\tau_s=2\ 000$ 及 $\tau_e=12\ 000$,重叠量为信号段长度的 0.5 倍^[14],即 12 000;VMD 待优化参数 α 和 k 的寻优范围分别设为 $[100,2\ 000]$ 和 $[3,10]$ ^[9];最大迭代周期经过多次尝试,设为 20 时已能达到收敛一致性。仿真信号平均自相关结果、优化收敛曲线及计算结果分别如图 3~5 所示。由图可知:①原信号经过平均自相关降噪后大部分噪声得以滤除,谐波干扰 x_3 突显出来;②适应度迭代到第 14 代时已经收敛,且优化得到的最佳参数组合为 $[5,785]$,适应度最小值为 $-0.567\ 0$;③最佳 IMF 分量 $0\sim 0.04\text{ s}$ 的时域图提取出了周期为 T 的故障冲击成分,且平方包络谱出现了故障频率的 1~4 倍频。

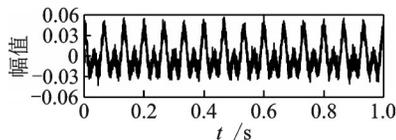


图 3 仿真信号平均自相关结果

Fig.3 Average autocorrelation result of simulation signal

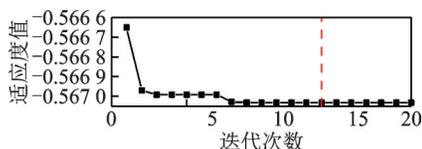


图 4 仿真信号优化收敛曲线

Fig.4 Optimization convergence curve of simulation signal

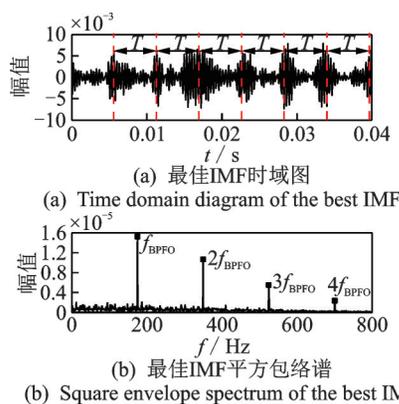


图 5 仿真信号计算结果

Fig.5 Calculation results of simulation signal

为了对笔者所提方法的诊断性能进行分析,采用表 3 中的 2 种方法作为对比。其中:对比方法 1 采用 MCKD 对原始信号降噪再进行包络谱分析;对比方法 2 采用 EMD 对自相关降噪后的信号进行分解,选取 EMD 分解后各分量中特征频率能量比最小的分量进行包络谱分析。

表 3 对比方法

Tab.3 Comparison method

序号	对比方法
1	原信号+MCKD+包络谱
2	原信号+平均自相关+EMD+包络谱

图 6 为仿真信号对比方法结果。对比方法 1 中 MCKD 的滤波器长度、解卷积周期和位移数经过多次尝试分别设为 500, 57.14 和 5,其计算结果如图 6(a)所示,从图中可以看到故障特征频率的 1~4 倍频,但笔者所提算法计算结果频谱更干净,故障频率及其倍频谱线更清晰。对比方法 2 的计算结果如图 6(b)所示,从图中可以看到故障特征频率的 1~4 倍频,且其谱线清晰,因此从另一方面表明平均自相关具有较好的降噪效果。

4 试验验证

4.1 外圈人工故障

外圈人工故障数据来源于 1:1 的跑合试验台,轴承为圆锥滚子轴承,其主要参数如表 4 所示,试验中轴承外圈添加人工局部故障,1:1 整车试验台如图 7 所示。笔者选取 100 km/h 速度级(对应内圈转频 $f_r=10.3\text{ Hz}$)的数据进行分析,信号的采样频率为 10 kHz。根据轴承内圈转频和轴承结构参数可计算出轴承外圈故障的冲击信号周期 $T_{\text{BPFO}}=0.012\text{ s}$,对

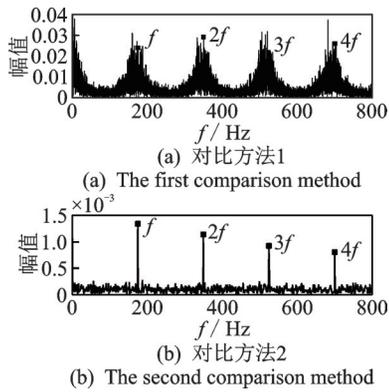


图6 仿真信号对比方法结果

Fig.6 Comparison method results of simulation signal

应的滚子故障特征频率 $f_{BPFO} = 83.3$ Hz。

表4 圆锥滚子轴箱轴承主要参数

Tab.4 Main parameters of tapered roller axle box bearing

轴承节径/ mm	滚子直径/ mm	滚子个数	接触角 /(°)
180	26.9	19	9



图7 1:1整车试验台

Fig.7 1:1 vehicle test bench

图8为外圈人工故障振动信号。由图可见,在时域图中无法观察到周期性的故障冲击信号,且包络谱中没有出现相应的外圈故障特征频率。

采用笔者所提方法对该信号进行分析,计算参数设置与仿真信号相同,外圈人工故障振动信号平

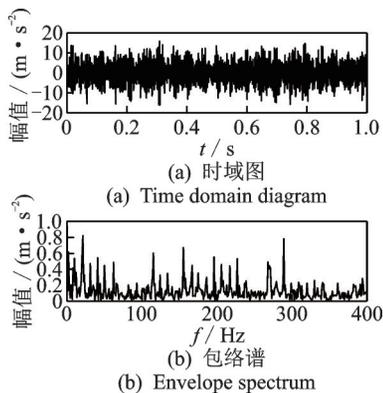


图8 外圈人工故障振动信号

Fig.8 Manual fault vibration signal of outer ring

均自相关结果、优化收敛曲线及计算结果分别如图9~11所示。由图可知:①原信号经过平均自相关降噪后大部分噪声得以滤除且周期为 T_r (转频 f_r 对应时间周期) 的冲击信号突显出来;②适应度在迭代到第13代时已经收敛,且优化得到的最佳参数组合为 [8, 193], 适应度最小值为 -0.672 2;③最佳IMF分量 0~0.08 s 的时域图提取出了周期为 T_{BPFO} 的故障冲击成分,且平方包络谱出现了故障频率的1和2倍频。

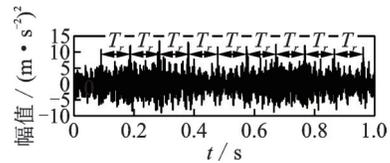


图9 外圈人工故障振动信号平均自相关结果

Fig.9 Average autocorrelation result of outer ring manual fault vibration signal

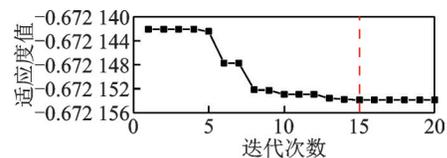


图10 外圈人工故障振动信号优化收敛曲线

Fig.10 Optimization convergence curve of outer ring manual fault vibration signal

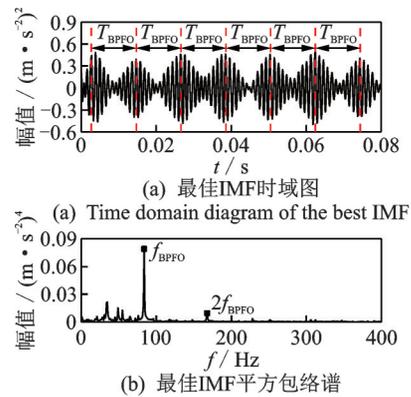


图11 外圈人工故障振动信号计算结果

Fig.11 Calculation results of outer ring manual fault vibration signal

同样采用表3中的对比方法进行对比分析,外圈人工故障振动信号对比方法结果如图12所示。对比方法1中MCKD的滤波器长度、解卷积周期和位移数分别设为600, 119.05和5, 计算得到的包络谱结果如图12(a)所示,由图可见,图中出现了故障频率的1~4倍频且谱线较为清晰。对比方法2的计算结果如图12(b)所示,显然无法从图中观察到故

障特征频率及其倍频成分。

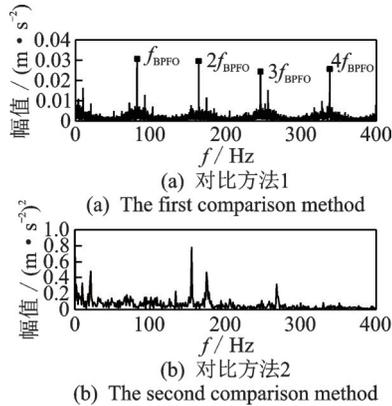


图 12 外圈人工故障振动信号对比方法结果

Fig.12 Comparison method results of outer ring manual fault vibration signal

4.2 外圈实际故障

外圈实际故障振动数据来自某型号动车组轴箱轴承寿命试验台,被试轴承为圆柱滚子轴承,其主要参数如表 5 所示。试验中轴承外圈径向载荷为 300 kN,主轴转速为 2 kr/min(对应轴承内圈转频 $f_i=33.3$ Hz)。随着寿命试验的进行,轴承外圈产生了局部故障,通过在试验台两侧平台上加装振动加速度传感器进行轴承外圈局部故障状态下的振动数据采集,采样频率为 10 kHz。轴箱轴承试验台如图 13 所示。

根据轴承内圈转频和轴承结构参数可计算出轴承的外圈故障的冲击信号周期 $T_{BPF0}=0.004$ 1 s,对应的外圈故障特征频率 $f_{BPF0}=242$ Hz。

表 5 圆柱滚子轴箱轴承主要参数

Tab.5 Main parameters of cylindrical roller axle box bearing

轴承节径/mm	滚子直径/mm	滚子个数
184	27	17



图 13 轴箱轴承试验台

Fig.13 Axle box bearing test bench

图 14 为外圈实际故障振动信号。由图可见,在时域图中难以直接观察到周期性的故障冲击信号,

包络谱中出现了外圈故障特征频率的 1 和 2 倍频及其边频,但不够明显。

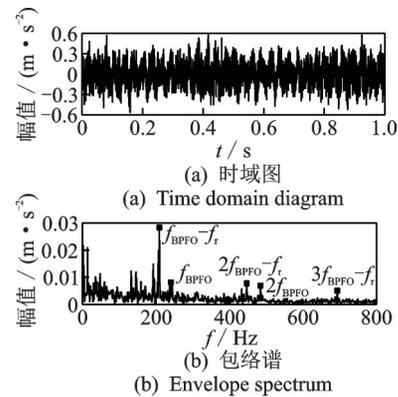


图 14 外圈实际故障振动信号

Fig.14 Actual fault vibration signal of outer ring

采用笔者所提方法对该信号进行分析,计算参数设置与仿真信号相同,外圈实际故障振动信号平均自相关结果、优化收敛曲线及计算结果如图 15~17 所示。由图可见:①原信号经过平均自相关降噪后消除了大部分噪声,低频谐波干扰突显出来;②适应度在迭代到第 9 代时收敛,且优化得到的最佳参数组合为 [6, 1 261],适应度最小值为 -0.683 5;③最佳 IMF 分量 0~0.02 s 的时域图提取出了周期为 T_{BPF0} 的故障冲击成分,且最终平方包络谱中提取出了故障频率的 1~3 倍频,因此可判断轴承产生了外圈故障。

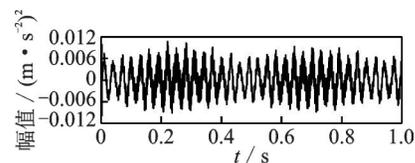


图 15 外圈实际故障振动信号平均自相关结果

Fig.15 Average autocorrelation result of outer ring actual fault vibration signal

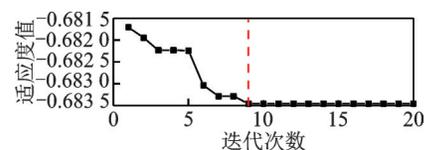


图 16 外圈实际故障振动信号优化收敛曲线

Fig.16 Optimization convergence curve of outer ring actual fault vibration signal

同样地,采用表 3 中的对比方法进行对比分析,外圈实际故障振动信号对比方法结果如图 18 所示。对比方法 1 中 MCKD 的滤波器长度、解卷积周期和位移数分别设为 500, 41.32 和 3,计算得到的包络谱

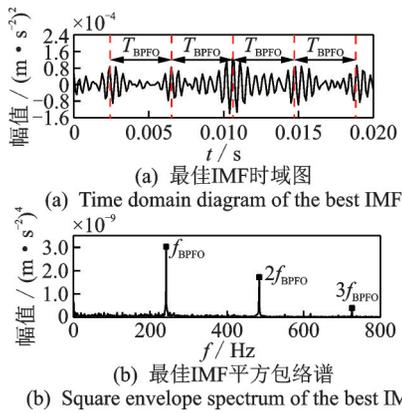


图17 外圈实际故障振动信号计算结果

Fig.17 Calculation results of outer ring actual fault vibration signal

结果如图18(a)所示,从图中可以看到故障特征频率的1~3倍频,但仅有1倍频谱线较为清晰。对比方法2的计算结果如图18(b)所示,由图可见,图中出现了明显的故障特征频率的1~3倍频,但笔者所提方法频谱更加干净。

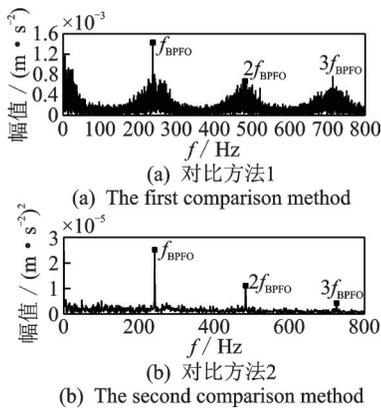


图18 外圈实际故障振动信号对比方法结果

Fig.18 Comparison method results of outer ring actual fault vibration signal

5 结论

1) 动车组轴箱轴承工作条件复杂,受到的激振源多,振动信号噪声较大,采用平均自相关能有效地消除随机噪声并保留低频谐波成分以及周期性故障冲击成分。

2) 采用哈里斯鹰优化算法优化VMD能够准确、稳定地找到最佳参数组合,提高了算法的自适应性。

3) 对仿真信号、外圈人工故障信号以及外圈实际故障信号的分析结果表明:MCKD方法在仿真信号和外圈实际故障中诊断效果较差;平均自相关结合EMD方法无法诊断出1:1跑合试验台的外圈

人工故障;而本研究所提方法对这3种信号均能实现较好的诊断效果,为高速动车组轴箱轴承故障诊断提供了一种新方法。

参 考 文 献

- [1] DYBALA J, ZIMROZ R. Rolling bearing diagnosing method based on empirical mode decomposition of machine vibration signal[J]. Applied Acoustics, 2014, 77:195-203.
- [2] 刘建强, 赵治博, 任刚, 等. 基于小波包分解和集合经验模态分解的列车转向架轴承智能故障诊断方法[J]. 铁道学报, 2015, 37(7):40-45.
LIU Jianqiang, ZHAO Zhibo, REN Gang, et al. An intelligent fault diagnosis method for bogie bearings of train based on wavelet packet decomposition and EEMD [J]. Journal of the China Railway Society, 2015, 37(7):40-45. (in Chinese)
- [3] 杨宇, 王欢欢, 程军圣, 等. 基于LMD的包络谱特征值在滚动轴承故障诊断中的应用[J]. 航空动力学报, 2012, 27(5):1153-1158.
YANG Yu, WANG Huanhuan, CHENG Junsheng, et al. Application of envelope spectrum characteristics based on LMD to roller bearing fault diagnosis[J]. Journal of Aerospace Power, 2012, 27(5):1153-1158. (in Chinese)
- [4] CHEGINI S N, BAGHERI A, NAJAFI F. Application of a new EWT-based denoising technique in bearing fault diagnosis[J]. Measurement, 2019, 144:275-297.
- [5] DRAGOMIRETSKIY K, ZOZZO D. Variational mode decomposition[J]. IEEE Transactions on Signal Processing, 2014, 62(3):531-544.
- [6] ZHAO H S, LI L. Fault diagnosis of wind turbine bearing based on variational mode decomposition and teager energy operator[J]. IET Renewable Power Generation, 2017, 11(4):453-460.
- [7] KRISHNA K R, RAMACHANDRAN K I. Machinery bearing fault diagnosis using variational mode decomposition and support vector machine as a classifier[J]. IOP Conference Series: Materials Science and Engineering, 2018, 310:012076.
- [8] 王奉涛, 柳晨曦, 张涛, 等. 基于k值优化VMD的滚动轴承故障诊断方法[J]. 振动、测试与诊断, 2018, 38(3):540-547.
WANG Fengtao, LIU Chenxi, ZHANG Tao, et al. Fault diagnosis of rolling bearing based on k-optimized VMD[J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(3):540-547. (in Chinese)

- [9] 张俊, 张建群, 钟敏, 等. 基于 PSO-VMD-MCKD 方法的风机轴承微弱故障诊断[J]. 振动、测试与诊断, 2020, 40(2):287-296.
ZHANG Jun, ZHANG Jianqun, ZHONG Min, et al. PSO-VMD-MCKD based fault diagnosis for incipient damage in wind turbine rolling bearing[J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(2):287-296. (in Chinese)
- [10] HEIDARI A A, MIRJALILI S, FARIS H, et al. Harris hawks optimization: algorithm and applications [J]. Future Generation Computer Systems, 2019, 97: 849-872.
- [11] JIANG H M, CHEN J, DONG G M, et al. Study on Hankel matrix-based SVD and its application in rolling element bearing fault diagnosis[J]. Mechanical Systems and Signal Processing, 2015(52/53):338-359.
- [12] 张龙, 胡俊锋, 熊国良. 基于 MED 和 SK 的滚动轴承循环冲击特征增强[J]. 振动、测试与诊断, 2017, 37(1):97-101.
ZHANG Long, HU Junfeng, XIONG Guoliang. Cyclic shock enhancement by the combination of minimum entropy deconvolution and spectral kurtosis[J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(1): 97-101. (in Chinese)
- [13] ZHENG K, LI T L, ZHANG B, et al. Incipient fault feature extraction of rolling bearings using autocorrelation function impulse harmonic to noise ratio index based SVD and teager energy operator[J]. Applied Sciences, 2017, 7(11):1117.
- [14] 张俊甲, 马增强, 王梦奇, 等. 基于 VMD 与自相关分析的滚动轴承故障特征提取[J]. 电子测量与仪器学报, 2017, 31(9):1372-1378.
ZHANG Junjia, MA Zengqiang, WANG Mengqi, et al. Rolling bearing fault feature extraction based on VMD and autocorrelation analysis[J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(9): 1372-1378. (in Chinese)
- [15] XU Y D, ZHEN D, GU J X, et al. Autocorrelated envelopes for early fault detection of rolling bearings[J]. Mechanical Systems and Signal Processing, 2020, 146: 106990.
- [16] ABBASI A, FIROUZI B, SENDUR P. On the application of Harris hawks optimization (HHO) algorithm to the design of microchannel heat sinks[J]. Engineering with Computers, 2021, 37(2):1409-1428.
- [17] HE W P, ZI Y Y, CHEN B Q, et al. Automatic fault feature extraction of mechanical anomaly on induction motor bearing using ensemble super-wavelet transform [J]. Mechanical Systems and Signal Processing, 2015(54/55):457-480.
- [18] 齐咏生, 刘飞, 高学金, 等. 基于 MCKD 和 teager 能量算子的滚动轴承复合故障诊断[J]. 大连理工大学学报, 2019, 59(1):35-44.
QI Yongsheng, LIU Fei, GAO Xuejin, et al. Composite fault diagnosis of rolling bearing based on MCKD and teager energy operator[J]. Journal of Dalian University of Technology, 2019, 59(1):35-44. (in Chinese)
- [19] 陈祥龙, 冯辅周, 张兵志, 等. 基于平方包络谱相关峭度的最优共振解调诊断滚动轴承故障[J]. 机械工程学报, 2018, 54(21):90-100.
CHEN Xianglong, FENG Fuzhou, ZHANG Bingzhi, et al. Rolling bearing fault diagnosis with optimal resonant frequency band demodulation based on squared envelope spectral correlated kurtosis [J]. Journal of Mechanical Engineering, 2018, 54(21): 90-100. (in Chinese)
- [20] CHENG Y, WANG Z W, ZHANG W H, et al. Particle swarm optimization algorithm to solve the deconvolution problem for rolling element bearing fault diagnosis[J]. ISA Transactions, 2019, 90:244-267.
- [21] CHEN B Y, ZHANG W H, SONG D L, et al. Blind deconvolution assisted with periodicity detection techniques and its application to bearing fault feature enhancement[J]. Measurement, 2020, 159:107804.



第一作者简介:陈春俊,男,1967年7月生,博士、教授、博士生导师。主要研究方向为轨道交通设备性能测试、诊断与控制。曾发表《Investigation of effect of train body vibration on measurement of fluctuation pressure on the surface of high-speed train》(《Measurement》2021, Vol.168)等论文。

E-mail: cjchen@swjtu.edu.cn