

时变转速下基于 IFMD 的行星齿轮箱 微弱故障诊断

王朝阁¹, 张奇奇¹, 周福娜¹, 王 冉¹, 胡 雄¹, 李宏坤²

(1. 上海海事大学物流工程学院, 上海 201306; 2. 大连理工大学机械工程学院, 辽宁 大连 116024)

摘要: 针对强背景噪声干扰且变转速下行星齿轮箱早期微弱故障特征难以被有效识别的问题, 提出一种改进特征模态分解 (Improved Feature Mode Decomposition, IFMD) 的时变工况行星齿轮箱微弱故障诊断方法。对于特征模态分解算法中的关键输入参数分解模态个数 n 、滤波器个数 K 和滤波器长度 L 需要依靠人为经验反复尝试而不具有自适应的问题, 提出通过尺度空间谱划分来确定所需分解模态个数 n ; 在此基础上, 以谱基尼指数 (Spectral Gini Index, SGI) 作为目标函数, 采用粒子群算法自动确定最佳的滤波器个数 K 和滤波器长度 L 。最优输入参数组合下, 采用 IFMD 对故障信号进行最佳模态分解, 并选取 SGI 值最大的分量作为敏感模态。从敏感分量的包络阶次谱中提取显著故障特征阶次来准确判别故障类型。通过变转速仿真信号和工程实验数据分析表明, 相比 PSO-VMD 方法、MED 方法、SGMD 方法和快速谱峭度方法, 所提方法能够更加清晰、全面地提取微弱故障信息, 提高了时变工况下行星齿轮箱早期故障特征的表征能力和诊断精度。

关键词: 故障诊断; 行星齿轮箱; 时变转速工况; 特征模态分解; 微弱故障

中图分类号: TH165⁺.3; TH132.425 **文献标志码:** A **文章编号:** 1004-4523(2024)11-1980-13

DOI: 10.16385/j.cnki.issn.1004-4523.2024.11.018

引 言

行星齿轮箱通常被用作直升机、舰船、装甲车、风力发电和工业机器人等重要机械装备的传动装置, 其健康状况直接关乎整个机器的安全稳定运行^[1]。在实际工程应用中, 行星齿轮箱根据需求要长期服役于变转速、变载荷等复杂工况环境, 这导致齿轮上将承受交变的动态重载荷作用力, 从而容易出现故障。变工况下, 故障振动信号中的特征频率随时间动态变化, 现有的以稳态工况为前提的诊断技术将不再适用, 这给行星齿轮箱故障诊断带来了巨大挑战。因此, 研究新颖的变工况行星齿轮箱故障诊断方法, 具有重要的实际工程意义^[2-3]。

计算阶次跟踪通过对振动信号进行等角度重采样将时域非平稳信号转换为角域平稳信号, 从而消除转速变化带来的影响, 是时变工况下机械设备故障诊断常用的分析工具^[4]。然而, 变工况下的行星齿轮箱故障信号受噪声污染严重, 且具有非平稳、多分量调制和特征微弱等特点, 因此仅靠单一手段难以有效提取有用信息。近年来, 学者们提出了最小熵解卷积 (Minimum Entropy Deconvolution,

MED)、最大相关峭度解卷积 (Maximum Correlation Kurtosis Deconvolution, MCKD) 和多点最优最小熵解卷积 (Multipoint Optimal Minimum Entropy Deconvolution Adjusted, MOMEDA) 等方法^[5-7], 并在机械故障诊断领域得到了广泛的应用。然而, MED 在故障信号的解卷积过程中只能突显少数大的脉冲成分, 会丢失周期性冲击特征; MCKD 和 MOMEDA 虽然实现了对周期性冲击成分的有效提取, 但算法中存在多个关键输入参数需要依靠人为主观选取, 缺乏自适应性。自适应模态分解方法由数据驱动, 能够自适应地将一个复杂的多分量信号分解为若干个反映信号局部变化特征的模式分量。例如, 经验模态分解 (Empirical Mode Decomposition, EMD)^[8] 和局部均值分解 (Local Mean Decomposition, LMD)^[9] 通过不断地迭代和筛分, 自适应地将信号分解为若干个本征模态函数, 从而有效揭示信号中蕴含的特征成分和细节信息。但是, EMD 和 LMD 均存在模态混叠和端点效应等不足, 影响分解精度。集合经验模式分解和总体局部平均分解通过添加白噪声辅助分解来抑制模态混叠现象^[10-11], 但是会造成计算量大幅增加, 且添加白噪声参数 (噪声的幅值和集成次数) 的选取机理尚不明确。不同于

EMD 及其衍生算法,经验小波变换(Empirical Wavelet Transform, EWT)^[12]是对信号的 Fourier 频谱进行自适应分割,然后通过构造小波滤波器组来提取信号中的模态分量,具有完备的理论基础和较快的运算速度。但 EWT 容易受噪声影响从而导致频谱划分过于密集,使结果出现过分解。辛几何模态分解(Symplectic Geometry Mode Decomposition, SGMD)^[13]采用辛几何相似变换及对角平均获得相应的辛几何分量,该方法在处理非平稳信号方面有着良好的效果,但该方法根据各分量间的周期、频率等相似性重构最终的模态分量,会导致分析结果稳定性较差。变分模态分解(Variational Mode Decomposition, VMD)^[14]作为一种无递归的分解算法,将信号分解问题转化为变分求解问题,通过迭代求解约束变分模型的最优解来实现信号自适应分解。然而,VMD 需要预设模态个数和惩罚因子等参数,若参数选取不合理将严重影响其性能。

为克服上述方法的缺陷,受解卷积和自适应信号分解原理启发,MIAO 等^[15]提出了特征模态分解(Feature Mode Decomposition, FMD)算法,作为一种新颖的自适应非平稳信号分解理论,通过迭代更新滤波器系数来构建自适应的 FIR 滤波器组,使滤波信号无限接近解卷积相关峭度(CK)的目标函数,从而将非平稳多分量信号分解为不同的模态分量。FMD 综合考虑了信号的冲击性和周期性,并且对干扰和噪声具有一定的鲁棒性,在分解过程中无需先验知识即可获得信号的故障周期。然而,FMD 分解效果受分解模态个数 n 、滤波器个数 K 和滤波器长度 L 的影响。文献[16]提出参数优化的 FMD,通过平方包络谱特征能量比的网格搜索方式来选取模态个数 n 与滤波器长度 L ,并将其应用于平稳工况下轴承故障诊断。然而,滤波器个数 K 的选取对诊断精度也具有较大影响,将 FMD 用于变工况下行星齿轮箱故障诊断领域的研究尚未见报道。

针对上述问题,本文提出一种基于 IFMD 的时变工况早期微弱故障特征提取方法。首先,利用计算阶次跟踪对变工况下行星齿轮箱故障信号进行角域重采样,将其转化为角域信号;随后,根据角域信号尺度空间谱的自适应分割来确定 IFMD 分解模态个数 n ;在此基础上,采用粒子群优化算法自动选取最佳的滤波器数量 K 和长度 L ;在最佳参数组合下,

$$W_M = \begin{bmatrix} \left(\prod_{m=0}^M u_k(1 - mT_s) \right)^2 & 0 \\ 0 & \left(\prod_{m=0}^M u_k(2 - mT_s) \right)^2 \\ \vdots & \\ 0 & 0 \end{bmatrix}$$

采用 IFMD 对角域故障信号进行最佳模态分解,获取敏感模态分量;最后,从敏感分量的包络阶次谱中提取明显故障特征阶次信息来准确定位故障。数值仿真和实测数据分析表明,所提方法能够清晰、准确地提取到早期微弱的故障特征,为时变工况下行星齿轮箱故障诊断提供了一种研究思路。

1 改进的特征模态分解

1.1 FMD 算法

FMD 是一种无递归的自适应分解算法,通过建立 FIR 滤波器组、迭代更新滤波器系数、估计被测信号故障周期,从而实现各模态分量的有效分离。设任一原始信号时间序列为 $x(n) = x_1, x_2, \dots, x_N$, 其中 N 为信号长度。FMD 对信号 x 的分解过程可转换为对如下约束问题的求解^[15]:

$$\arg \max_{\{f_k(l)\}} \left\{ CK_M(u_k) = \frac{\sum_{n=1}^N \left(\prod_{m=0}^M u_k(n - mT_k) \right)^2}{\left(\sum_{n=1}^N u_k^2(n) \right)^{M+1}} \right\}$$

$$\text{s.t. } u_k(n) = \sum_{l=1}^L f_k(l) x(n - l + 1) \quad (1)$$

式中 $u_k(n)$ 为第 k 个分解模态; f_k 为第 k 个 FIR 滤波器,其长度为 L ; T_k 为估计的故障周期; M 为位移数。

采用文献[17]中的迭代特征值分解法来求解式(1),分解模态用矩阵的形式可表示为:

$$u_k = X f_k \quad (2)$$

其中:

$$u_k = \begin{bmatrix} u_k(1) \\ \vdots \\ u_k(N - L + 1) \end{bmatrix}, \quad X = \begin{bmatrix} x(1) & \cdots & x(L) \\ \vdots & & \vdots \\ x(N - L + 1) & \cdots & x(N) \end{bmatrix}, \quad f_k = \begin{bmatrix} f_k(1) \\ \vdots \\ f_k(L) \end{bmatrix}.$$

因此,分解模式的 CK 值可被定义为:

$$CK_M(u_k) = \frac{u_k^H W_M u_k}{u_k^H u_k} \quad (3)$$

式中 上标“H”表示矩阵的共轭转置; W_M 为中间变量,用来控制加权相关矩阵,其表达式为:

$$W_M = \begin{bmatrix} \left(\prod_{m=0}^M u_k(1 - mT_s) \right)^2 & 0 & \cdots & 0 \\ 0 & \left(\prod_{m=0}^M u_k(2 - mT_s) \right)^2 & & \\ \vdots & & & \\ 0 & 0 & & \\ \cdots & \left(\prod_{m=0}^M u_k(N - L + 1 - mT_s) \right)^2 & & \end{bmatrix} \frac{1}{\sum_{n=1}^{N-L+1} u_k^{M-1}(n)}.$$

将式(2)代入式(3)中,得到如下表达式:

$$CK_M(u_k) = \frac{f_k^H X^H W_M X f_k}{f_k^H X^H X f_k} = \frac{f_k^H R_{XWX} f_k}{f_k^H R_{XX} f_k} \quad (4)$$

式中 R_{XWX} 为加权相关矩阵; R_{XX} 为相关矩阵。

式(4)中,可通过求解一个广义特征值使滤波器系数最大化,且最大特征值 λ 对应最大的 f 系数:

$$R_{XWX} f_k = R_{XX} f_k \lambda \quad (5)$$

因此,随着迭代进行,第 k 个滤波器系数将不断被更新,从而逐渐逼近所设定的目标,即滤波信号的 CK 值达到最大。在滤波器系数更新的过程中,故障周期 T_k 起着决定性的作用。这里,每个滤波信号的周期由 u_k 自相关谱通过过零点后的局部最大值对应的时刻确定^[18]。

获得分解的模态后,计算每两个模态分量之间的相关系数,构建一个 $K \times K$ 的相关矩阵 $CC_{(K \times K)}$,选取具有最大相关系数 CC_{\max} 的两个模态分量,并通过估计故障周期来计算它们的 CK 值。随后,为保留含有更多故障信息的模态,选择 CK 值较大的模态分量作为最终的分解模态。

最终,信号 x 通过 FMD 分解获得 n 个模态分量。FMD 算法流程如图 1 所示。

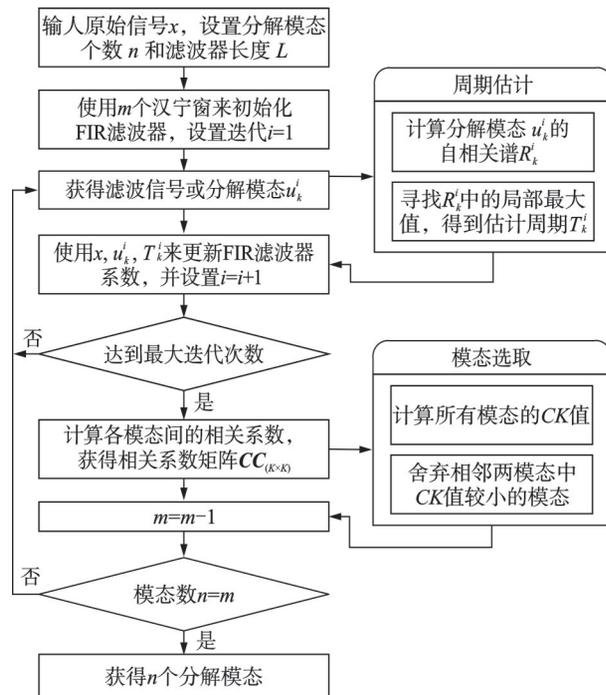


图 1 FMD 算法流程图

Fig. 1 FMD algorithm flowchart

1.2 参数的自适应选取

FMD 算法中的输入参数: 分解模态个数 n 、滤波器个数 K 和滤波器长度 L 直接影响分解的性能。因此, 寻找与故障信号相匹配的最佳参数组合 $[n, K, L]$ 对提高诊断的准确性至关重要。

(1) 分解模态个数 n 。参数 n 决定信号分解的程度, 过大的 n 值将会产生冗余模态, 过小的 n 值将造成分解不充分。为选取合适的 n 值, 本文采用尺度空间的傅里叶频谱划分来自适应确定最佳分解模态个数。尺度空间表示是一种能从信号频谱中快速寻找有意义模态的方法, 且具有良好的抗噪性。对于离散信号 $x(m)$, 其傅里叶变换为:

$$X(f) = \sum_{m=-\infty}^{+\infty} x(m) e^{-2\pi f m} \quad (6)$$

信号的离散尺度空间表示为^[19]:

$$L(f, s) = g(f, s) * X(f) = \sum_{\tau=-P}^{+P} g(\tau, s) X(f - \tau) \quad (7)$$

式中 $g(f, s) = \frac{1}{\sqrt{2\pi f}} e^{-\frac{f^2}{2s}}$ 为核函数; s 为尺度参数;

* 表示卷积; P 为高斯核函数长度, 这里取 $P = 6\sqrt{s} + 1$ 以使其近似误差足够小。

尺度参数 s 设定之后, 离散尺度空间 $L(f, s)$ 中的每个局部极大值均对应一个单分量成分, 每个分量的带宽由相邻的局部极小值确定。因此, 寻找有意义的模态, 可通过检测 $L(f, s)$ 尺度曲线上的所有局部极大值, 并在其两侧搜寻局部极小值来确定每个模态分量的边界。如此可获得傅里叶谱分割时的边界点 $\omega_n (n = 1, 2, 3, \dots, D)$, 其中 D 为划分的连续频带的个数, 即自动寻找到 D 个有意义的模态分量。上述获得的模态分量数目成为 FMD 算法中最佳分解模态个数确定的依据 (即 $n = D$)。另外, 为保障分解模态中尽可能多地包含故障信息, 尺度参数 s 应取较大的值, 但过大的 s 将会忽略掉与故障相关的微弱特征。因此, 本文设置尺度参数 $s = 3 \times f_{ch}^2$, f_{ch} 为故障特征阶次。

(2) 滤波器个数 K 与滤波器长度 L 。参数 K 决定初始 FIR 滤波器对频带的划分个数, 为了满足分解条件, 要求 $K \geq n$; 然而, K 值过大会带来额外的计算量。同样地, 滤波器长度 L 直接影响着滤波器的性能与计算效率, L 过小将会造成滤波效果粗糙, 而过大的 L 会导致分解失真并增加运算量。为了选取最优的参数组合 $[K, L]$, 本文采用谱基尼指数 (SGI) 作为目标函数来自适应地确定最佳的滤波器个数和滤波器长度。SGI 可以有效量化滤波信号中的瞬态故障冲击, 其值越大表明信号中蕴含的故障冲击特征越明显。SGI 定义如下^[20]:

$$SGI = 1 - 2 \sum_{q=1}^N \frac{SE^r[q]}{\|SE\|_1} \left(\frac{N - q + 0.5}{N} \right) \quad (8)$$

式中 $\|\cdot\|_1$ 表示 L_1 范数; N 表示信号的长度; SE^r 为 SE 的升序排列 (即 $SE[1] \leq SE[2] \leq \dots \leq SE[N]$); SE 为待分析信号平方包络谱的离散序

列,其表达式为:

$$SE = |\bar{y}|^2 = |y + j \cdot h(y)|^2 \quad (9)$$

式中 \bar{y} 为分量信号 y 的解析信号; $h(\cdot)$ 为 Hilbert 变换; $j^2 = -1$ 。

1.3 改进的特征模态分解算法

基于上述讨论,首先通过尺度空间谱自适应快速地确定 FMD 算法中最佳的分解模态个数 n ; 然后,根据输入参数之间的限制条件 $K \geq n$, 确定 K 和 L 的寻优区间,将 SGI 作为参数寻优的目标函数,利用 PSO 优良的寻优特性^[21-22],自动获取最优分解参数组合 $[K, L]$,从而实现最佳的模态分解。IFMD 算法在时变转速下行星齿轮箱微弱故障诊断中的具体实现步骤如下:

步骤 1: 输入变转速行星齿轮箱故障信号。

步骤 2: 利用计算阶次跟踪将行星齿轮箱故障信号转化为角域,并计算角域信号的空间尺度表示,根据空间尺度谱来确定分解模态个数 n 。

步骤 3: 初始化粒子群算法中的各项数值,本文设置粒子群个数为 30,最大迭代次数为 40; 设置 FMD 中滤波器个数寻优区间为 $K \in [n, n + C]$, 其中 C 为常数,本文取 $C = 10$ 。综合考虑 FMD 的分解性能和计算效率,滤波器长度寻优区间设置为 $L \in [30, 100]$, 这里参考文献[15]中给出的建议区间。以参数组合 $p = (K, L)$ 作为粒子,随机产生一定数量的参数组合作为粒子的初始位置,随机初始化每个粒子的移动速度。

步骤 4: 采用 SGI 作为参数寻优的目标函数,即 FMD 的参数寻优可以理解成求取 SGI 最大化的问题。具体的优化问题构造如下:

$$\arg \max_{p_i=(K,L)} \{SGI_{p_i}\}, \text{ s.t. } K \in [n, n + 10] \text{ and } L \in [30, 100] \quad (10)$$

式中 p_i 表示第 i 个粒子的位置。

步骤 5: 计算当前迭代中每个粒子的目标函数,并记录个体局部最优 p_i^d 与种群全局最优 g^d ; 利用下式更新种群的速度 v_i 与位置 p_i , 循环迭代,转到步骤 3,直到满足终止条件,获取最优参数组合 $[n, K, L]$:

$$\begin{cases} v_i(d+1) = \omega v_i(d) + c_1 \eta [p_i^d - p_i(d)] + \\ \quad c_2 \eta [g^d - p_i(d)] \\ p_i(d+1) = x_i(d) + v_i(d+1); i = 1, 2, \dots, r \end{cases} \quad (11)$$

式中 $x_i(d)$ 为第 i 个粒子的当前位置; $p_i(d)$ 为第 d 次迭代中第 i 个粒子的位置; $v_i(d)$ 为第 d 次迭代中第 i 个粒子的速度; ω 为惯性权重; c_1 和 c_2 为加速度因子; η 为介于 $[0, 1]$ 之间的随机数。

步骤 6: 利用参数优化的 FMD 将角域信号分解为一系列最佳模态,并选取 SGI 值最大的模态分量作为敏感模态。

步骤 7: 对敏感模态分量进行包络解调处理,提取故障特征阶次信息,从而定位行星齿轮箱故障。诊断方法流程如图 2 所示。

2 仿真信号分析

2.1 变工况太阳轮局部故障模型

为验证所提方法在时变转速下行星齿轮微弱故障特征提取中的有效性,构建太阳轮局部故障信号模型。该信号模型 $x(t)$ 由太阳轮故障冲击振动 $g(t)$ 、其他零部件旋转振动 $r(t)$ 、随机冲击 $s(t)$ 和噪声 $n(t)$ 四部分组成,其方程如下:

$$x(t) = g(t) + r(t) + s(t) + n(t) \quad (12)$$

在变速工况下,齿轮箱中各部件的故障特征频率和啮合频率将随着转速的改变而发生实时变化。因此,构建的太阳轮故障冲击数学模型为^[23]:

$$\begin{aligned} g(t) = & \left[1 - \cos \left(2\pi \int_0^T f_{sr}(t) dt \right) \right] \cdot \\ & \left[1 + A \cos \left(2\pi \int_0^T f_s(t) dt + \theta_1 \right) \right] \cdot \\ & \cos \left[2\pi \int_0^T f_m(t) dt + B \sin \left(2\pi \int_0^T f_s(t) dt + \theta_2 \right) + \theta_3 \right] \end{aligned} \quad (13)$$

式中 A 和 B 为常数; θ_1 , θ_2 和 θ_3 为初始相位。在仿真瞬时转速匀速上升的工况,令太阳轮转频为 $f_{sr}(t) = 3.5t + 6$, 啮合频率为 $f_m(t) = \frac{50}{3} f_{sr}(t)$, 太阳轮故障频率为 $f_s(t) = 2.5f_{sr}(t)$ 。

行星齿轮箱在运转过程中,其他零部件的振动也会被传感器所拾取到,因此用高、低谐波分量分别表示不同部件的正常旋转振动:

$$\begin{aligned} r(t) = & C \sin \left[2\pi \int_0^T f_{sr}(t) dt + \theta_3 \right] + \\ & D \sin \left[12\pi \int_0^T f_{sr}(t) dt + \theta_4 \right] \end{aligned} \quad (14)$$

式中 C 和 D 为常数; θ_4 为初始相位。

此外,在故障信号收集时,考虑齿轮箱壳体可能受电磁干扰或偶然撞击而产生随机冲击:

$$\begin{cases} s(t) = \sum_j R_j S(t - Tr_j) \\ S(t) = e^{-\beta t} \sin(2\pi f_{RE} t) \end{cases} \quad (15)$$

式中 R_j 和 Tr_j 分别为随机脉冲幅值和出现时刻; $S(t)$ 为单位脉冲; f_{RE} 为脉冲激发的共振频率; β 为阻尼系数。

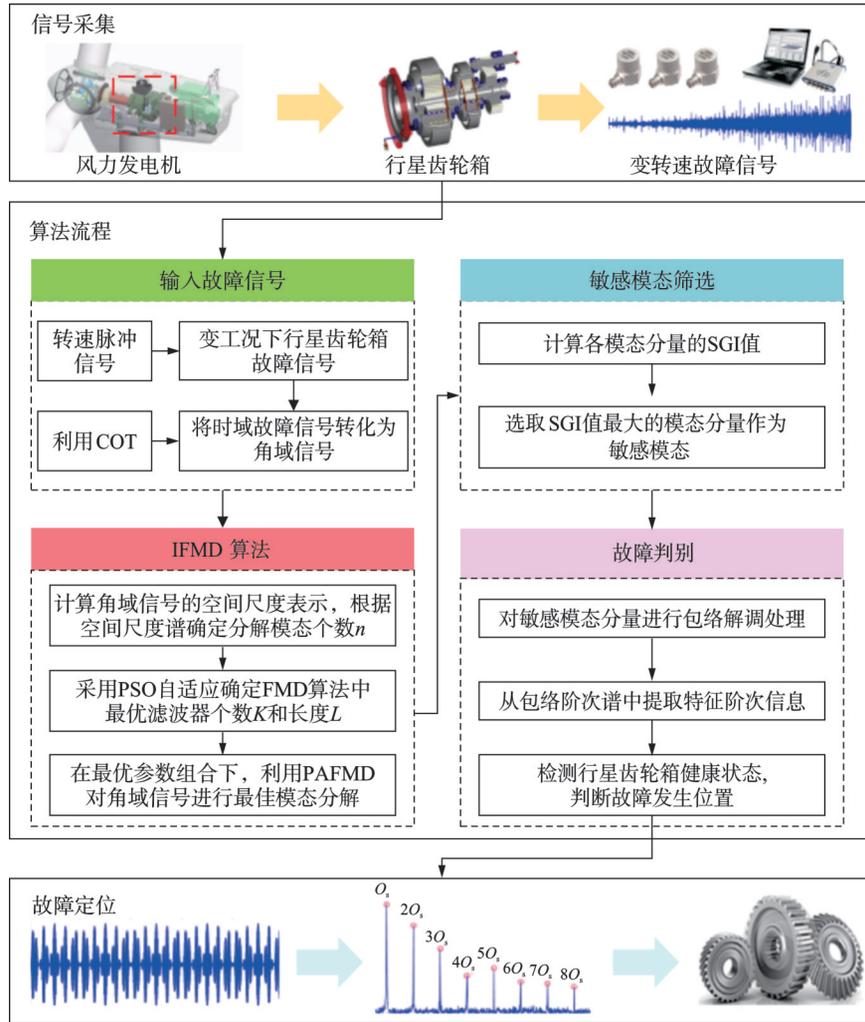


图 2 基于 IFMD 的时变工况故障诊断流程

Fig. 2 Fault diagnosis process for time-varying speed operating condition by IFMD

$n(t)$ 为故障仿真信号中混入的信噪比 $SNR = -10$ dB 的高斯白噪声。仿真构建时,采样频率设为 12000 Hz,采样时长为 8 s。仿真信号中各参数值如表 1 所示。

表 1 变工况下太阳轮故障仿真数值
Tab. 1 Numerical simulation of sun gear fault signal under variable operating conditions

参数	数值	参数	数值
A	2	R_1	1.4
B	0.06	R_2	3.4
θ_i	0	R_3	6.6
C	0.3	β	180
D	0.2	f_{RE}/Hz	1000

2.2 太阳轮故障仿真实验

将表 1 中数值分别代入式(13)~(15)中,得到时变工况下太阳轮故障仿真信号中各分量如图 3 所示。图 4 为太阳轮故障仿真信号及其傅里叶频谱、

包络谱和阶次谱。由图 4 可知,随着转速升高,故障引起的冲击间隔逐渐减小,由于受强噪声的影响,故障冲击已被完全掩盖;同时,在对应的频谱和包络谱中均出现了频率模糊现象,无法提取到有用的特征频率信息;此外,在阶次谱中谱线较为复杂,与故障相关的阶次信息已被噪声掩盖。因此,传统的分析方法对行星齿轮箱微弱故障失去诊断能力。

为了有效提取表征太阳轮故障的特征信息,采用所提方法对图 4(a)中的混合仿真信号进行分析。首先,通过计算阶次跟踪将时变工况下的混合故障仿真信号转化为角域,并对角域信号频谱进行尺度空间表示,得到尺度空间谱如图 5 所示。可以看到,尺度空间谱根据角域信号特征自适应识别有意义模态的划分边界(图 5 中红色点划线),共确定 5 个模态分量。因此,设置 IFMD 中最佳分解模态个数 $n^* = 5$ 。随后,按 1.2 节关键参数选取机制,设置滤波器个数 K 和长度 L 的寻优区间分别为 $[5, 15]$ 和 $[30, 100]$ 。随后,采用 PSO 算法确定最佳参数为 $K^* = 7$ 和 $L^* = 45$ 。

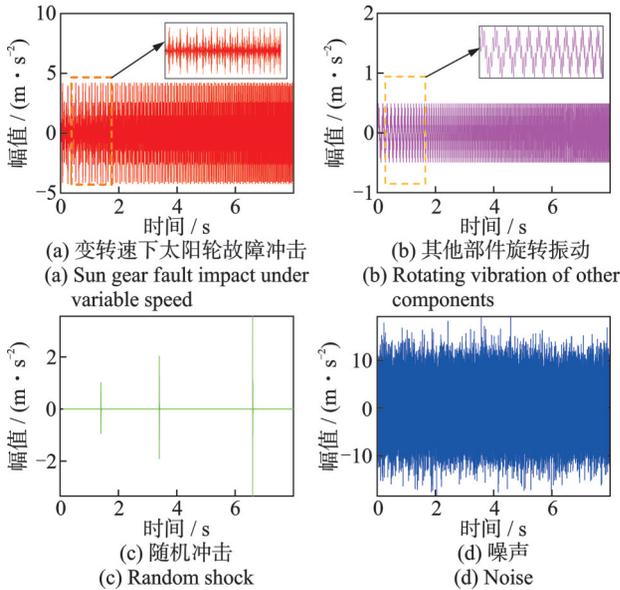


图 3 变工况下仿真信号各分量

Fig. 3 Simulation signal components under variable operating conditions

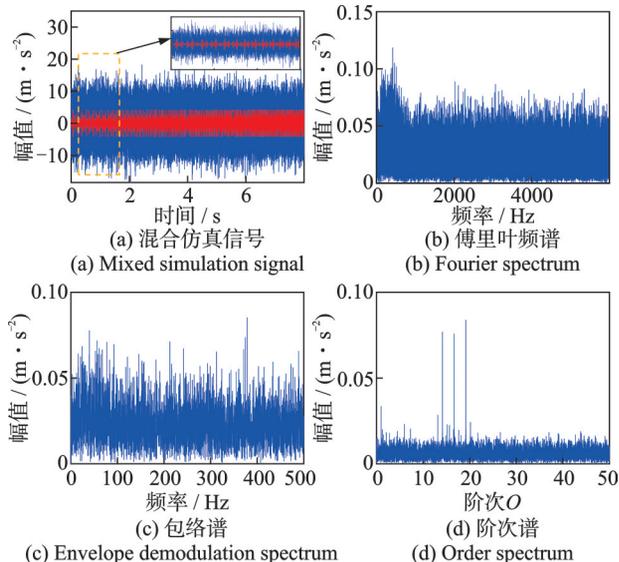


图 4 混合仿真信号初步分析

Fig. 4 Preliminary analysis of mixed simulation signal

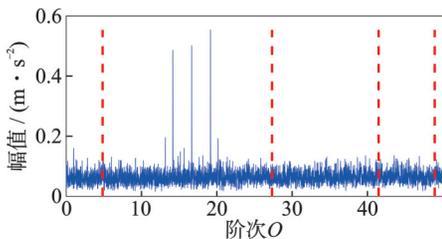


图 5 尺度空间谱划分结果

Fig. 5 Scale space spectral division results

在最佳参数组合 $[n^*, K^*, L^*] = [5, 7, 45]$ 下, 采用 IFMD 算法将角域信号进行最优模态分解, 获得的模态分量如图 6 所示, 图中 θ 表示弧度。根据敏感模态筛选准则, 选取 SGI 最大的 u_2 模态分量作为敏感模态进行分析。图 7 为敏感模态分量的包络阶次谱, 可以看到, 谱图中在太阳轮故障特征阶次 O_s 及其

2 倍频 $2O_s$, 以及与旋转阶次的组合 ($O_s - O_{sr}$, $O_s + O_{sr}$ 和 $2O_s - O_{sr}$) 处呈现出较为突显的谱峰。由此, 可以判断太阳轮出现了故障, 这与仿真设置一致。

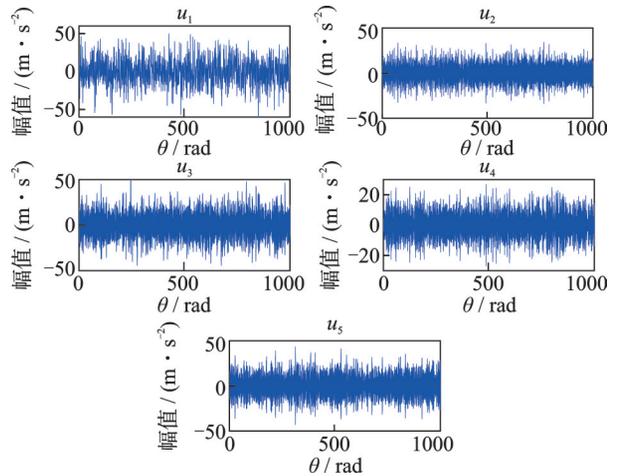


图 6 混合仿真信号的 IFMD 分解结果

Fig. 6 IFMD decomposition results of mixed simulation signal

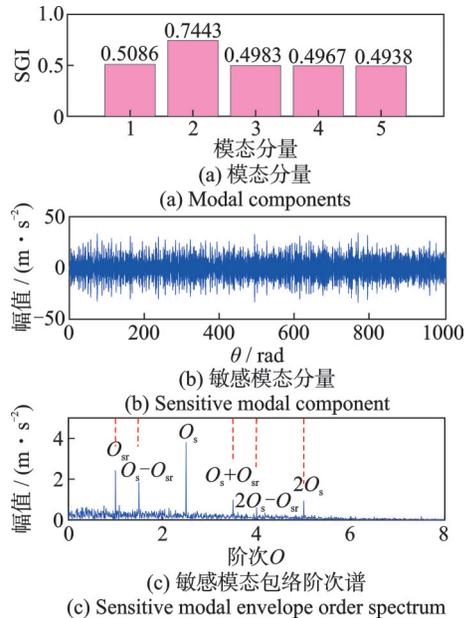


图 7 本文所提方法对仿真信号处理结果

Fig. 7 Processing results of the proposed method on simulation signal

作为对比, 分别采用 PSO-VMD 方法、MED 方法、SGMD 方法和快速谱峭度 (FSK) 方法对故障仿真的角域信号进行处理。在 VMD 算法中分解模态个数和惩罚因子作为 PSO 优化的对象, 目标函数为分解模态的 SGI 值。寻优得到最佳参数组合为 6 和 2300。图 8 为 PSO-VMD 的分析结果, 可以看到, 敏感模态的包络阶次谱中, 在太阳轮故障阶次处出现了微弱的峰值, 且整个谱图受噪声干扰较为严重, 无法直接清晰辨识故障。MED 算法中终止迭代次数和滤波器长度分别设置为 30 和 100。图 9 为 MED 方法的分析结果。由图 9 可知, 在解卷积信号的包络阶次谱中尽管能够提取到太阳轮故障阶次, 但存在严重的噪声干扰谱线, 影响诊断的准确性。图 10

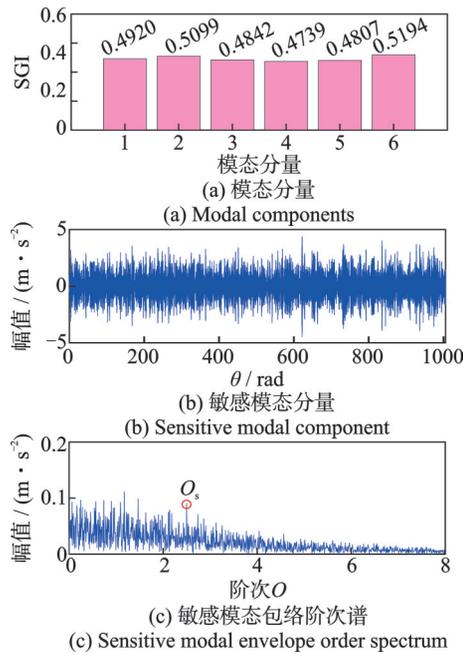


图8 PSO-VMD方法对仿真信号的分析结果

Fig. 8 Analysis results of simulation signal by PSO-VMD

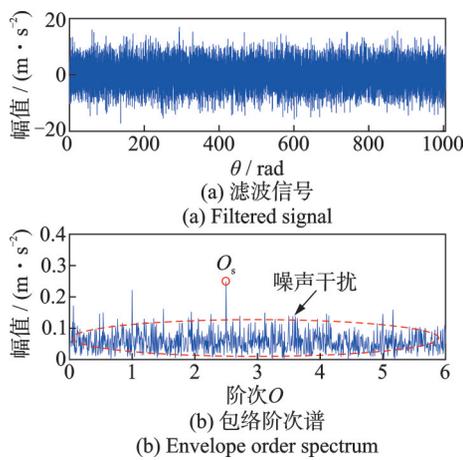


图9 MED方法对仿真信号的分析结果

Fig. 9 Analysis results of simulation signal by MED

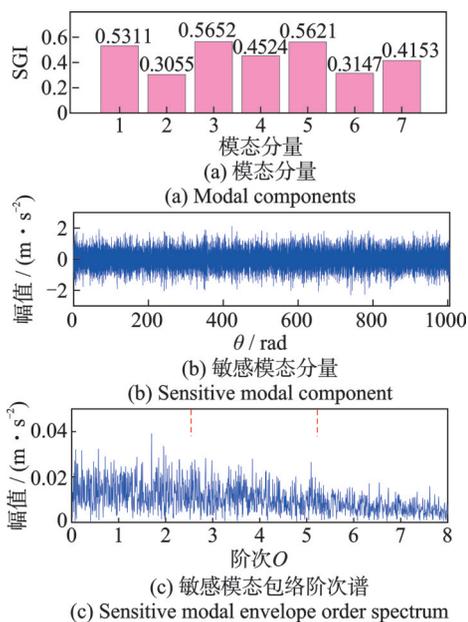


图10 SGMD方法对仿真信号的分析结果

Fig. 10 Analysis results of simulation signal by SGMD

为SGMD方法的分析结果。可以观察到,SGMD未能提取到任何与太阳轮故障相关的特征阶次。图11为FSK方法的分析结果。滤波信号的包络阶次谱中同样未能提取出太阳轮故障阶次信息,该方法失效。对比图7中IFMD算法分析结果,上述4种方法都无法清晰、有效地提取出太阳轮故障特征阶次,处理效果并不理想。

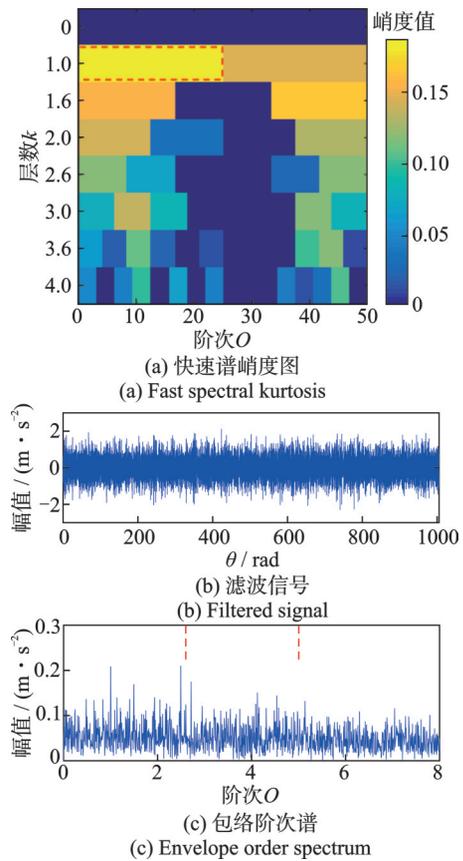


图11 快速谱峭度方法对仿真信号的分析结果

Fig. 11 Analysis results of simulation signal by FSK

3 实验验证

3.1 实验说明

为验证所提方法在时变工况下行星齿轮箱故障诊断中的有效性,在动力传动故障诊断综合实验台上设计转速上升模式下的实验。如图12所示,该实验台主要由变速驱动电机、行星齿轮箱、2级平行轴齿轮箱和可编程磁力制动器等组成。行星齿轮箱结构参数如表2所示。采用线切割在太阳轮和行星轮的某个轮齿齿根部位加工宽为0.15 mm,深为1 mm的微小贯通裂纹作为故障,故障件如图13所示。实验时,将PCB352C33型振动加速度传感器布置在行星齿轮箱壳体的正上方,同时使用激光脉冲转速计来实时测量电机转速。数据采样频率设置为

12000 Hz。在变转速工况下,行星齿轮箱中各元件故障特征阶次如表 3 所示。

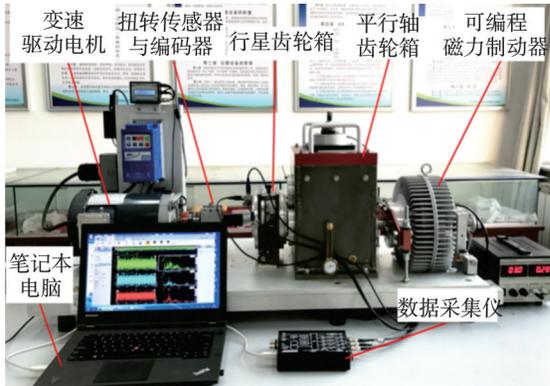


图 12 行星齿轮箱实验台

Fig. 12 Planetary gearbox experiment bench

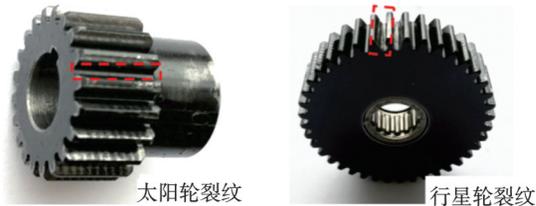


图 13 齿轮故障件

Fig. 13 Tested gear faulty parts

表 2 行星齿轮箱结构参数

Tab. 2 Planetary gearbox configuration parameters

齿轮	齿数
太阳轮	20
行星轮(数量)	40(3)
齿圈	100

表 3 变工况下行星齿轮箱中的特征阶次

Tab. 3 Characteristic frequencies of planetary gearbox under variable operating conditions

参数/Hz	数值
啮合阶次 O_m	16.67
太阳轮旋转阶次 O_{sr}	1.00
行星架转频阶次 O_c	0.17
太阳轮故障阶次 O_s	2.50
行星轮故障阶次 O_p	0.42

3.2 实测信号分析

3.2.1 太阳轮故障分析

太阳轮故障实验时,电机转速在 8 s 内从 6.7 Hz 上升到 34 Hz。图 14 为时变工况下太阳轮故障信号的时域波形及其傅里叶频谱、包络谱和阶次谱。由图 14 可知,随着转速的升高,故障信号的幅值也逐渐增大,并出现一些明显的冲击,但冲击的间隔存在时变性;同时,在对应的频谱和包络谱中均出现了频率模糊现象,无法提取到表征太阳轮故障的有用信

息;此外,阶次谱中在 2 倍啮合阶次 $2O_m$ 处存在峰值,但其两侧无明显的与太阳轮故障相关的边频信息。因此,采用传统分析方法都无法有效诊断时变工况下太阳轮早期微弱故障。

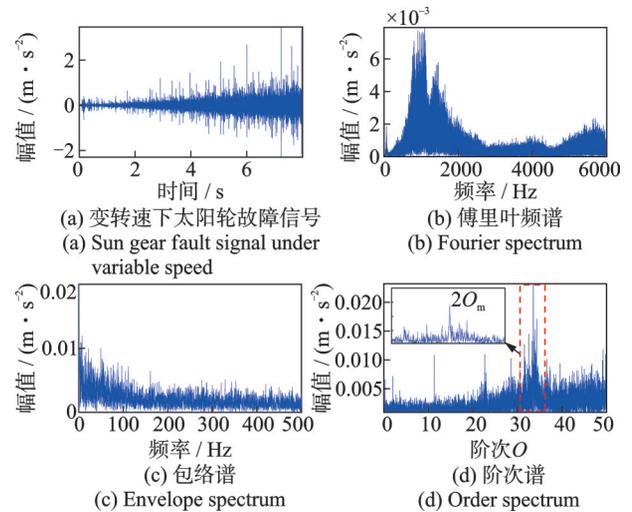


图 14 变工况下太阳轮故障信号

Fig. 14 Sun gear fault signal under variable operating conditions

为了有效揭示表征太阳轮故障的微弱特征信息,采用本文方法对时变工况下的太阳轮故障信号进行分析。首先,通过计算阶次跟踪将太阳轮故障信号转化为角域,并对角域信号频谱进行尺度空间表示,获得尺度空间谱如图 15 所示。由图 15 可知,尺度空间谱根据太阳轮角域信号特征自适应地识别有意义模态的划分边界(如图 15 中红色点划线),共确定 4 个模态分量。因此,设定 IFMD 算法中最佳分解模态个数 $n^* = 4$ 。随后,根据 1.2 节关键参数选取机制,设置滤波器个数 K 和长度 L 的寻优区间分别为 $[4, 14]$ 和 $[30, 100]$;采用 PSO 确定的最佳参数为 $K^* = 8$ 和 $L^* = 30$ 。

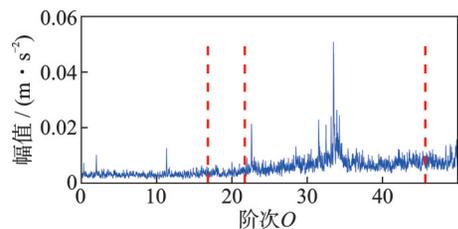


图 15 尺度空间谱划分结果

Fig. 15 Scale space spectral division results

在最佳参数组合 $[n^*, K^*, L^*] = [4, 8, 30]$ 下,采用 IFMD 将太阳轮故障角域信号进行最优模态分解,得到的 4 个模态分量如图 16 所示。根据敏感模态筛选准则,选取 SGI 最大的 u_3 模态分量作为敏感模态。图 17 为敏感模态分量的包络阶次谱,可以清晰地看到,谱图中在太阳轮故障特征阶次的 $\frac{1}{3}$ 倍频 $\frac{1}{3}O_s = 0.8254$ 及其 2~6 倍频 $(\frac{2}{3}O_s, O_s, \frac{4}{3}O_s, \frac{5}{3}O_s$

和 $2O_s$ 处呈现出明显的谱峰(实际行星齿轮箱中,3个行星轮不可能完全相同,这种差异使3个行星轮与太阳轮啮合时产生的故障冲击被视为不同的3个冲击,因此会出现 $\frac{n}{3}O_s$ ($n=1, 2, \dots, 6$) 倍的太阳轮故障阶次成分)。由此,可判断太阳轮出现了故障,这与实验设置相符。

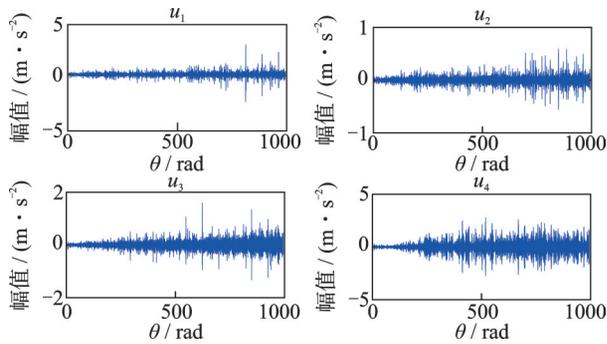


图 16 太阳轮故障信号的 IFMD 分解结果

Fig. 16 IFMD decomposition results of sun gear fault signal

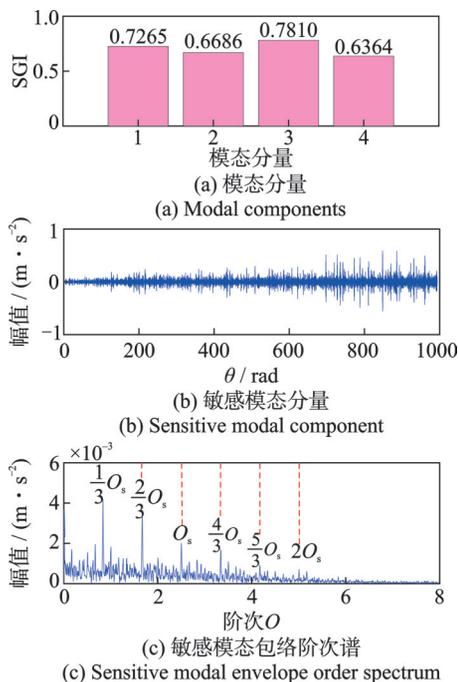


图 17 本文所提方法对太阳轮故障处理结果

Fig. 17 Processing results of the proposed method on sun gear fault signal

作为对比,分别采用 PSO-VMD 方法、MED 方法、SGMD 和 FSK 方法对太阳轮故障角域信号进行处理。在 VMD 算法中分解模态个数和惩罚因子作为 PSO 优化对象,目标函数为分解模态的 SGI 值。寻优得到的最佳参数组合为 7 和 1800。图 18 为 PSO-VMD 的分析结果,可以看到,敏感模态的包络阶次谱中仅在太阳轮故障阶次的 $\frac{2}{3}O_s$ 处呈现出微小峰值,但这不足以作为有力证据来判断太阳轮出现故障。MED 算法中滤波器长度和终止迭代次数分别设置为 30 和 100。图 19 为 MED 方法的分析结

果。可以观察到,在解卷积信号的包络阶次谱中出现了太阳轮故障特征阶次的 $\frac{2}{3}O_s$ 和 $\frac{4}{3}O_s$ 倍频成分,但在其周围存在许多未知谱线和噪声干扰,这对准确判别故障十分不利。图 20 为 SGMD 方法的分析结果。谱图中虽然在太阳轮故障阶次的 $\frac{1}{3}O_s, \frac{2}{3}O_s$ 和 $\frac{4}{3}O_s$ 倍频处出现谱峰,但整个谱图存在许多幅值较大的干扰谱线,容易导致误判。图 21 为 FSK 方法的分析结果。由图 21 可知,滤波信号的包络谱阶次谱中仅提取到了太阳轮故障阶次的 $\frac{1}{3}O_s$ 和 $\frac{2}{3}O_s$ 倍频成分。对比图 17 中 IFMD 方法结果,上述 4 种方法都难以清晰、全面地提取太阳轮故障特征阶次信息,处理效果并不理想。

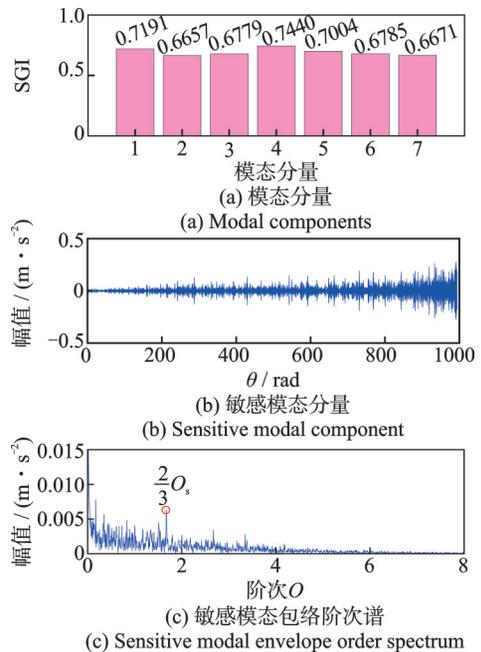


图 18 PSO-VMD 方法对太阳轮故障的分析结果

Fig. 18 Analysis results of sun gear fault by PSO-VMD

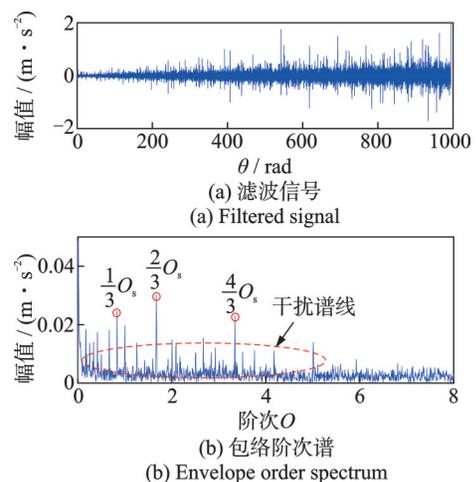


图 19 MED 方法对太阳轮故障的分析结果

Fig. 19 Analysis results of sun gear fault by MED

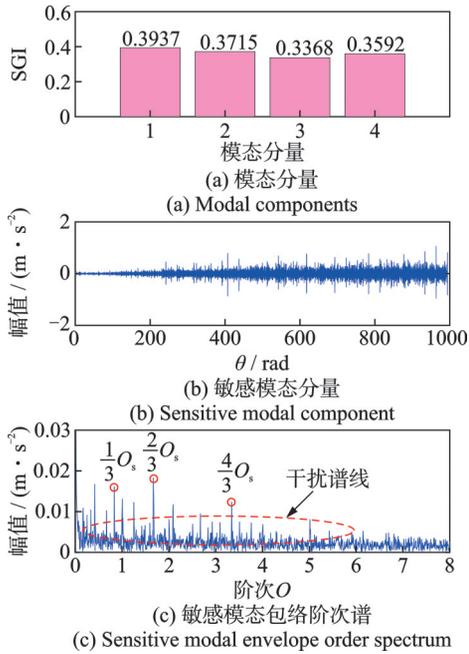


图 20 SGMD 方法对太阳轮故障的分析结果
Fig. 20 Analysis results of sun gear fault by SGMD

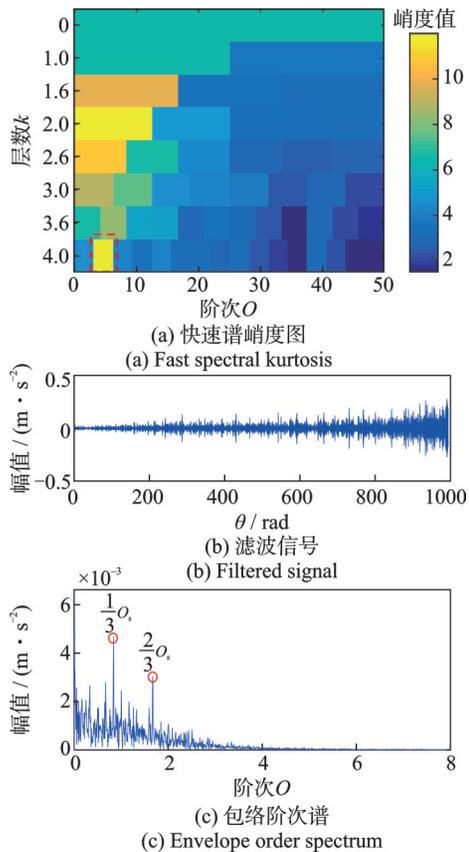


图 21 快速谱峭度方法对太阳轮故障的分析结果
Fig. 21 Analysis results of sun gear fault signal by FSK

3.2.2 行星轮故障分析

行星轮故障实验时,电机转速在 8 s 内从 9.6 Hz 上升到 30 Hz。图 22 为时变工况下行星轮故障信号及其傅里叶频谱、包络谱和阶次谱。可以看到,故障信号中出现一些明显的冲击,但冲击的间隔逐渐减小;同时,在对应的频谱和包络谱中都出现了频率模

糊现象,无法辨识故障;此外,阶次谱中在啮合阶次的 2 倍频 $2O_m$ 处存在峰值,由于受噪声影响在其两侧未发现明显边频信息。因此,采用传统方法无法对时变工况下的行星轮早期微弱故障做出有效诊断。

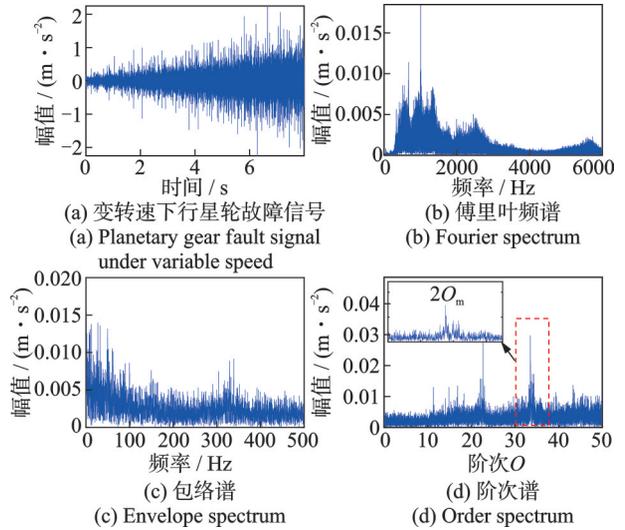


图 22 变工况下行星轮故障信号
Fig. 22 Planetary gear fault signal under variable operating conditions

对时变工况下的行星轮故障信号采用本文方法进行特征提取。首先,将行星轮故障信号转化为角域,并对角域信号频谱进行尺度空间表示,如图 23 所示。可以看到,根据行星轮角域信号特征,尺度空间谱自适应识别有意义模态的划分边界并确定 5 个模态分量。因此,IFMD 中最佳分解模态个数取 $n^* = 5$ 。随后,设置滤波器个数 K 和滤波器长度 L 的寻优区间分别为 $[5, 15]$ 和 $[30, 100]$,采用 PSO 确定的最佳参数为 $K^* = 13$ 和 $L^* = 93$ 。

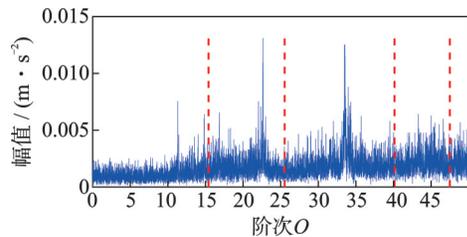


图 23 尺度空间谱划分结果
Fig. 23 Scale space spectral division results

在最佳参数组合 $[n^*, K^*, L^*] = [5, 13, 93]$ 下,利用 IFMD 算法将行星轮故障角域信号进行最优模态分解,如图 24 所示。根据敏感模态筛选准则,选取 SGI 最大的 u_1 模态分量作为敏感模态。图 25 为敏感模态分量的包络阶次谱,谱图中在行星轮故障特征阶次 $O_p = 0.4156$ 及其 2~12 倍频处清晰地出现明显的谱峰。由此,可以判断行星轮出现了故障,这与实验设置一致。

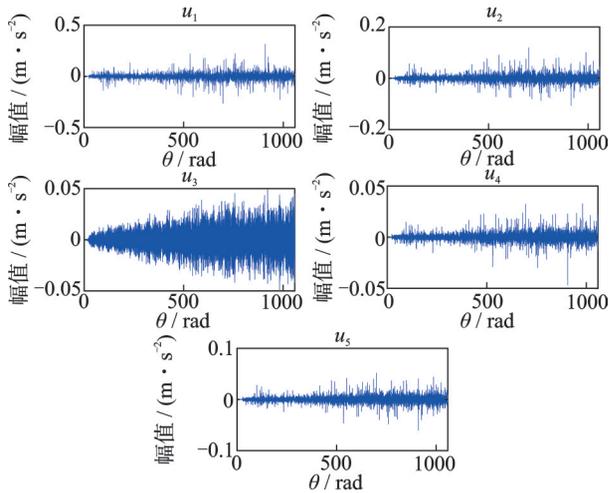


图24 行星轮故障信号的IFMD分解结果

Fig. 24 IFMD decomposition results of planetary gear fault signal

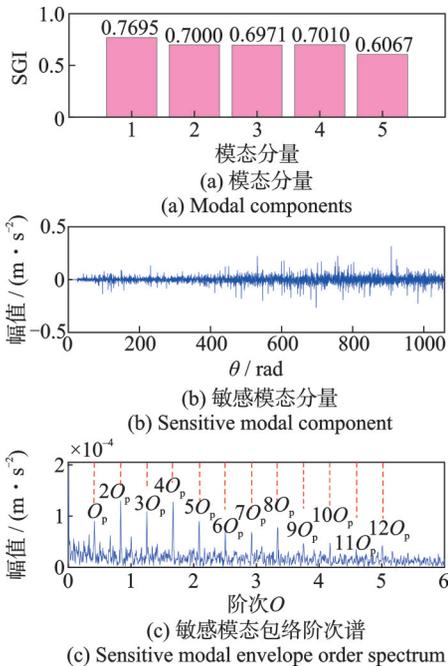


图25 本文所提方法对行星轮故障处理结果

Fig. 25 Processing results of the proposed method on planetary gear fault

作为对比,分别采用 PSO-VMD 方法、MED 方法、SGMD 和 FSK 方法对行星轮故障角域信号进行处理。寻优得到的 VMD 算法中最佳参数组合为 6 和 2500, PSO-VMD 方法的分析结果如图 26 所示。由图 26 可知,敏感模态分量的包络阶次谱中仅提取出行星轮故障阶次的 2~5 倍频成分。MED 算法中滤波器长度和终止迭代次数分别设为 30 和 100, 图 27 为 MED 方法的分析结果。可以观察到,在解卷积信号的包络阶次谱中出现了行星轮故障阶次的 1~5 倍和 8 倍频成分,但谱图中噪声干扰较为突显,不利于准确判别故障。图 28 为 SGMD 方法的分析结果。谱图中虽然在行星轮故障阶次的 2 倍、3 倍和 5 倍频处有谱峰出现,但整个谱图依然存在许多干扰谱线,容易产生误判。图 29 为 FSK 方法的分析结

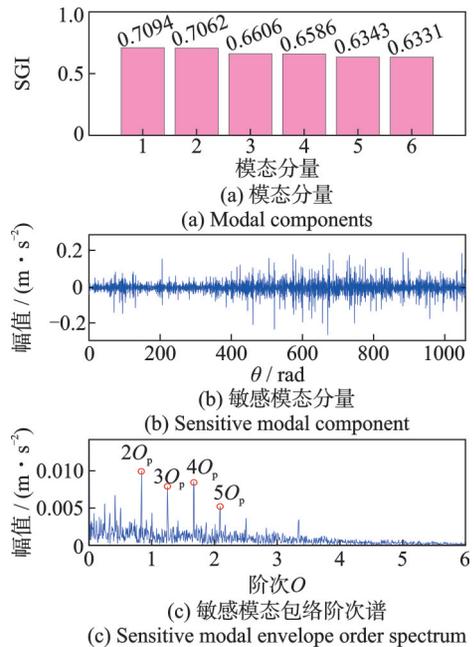


图26 PSO-VMD方法对行星轮故障的分析结果

Fig. 26 Analysis results of planetary gear fault by PSO-VMD

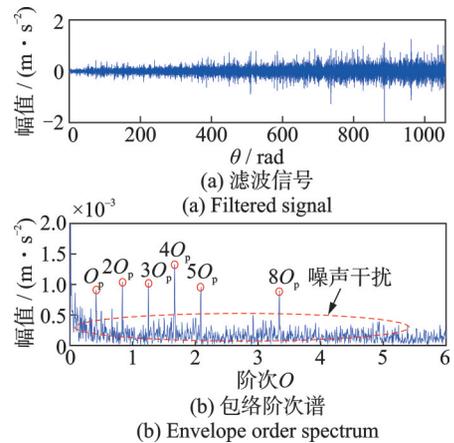


图27 MED方法对行星轮故障的分析结果

Fig. 27 Analysis results of planetary gear fault by MED

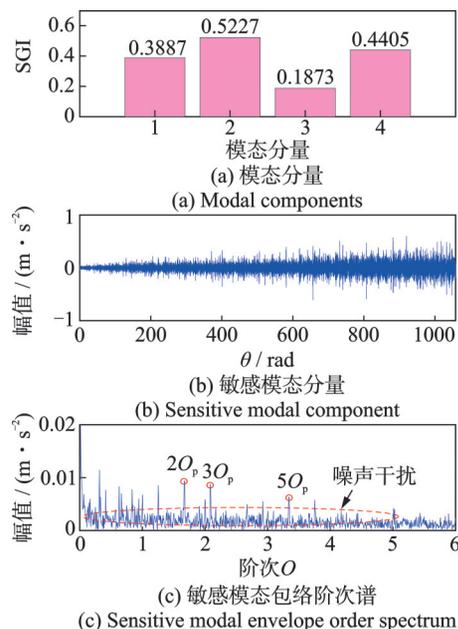


图28 SGMD方法对行星轮故障的分析结果

Fig. 28 Analysis results of planetary gear fault by SGMD

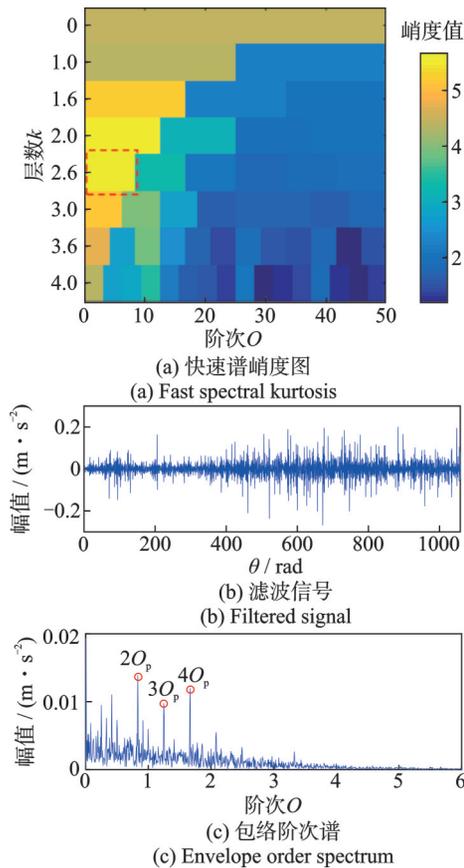


图 29 快速谱峭度方法对行星轮故障的分析结果

Fig. 29 Analysis results of planetary gear fault by FSK

果。由图 29 可知,滤波信号的包络谱阶次谱中仅提取到行星齿轮故障阶次的 2~4 倍频成分。与图 25 中 IFMD 算法对比可知,上述 4 种方法都难以清晰、全面地提取行星齿轮故障阶次信息,处理效果并不理想。

4 结 论

本文提出了一种基于 IFMD 的变工况微弱故障诊断方法,并将其应用于时变工况下行星齿轮箱故障特征提取中。仿真和工程实验数据分析验证了所提方法的有效性和优越性。获得的主要结论如下:

(1) IFMD 算法能自适应获得模态分解所需的最佳参数,且具有理论依据,弥补了 FMD 主要影响参数设置需要依靠人工经验反复尝试的不足,实现了最优模态分解。

(2) 本文方法可有效抑制变工况下故障信号中噪声和其他无关干扰的影响,从而突显模态分量中微弱故障特征阶次信息,有利于行星齿轮箱早期故障的准确溯源。

(3) 通过与 PSO-VMD 方法、MED 方法、SGMD 方法和快速谱峭度方法对比,所提方法能够提取到更加清晰、明显的故障特征阶次成分且诊断效果更佳,为实际工程应用提供了一种方案,对解决其他旋转机械诊断的共性问题提供了参考。

参考文献:

- [1] 王辉,徐佳文,严如强.基于深度宽卷积 Q 网络的行星齿轮箱故障智能诊断方法[J].仪器仪表学报,2022,43(3):109-120.
WANG H, XU J W, YAN R Q. Intelligent fault diagnosis for the planetary gearbox based on the deep wide convolutional Q network[J]. Chinese Journal of Scientific Instrument, 2022,43(3):109-120.
- [2] WANG C G, LI H K, ZHANG K L, et al. Intelligent fault diagnosis of planetary gearbox based on adaptive normalized CNN under complex variable working conditions and data imbalance[J]. Measurement, 2021, 180: 109565.
- [3] WEI S, WANG D, PENG Z K, et al. Variational non-linear component decomposition for fault diagnosis of planetary gearboxes under variable speed conditions[J]. Mechanical Systems and Signal Processing, 2022, 162: 108016.
- [4] LI Y Z, DING K, HE G L, et al. Non-stationary vibration feature extraction method based on sparse decomposition and order tracking for gearbox fault diagnosis[J]. Measurement, 2018, 124:453-469.
- [5] ENDO H, RANDALL R B. Enhancement of autoregressive model based gear tooth fault detection technique by the use of minimum entropy deconvolution filter[J]. Mechanical Systems and Signal Processing, 2007, 21(2): 906-919.
- [6] 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.
- [7] MA H Q, FENG Z P. Planet bearing fault diagnosis using multipoint optimal minimum entropy deconvolution adjusted[J]. Journal of Sound and Vibration, 2019, 449: 235-273.
- [8] WANG J, DU G F, ZHU Z K, et al. Fault diagnosis of rotating machines based on the EMD manifold[J]. Mechanical Systems and Signal Processing, 2020, 135: 106443.
- [9] 孟宗,王亚超,胡猛.基于改进 LMD 和 IED-SampEn 的齿轮故障特征提取方法[J].机械工程学报,2016,52(5): 169-176.
MENG Z, WANG Y C, HU M. Fault feature extraction method of gear based on improved local mean decomposition and instantaneous energy distribution-sample entropy[J]. Journal of Mechanical Engineering, 2016, 52(5): 169-176.
- [10] SUN Y J, LI S H, WANG X H. Bearing fault diagnosis based on EMD and improved Chebyshev distance in SDP image[J]. Measurement, 2021, 176: 109100.
- [11] WANG L, LIU Z W, MIAO Q, et al. Time-frequency analysis based on ensemble local mean decomposition and fast kurtogram for rotating machinery fault diagnosis

- [J]. Mechanical Systems and Signal Processing, 2018, 103: 60-75.
- [12] LI J M, WANG H, WANG X D, et al. Rolling bearing fault diagnosis based on improved adaptive parameterless empirical wavelet transform and sparse denoising [J]. Measurement, 2020, 152: 107392.
- [13] PAN H Y, YANG Y, ZHENG J D, et al. A fault diagnosis approach for roller bearing based on symplectic geometry matrix machine[J]. Mechanism and Machine Theory, 2019, 140: 31-43.
- [14] 王朝阁, 李宏坤, 曹顺心, 等. 改进 VMD 和非凸重叠组收缩降噪的行星齿轮箱早期故障特征提取[J]. 振动工程学报, 2021, 34(6): 1293-1304.
WANG C G, LI H K, CHAO S X, et al. Incipient fault feature extraction of planetary gearbox based on modified VMD and non-convex overlap group shrinkage denoising[J]. Journal of Vibration Engineering, 2021, 34(6): 1293-1304.
- [15] MIAO Y H, ZHANG B Y, LI C H, et al. Feature mode decomposition: new decomposition theory for rotating machinery fault diagnosis[J]. IEEE Transactions on Industrial Electronics, 2023, 70(2): 1949-1960.
- [16] 鄢小安, 贾民平. 基于参数自适应特征模态分解的滚动轴承故障诊断方法[J]. 仪器仪表学报, 2022, 43(10): 252-259.
YAN X A, JIA M P. A rolling bearing fault diagnosis method based on parameter-adaptive feature mode decomposition[J]. Chinese Journal of Scientific Instrument, 2022, 43(10): 252-259.
- [17] LEE J Y, NANDI A K. Extraction of impacting signals using blind deconvolution[J]. Journal of Sound and Vibration, 2000, 232(5): 945-962.
- [18] 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.
- [19] PAN J, CHEN J L, ZI Y Y, et al. Mono-component feature extraction for mechanical fault diagnosis using modified empirical wavelet transform via data-driven adaptive Fourier spectrum segment[J]. Mechanical Systems and Signal Processing, 2016, 72-73: 160-183.
- [20] WANG D. Some further thoughts about spectral kurtosis, spectral L2/L1 norm, spectral smoothness index and spectral Gini index for characterizing repetitive transients [J]. Mechanical Systems and Signal Processing, 2018, 108: 360-368.
- [21] TRELEA I C. The particle swarm optimization algorithm: convergence analysis and parameter selection[J]. Information Processing Letters, 2003, 85(6): 317-325.
- [22] ZHU Y, LI G P, TANG S N, et al. Acoustic signal-based fault detection of hydraulic piston pump using a particle swarm optimization enhancement CNN[J]. Applied Acoustics, 2022, 192: 108718.
- [23] FENG Z P, QIN S F, LIANG M. Time-frequency analysis based on Vold-Kalman filter and higher order energy separation for fault diagnosis of wind turbine planetary gearbox under nonstationary conditions[J]. Renewable Energy, 2016, 85: 45-56.

Weak fault diagnosis of planetary gearbox based on IFMD under time-varying speed

WANG Chao-ge¹, ZHANG Qi-qi¹, ZHOU Fu-na¹, WANG Ran¹, HU Xiong¹, LI Hong-kun²

(1. Logistics Engineering College, Shanghai Maritime University, Shanghai 201306, China;

2. School of Mechanical Engineering, Dalian University of Technology, Dalian 116024, China)

Abstract: The incipient fault characteristics of planetary gearbox are weak and difficult to effectively identify under strong background noise interference and variable working conditions. To address these issues, an improved feature mode decomposition (IFMD) algorithm is proposed to extract the weak fault characteristics of planetary gearbox under time-varying speed conditions. Firstly, for the key input parameters of the FMD algorithm, such as the number of decomposition mode n , the number of filter K , and the length of filter L , which need to be set manually and lack adaptability, an adaptive scale space spectrum segmentation method is proposed to determine the required number of decomposition modes n . On this basis, the Spectral Gini Index (SGI) is used as the objective function, and particle swarm optimization algorithm is used to automatically determine the optimal filter number K and filter length L . Subsequently, the IFMD is applied to perform optimal modal decomposition on the fault signal under the optimal parameter combination, and the decomposed component with the highest SGI value is selected as the sensitive modal component. Finally, significant fault feature orders are extracted from the envelope order spectrum of sensitive component to accurately diagnose the fault type and location of planetary gearbox. The analysis results of variable speed simulation signals and engineering experimental data indicate that compared to the PSO-VMD method, MED method, SGMD method, and fast spectral kurtosis method, the proposed method can extract weak fault information more clearly and comprehensively, thereby improving the characterization ability and diagnostic accuracy of early fault features of planetary gearbox under time-varying speed conditions.

Key words: fault diagnosis; planetary gearbox; time-varying speed operating conditions; feature modal decomposition; weak fault

作者简介: 王朝阁(1992—),男,博士,讲师。E-mail:cgwang@shmtu.edu.cn。

通讯作者: 李宏坤(1984—),男,博士,教授。E-mail:lihk@dlut.edu.cn。