

平均降采样多周期微分均值的旋转部件 故障特征增强方法

陈鑫, 郭瑜

(昆明理工大学机电工程学院, 云南昆明 650500)

摘要: 为解决编码器的瞬时角速度 (Instantaneous Angular Speed, IAS) 信号中旋转部件故障特征微弱的难题, 本文提出一种平均降采样多周期微分均值 (Average Down-Sampling Multi-period Differential Means, ADSMPDM) 的故障特征增强方法。基于 IAS 信号的估计特性, 开展了 IAS 信号的平均降采样研究, 验证了平均降采样具有抑制随机噪声的特性; 基于平均降采样抑制随机噪声特性、降低计算成本和减小存储空间的优势, 结合多周期微分均值的累积特性, 提出一种 ADSMPDM 算法对原始 IAS 信号中的旋转部件故障分量进行增强处理; 通过阶次谱分析揭示故障特征。采用仿真数据和实验数据进行验证分析, 并与快速谱峭度、可调整多点优化最小熵反卷积、离散随机分离和谱幅值调制算法进行对比, 验证了 ADSMPDM 算法增强旋转部件故障特征的有效性和优势。

关键词: 故障诊断; 平均降采样多周期微分均值; 编码器信号; 瞬时角速度; 特征提取

中图分类号: TH165⁺.3; TH133.3 **文献标志码:** A **文章编号:** 1004-4523(2024)02-0346-10

DOI: 10.16385/j.cnki.issn.1004-4523.2024.02.017

引言

齿轮和轴承是旋转机械的关键部件, 在运行中分别起到传递扭矩和支撑的作用, 其健康程度直接影响旋转机械的运行精度、效率和寿命^[1]。因此, 齿轮和轴承的故障特征提取成为故障诊断领域的研究热点之一。

近年来, 基于振动信号的故障特征提取技术得到快速发展, 比如 Antoni^[2]提出了快速谱峭度 (Fast Kurtogram, FK) 算法, 自适应确定包含丰富齿轮或轴承故障信息的解调频带, 进而有效揭示故障特征; 进一步地, Antoni^[3]提出一种信息熵指标以解决 FK 指标易遭受随机冲击干扰的问题。McDonald 等^[4]提出最大相关峭度反卷积用于增强齿轮故障冲击分量; 为自适应确定最大相关峭度反卷积算法的优化参数。McDonald 等^[5]提出可调整多点优化最小熵反卷积 (Multipoint Optimal Minimum Entropy Deconvolution Adjusted, MOMEDA) 算法。此外, Antoni 等^[6]提出一种自参考自消噪技术以提取旋转部件故障分量, 进而抑制背景噪声的干扰; Antoni 等^[7]提出一种离散随机分离 (Discrete Random Separation, DRS) 算法, 解决了自参考自消噪技术的收敛缺陷和计算冗余等问题。Borghesani 等^[8]提出倒谱

预白化技术以抑制具有一阶循环平稳特性的分量, 进而增强具有二阶循环平稳特性分量的能量幅值; 进一步地, Moshrefzadeh 等^[9]提出一种谱幅值调制 (Spectral Amplitude Modulation, SAM) 算法以扩展倒谱预白化技术在故障特征提取中的应用, 其有效性在齿轮和轴承故障特征提取中得到验证。值得指出的是, 上述方法在振动信号中可有效增强故障冲击特征。然而, 编码器信号中存在编码安装误差^[10]、测量误差等干扰分量, 上述方法在低信噪比工况下可能会失效。

振动信号受振动传感器频率下限的限制, 在低速工况下往往可能无法有效获取故障信息; 再者, 由于安装环境的限制, 在某些场合不易外置安装振动传感器, 比如工业机器人、数控机床等。为此, 一些学者开展了具有传递路径短、无需外置安装、无需定期校准、直接与动力学相关等优势编码器瞬时角速度 (Instantaneous Angular Speed, IAS) 信号的故障特征提取研究。例如, Braut 等^[11]开展了基于 IAS 信号的变分模态分解研究, 实现了不同转速工况下转子与定子摩擦状态的监测; Li 等^[12]提出一种基于 IAS 信号的经验模态分解和局部倒谱相关相结合的齿轮故障特征增强方法; Miao 等^[13]提出一种改进自适应最大相关峭度反卷积的故障特征增强方法。综上所述, 编码器信号中包含丰富的轴承故障信息, 其

收稿日期: 2022-04-15; 修订日期: 2022-07-27

基金项目: 国家自然科学基金资助项目 (52165067); 云南科技计划重大专项项目 (202002AC080001)。

可用于旋转机械故障特征提取。然而,早期齿轮局部故障引起的IAS变化较弱,并且轴承作为旋转机械的支撑部件(不传递扭矩),其故障引起的扭矩变化微弱。此外,由于编码安装误差、估计误差和测量误差的干扰,齿轮、轴承故障特征提取的难度加大。

为有效增强旋转部件的故障特征,本文基于IAS信号的估计特性,开展了IAS信号的平均降采样研究,讨论了IAS信号的平均降采样相较于传统降采样的优势;基于旋转部件的理论特征阶次,结合平均降采样的优势和多周期微分均值的累计特性,提出一种基于IAS信号的平均降采样多周期微分均值(Average Down-Sampling Multi-Period Differential Means, ADSMPDM)算法以增强旋转部件故障特征。研究中以仿真数据和实测数据进行验证分析,将所提算法与FK, MOMEDA, DRS和SAM算法的分析结果进行对比,验证了所提方法的有效性和优势。

1 瞬时角速度估计及故障特征

1.1 瞬时角速度估计

光学编码器主要由光栅盘和光电检测装置组成,如图1(a)所示;旋转过程中光栅盘对光束的通透和遮蔽作用产生方波电压,如图1(b)所示。在应用中,光学编码器将输出一系列的离散瞬时角位移(Instantaneous Angular Displacement, IAD)序列 $[\varphi_1, \varphi_2, \dots, \varphi_i]$,对应的时间序列为 $[t_1, t_2, \dots, t_i]$ 。IAS估计的表达式为^[14]:

$$IAS_i = \frac{\Delta\varphi}{\Delta t_i} \quad (1)$$

式中 IAS_i (rad/s) 表示第 i 阶瞬时角速度; $\Delta t_i = t_{i+1} - t_i$; $\Delta\varphi = 2\pi/N = \varphi_i - \varphi_{i-1}$, 其中 N 表示编码器第圈光栅数。




图1 光学编码器测量原理

Fig. 1 Measurement principle of optical encoder

1.2 故障引起的IAS信号特征

当齿轮和轴承发生局部点蚀或局部剥落等故障时,齿轮间或滚动体与滚道在故障位置处的接触刚度较无故障状态发生瞬时变化,对应的IAS信号产生规律性波动^[15],如图2所示。因此,故障引起IAS

变化的仿真信号可表示为:

$$W(\theta) = \omega(\theta) + \sum_j A e^{-\xi\psi} \sin(f_n \sqrt{1-\xi^2} \psi) \quad (2)$$

式中 $\omega(\theta)$ 表示平均角速度; A 为故障幅值; f_n 为固有频率; ξ 为阻尼系数; $\psi = \theta - j\Theta - \tau_j$, 其中, θ 表示角度, 谐波阶次 $j=1, 2, \dots, J$, Θ 表示相邻故障冲击间的平均角度, τ_j 为滚动轴承随机滑动角度。注意: 轴承作为旋转机械的支撑部件(不传递扭矩), 在径向载荷的作用下, 滚动体通过故障位置时的刚度变化会引起IAS信号变化^[16]。




图2 故障引起的IAS信号波动

Fig. 2 IAS signal fluctuation caused by fault

2 平均降采样及其特性

2.1 平均降采样

尽管高采样率(编码器每圈光栅数 N) 可获得更加丰富的故障信息,但其冗余信息对故障特征提取不会有显著的提升,而且会增加算法的计算成本以及数据的存储和传输成本。因此,必要的降采样操作既可以保证旋转部件的故障特征提取,又可以降低算法的计算成本和数据的存储成本。如1.1节讨论,IAS信号是角度 $\Delta\varphi$ 内的平均角速度。因此,IAS_g信号的平均降采样可表示为:

$$IAS_g^D = \frac{1}{D} \sum_g^{g+D} IAS_g \quad (3)$$

式中 D 为平均降采样倍数; $g=1, D+1, 2D+1, \dots$; IAS_g^D 表示在平均降采样倍数为 D 时估计的IAS信号。

比较式(1)和(3)可知, IAS_g^D 的数据长度是 IAS_i 的 $1/D$, 即平均降采样操作可降低算法的计算成本以及数据的存储和传输成本。

2.2 平均降采样的特性

与传统降采样不同,平均降采样是角度 $D\Delta\varphi$ 内的平均角速度,如图3所示。可见,由于故障引起的IAS信号具有累计特性,从而平均降采样会保留故障特征。然而,工程应用中通常无法估计故障引起的IAS波动的衰减角度 φ , 即当传统降采样角度 $D\Delta\varphi$ 大于由故障引起的IAS波动的衰减角度 φ , 则传统降采样将会丢失故障信息。通过式(2)可计算 φ , 其表达式为:

$$\varphi = \frac{\ln(\sigma/A)}{-\xi f_n} \quad (4)$$

式中 σ 为衰减后幅值; φ 为幅值 A 衰减到 σ 时的经过角度。




图3 平均降采样和传统降采样模型

Fig. 3 Average down-sampling and conventional down-sampling model

为进一步阐述平均降采样的特性,采用式(3)生成图4(a)所示的仿真信号,其中, $f_n=50 \times (\times$ 表示故障特征阶次), $\Theta=1941$, $A=1$, $\xi=0.01$, $\langle \tau_j \rangle=0$, $\max(|\tau_j|)=39$, 信噪比 $SNR=-10$ dB, $\langle \cdot \rangle$ 表示平均操作。图4(a)的降采样操作结果如图4(b)~(d)所示。值得指出的是,随机噪声通常满足高斯分布,平均降采样可抑制随机噪声的幅值,即随着平均降采样倍数 D 的增大,图4(b)~(d)中的随机噪声被逐渐削弱。




图4 不同 D 条件下估计的 IAS 波形

Fig. 4 IAS waveforms estimated under different D conditions

在信噪比低的工况下,较小的采样率(编码器每圈光栅数 N)可能无法有效获取故障信息,即工程应用中尽量以高采样率估计原始 IAS 信号。此外,平均降采样倍数 D 过大可能会丢失故障信息,即满足下式时:

$$IAS_g^D - IAS_a^D = 0 \quad (5)$$

式中 IAS_a^D 为 IAS_g^D 的均值。

3 平均降采样多周期微分均值技术

3.1 平均降采样多周期微分均值

针对故障引起的 IAS 信号微弱的难题,基于 2.2

节中的平均降采样特性,结合故障时会引起 IAS 信号的规律性变化,以及故障 IAS 分量较无故障状态具有突变趋势,研究中基于对突变敏感的微分算法和多周期的累计特性,提出 ADSMPDM 算法以增强旋转部件故障特征,平均降采样信号 IAS_g^D 的多周期微分均值可表示为:

$$DS_{MPDM}(m) = \frac{1}{2\eta N_s^m N_w} \sum_m \sum_k \sum_q \sum_h \mathfrak{R} \quad (6)$$

式中 N_s^m 表示相邻故障冲击间实际角度间隔与理论角度间隔的最大差值; N_w 表示微分窗长; K 为感兴趣故障冲击的周期数;在数据点为 m 和冲击周期数为 k 时的微分位置 $q=m+(k-1)N/f_{\text{fault}}$, 其中, $k=1, 2, \dots, K$, f_{fault} 为理论故障特征阶次, N/f_{fault} 表示故障旋转部件的理论角度间隔; $Q=m+(k-1)N/f_{\text{fault}}+N_w$; $m=2N_s^m+1, 2N_s^m+2, \dots, M$; $M=length(IAS_g^D)-KN/f_{\text{fault}}-N_w-2N_s^m$ 为处理后数据长度,其中 $length(IAS_g^D)$ 表示平均降采样信号 IAS_g^D 的长度;在冲击周期数为 k 时的随机滑动角度范围 $[h, H]=[q-\eta N_s^m, q+\eta N_s^m]$; η 为相邻故障冲击间的滑动比例;微分算子 $\mathfrak{R}=(IAS_h^D-IAS_{h-1}^D)/(D\Delta\varphi)$ 。

ADSMPDM 算法的示意图如图 5 所示。




图5 ADSMPDM 算法示意图

Fig. 5 Schematic diagram of ADSMPDM algorithm

相邻故障冲击间的实际角度间隔与理论角度间隔的差值 N_s 可根据故障类型确定,其表达式为:

$$N_s = \begin{cases} \eta_{\text{slip}}(j) + \eta_a(j) + \eta_d(j), & \text{轴承故障} \\ \eta_a(j) + \eta_d(j), & \text{齿轮故障} \end{cases} \quad (7a)$$

$$\eta_{\text{slip}}(j) = \frac{NR(f_{\text{Ac}}(j) - f_{\text{fault}})}{Df_{\text{Ac}}(j)f_{\text{fault}}} \quad (7b)$$

式中 $\eta_a(j)$ 表示平均降采样操作对故障波形分割导致的相邻冲击间实际角度间隔与理论角度间隔的差值, $\eta_a(j) \leq 2D$; $\eta_d(j)$ 表示理论角度间隔 $N/(Df_{\text{fault}})$ 不是整数引起的采样误差; $\eta_{\text{slip}}(j)$ 表示轴承随机滑动引起的理论角度间隔与实际角度间隔的差值; R 为编码器安装轴和故障旋转部件安装轴间的传动比; $f_{\text{Ac}}(j)$ 为故障旋转部件的实际特征阶次。

如图 6 所示,由于平均降采样对故障波形的分

割和编码器每圈光栅数 N 与理论故障特征的比值 $N/(Df_{\text{fault}})$ 不是整数,进而产生故障冲击间角度间隔误差 $\eta_a(j)$ 和 $\eta_d(j)$ 。图中 D_1 和 D_2 分别表示第一次和第二次冲击的实际角度间隔点数与理论角度间隔点数的差值。对于轴承故障而言,当满足 $|f_{\text{Ac}}(j) - f_{\text{fault}}| = 0.02f_{\text{fault}}$ 和 $f_{\text{Ac}}(j) = 0.98f_{\text{fault}}$ 时,通过式(7)可获得相邻故障冲击间实际角度间隔与理论角度间隔的最大差值 N_s^m ,其计算式为:

$$N_s^m \approx \begin{cases} \frac{NR}{49Df_{\text{fault}}} + 2D + 2, & \text{轴承故障} \\ 2D + 2, & \text{齿轮故障} \end{cases} \quad (8)$$

值得指出的是,ADSMPDM算法的有效性和鲁棒性主要由感兴趣故障冲击的周期数 K 决定, K 值越大,理论上对感兴趣故障分量的累计增强效应越强。此外,因为ADSMPDM算法需要获得 f_{fault} ,即ADSMPDM算法是一种半自动技术。




图6 平均降采样和离散降采样的差异模型

Fig. 6 The difference model of average down-sampling and discrete down sampling

3.2 虚假分量引入和频率模糊现象

尽管 K 值越大越有利于旋转部件故障特征的增强,但较大 K 值和 N_w 可能导致干扰分量的多周期微分范围 $[h, H]$ 与故障引起的 IAS 波动范围部分重合,进而引入虚假分量,其计算式为:

$$\{h, H\} \cap \left\{ N_0 + \frac{jNR}{Df_{\text{fault}}} + N_s, N_0 + \frac{jNR}{Df_{\text{fault}}} + N_s + \varphi \right\} \neq \emptyset \quad (9)$$

式中 N_0 表示 IAS_g^D 中第一个故障冲击位置; \cap 表示交集运算; \emptyset 表示空集; $N_0 + jNR/(Df_{\text{fault}}) + N_s$ 表示 IAS_g^D 信号中第 j 次故障冲击位置; $N_0 + jNR/(Df_{\text{fault}}) + N_s + \varphi$ 表示 IAS_g^D 信号中第 j 次故障冲击幅值 A 衰减到 σ 时的冲击位置。

在较大 N_w 和较小 K 的条件下,ADSMPDM算法可能会不同程度地改变与故障相关 IAS 分量的幅值,例如位于故障冲击前离散序列的幅值可能会被增强,在阶次谱中表现为“频率模糊”现象,计算式为:

$$h < \left(N_0 + \frac{kNR}{Df_{\text{fault}}} + N_s \right) \& H > \left(N_0 + \frac{kNR}{Df_{\text{fault}}} + N_s + \mu\varphi \right) \quad (10)$$

式中 μ 为衰减系数, $\mu \in (0, 1]$; $\&$ 表示并运算。

值得指出的是,由于轴承的随机滑动特性,导致轴承故障引入的频率模糊现象较齿轮来说更显著,即二阶循环平稳特性将会增强。

3.3 计算成本

为有效表征 ADSMPDM 算法的计算成本,假设原始瞬时角速度信号 IAS_i 的长度为 $L = \text{length}(IAS_i)$, IAS_g^D 的长度为 L/D , 则 ADSMPDM 算法的循环计算次数 T_c 可表示为:

$$T_c = \begin{cases} \frac{L}{D} + \frac{LK}{D} \left(\frac{NR}{49Df_{\text{fault}}} + 2D + 2 \right), & \text{轴承故障} \\ \frac{L}{D} + \frac{LK}{D} (2D + 2), & \text{齿轮故障} \end{cases} \quad (11)$$

式中 T_c 主要由两部分组成,前者 (L/D) 为平均降采样的计算次数,后者为多周期微分均值的计算次数。可见,轴承故障的计算成本高于齿轮故障。此外,在 L, R, N 不变的工况下,增大 D 或减小 K, N_w 可降低 ADSMPDM 算法的循环计算次数。对于轴承故障而言, $LKNR/(49D^2f_{\text{fault}})$ 中 K 与计算次数呈线性关系,而 $1/D$ 与计算次数呈平方关系,即增大 D 值比减小 K 值更能降低 ADSMPDM 算法的计算成本。

为更直观地评估 ADSMPDM 算法的计算成本,采用 AMD R7 处理器和内存为 6 GB 的笔记本电脑,安装 2018b 版本的 MATLAB,基于式(2)生成仿真信号,其中, $f_{\text{fault}} = 3.56 \times$, $A = 1$, $\xi = 0.03$, 在转速为 1.257 rad/s 时,对应固频 f_n 为 $50 \times$, $\Theta = \text{floor}(N/f_{\text{fault}}) = 1404$, $\langle \tau_j \rangle = 0$, $\max(|\tau_j|) = 28$, $\text{SNR} = -10$ dB, $\text{floor}(\cdot)$ 表示向下取整操作,ADSMPDM 算法分别在参数 L, K, D, N_w 条件下循环计算 100 次的平均时间如图 7 所示。可见,轴承随机滑动特性导致 ADSMPDM 算法中轴承故障的计算成本高于齿轮故障。

3.4 参数讨论

ADSMPDM 算法需要设置 6 个参数: $D, K, R, f_{\text{fault}}, N_w$ 和 η 。其中, D 为降低算法计算成本的主要参数之一,由于编码器信号的采样率(每圈刻蚀编码器线数)不如传统振动信号的采样率高, D 通常取值为 2~4; K 为提升算法鲁棒性的主要参数,通常 $K \geq 3$, K 值越大,ADSMPDM 算法对感兴趣分量能量幅值的

增强效果越好,但需要更高的计算成本(如图7(b))

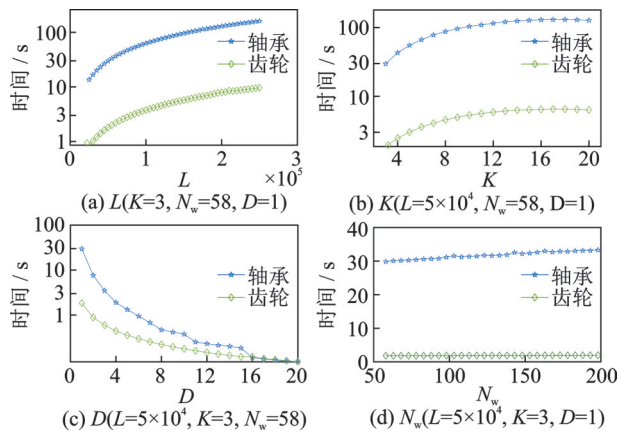


图7 不同参数与ADSMPDM算法计算成本的关系

Fig. 7 Relationship between different parameters and computational cost of ADSMPDM algorithm

所示);根据传动系统参数、齿轮齿数或者轴承参数, R 和 f_{fault} 可以被计算获得^[17];为有效包含旋转部件引起的 IAS 波形, $2\text{floor}(N_s^m) < N_w < 4\text{floor}(N_s^m)$;相邻故障冲击间滑动比例 η 通常取值为 $(0, 2]$, 以消除轴承随机滑动、降采样误差和离散采样误差的干扰。

4 基于 ADSMPDM 的关键旋转部件故障特征提取

4.1 技术路线

为有效增强 IAS 信号中旋转部件故障引起的 IAS 分量,提出一种 ADSMPDM 的故障特征增强方法,如图8所示。详细步骤如下:

(1)通过高速计数器获取瞬时角位移信息和对应的时间信息,并通过式(1)估计 IAS_i ;

(2)设置平均降采样倍数 D ,通过式(3)对原始 IAS_i 进行降采样操作以减小 ADSMPDM 算法的成本,并且抑制随机噪声的干扰;

(3)设置参数 $K, R, f_{\text{fault}}, N_w$ 和 η ,采用式(6)增强感兴趣分量的故障特征;

(4)阶次谱分析揭示故障特征。

4.2 所提方法的优势

本文所提方法具有以下优势:

(1)平均降采样操作既能抑制随机噪声,又能降低 ADSMPDM 算法的计算成本,为降低 ADSMPDM 算法的计算成本提供有效途径;

(2)通过 ADSMPDM 算法能有效增强旋转部件故障分量的幅值,进而抑制编码器安装误差、估计误差和测量误差等分量的干扰;

(3)基于 ADSMPDM 算法可实现旋转部件的故障特征增强。

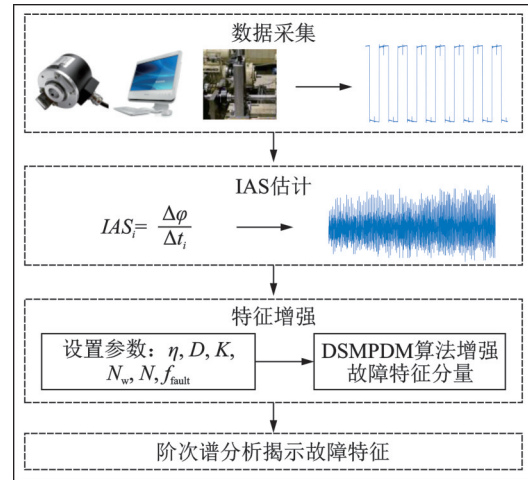


图8 ADSMPDM算法流程图

Fig. 8 Flow chart of ADSMPDM algorithm

5 仿真分析

采用仿真信号验证所提算法的有效性,并与 $FK^{[2]}$, $MOMEDA^{[5]}$, $DRS^{[7]}$ 和 $SAM^{[9]}$ 算法进行对比。由于滚动轴承故障分量相对于齿轮故障分量较微弱,本部分采用滚动轴承内圈故障仿真信号验证 ADSMPDM 算法的有效性。基于轴承故障引起的 IAS 特性,滚动轴承内圈故障模型可表示为:

$$W_{\text{bpf}} = w(\theta) + w_{\text{bpf}}(\theta) + w_o(\theta) + n(\theta),$$

$$w_{\text{bpf}}(\theta) = \sum_j A_m e^{-\xi_j \psi} \sin(f_n \sqrt{1 - \xi_j^2} \psi),$$

$$A_m = A_0 \cos(f_m \theta + \phi_A) + C_A,$$

$$w_o(\theta) = \left(\frac{\rho^2 - \rho \cos \theta_e}{(\rho \cos \theta_e - 1)^2} + \frac{\cos \beta}{(\cos \beta \cos \theta_i)^2 + (\sin \theta_i)^2} - 1 \right) w(\theta) \quad (12)$$

式中 W_{bpf} 为轴承内圈故障仿真信号; $w_{\text{bpf}}(\theta)$ 为轴承内圈冲击衰减分量; A_m 为滚动轴承内圈的调制函数; A_0 为冲击幅值; f_m 表示调制频率; ϕ_A 为初始角度; C_A 为常量; $w_o(\theta)$ 为编码器安装误差^[10]; ρ 和 β 分别表示编码器安装的偏心误差和倾斜误差; θ_e 和 θ_i 为初始角度; $n(\theta)$ 为随机噪声。

5.1 轴承内圈故障仿真信号

基于式(12)生成滚动轴承内圈故障仿真信号,其中 $N=10000$,在转速为 5 rad/s 时的固有频率 $f_n=50 \times$, $\Theta = \text{floor}(N/f_{\text{fault}}) = 1941$, $\rho=0.001$, $\beta=0.03$, $A=0.0001$, $\xi=0.03$, $\langle \tau_j \rangle = 0$, $\max(|\tau_j|) = 39$, $f_{\text{bpf}}=5.15 \times$, $R=1$,转频阶次 $f_{i1}=1 \times$,信噪比为 -25 dB 。仿真的 IAS 波形和对应的阶次谱分别如

图 9(a)和(b)所示。可见,转频阶次谱线占主导地位,而滚动轴承内圈特征谱线无法被有效辨识。

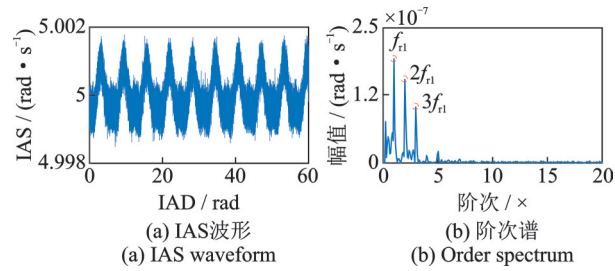


图 9 轴承内圈故障仿真信号
Fig. 9 Simulation signal of bearing inner race fault

一方面,采用 FK, MOMEDA, DRS 和 SAM 算法分别对原始 IAS 信号进行分析,其中,FK 算法中分解等级 $L=7$, MOMEDA 算法中滤波长度为 1000,周期点数为 1941,搜索范围为 $[2, 3000]$,DRS 算法中延迟为 500,窗宽为 15 倍故障特征阶次, SAM 算法中 MO 搜索范围为 $[-0.5, 1.5]$ 。如图 10(a)所示,FK 算法确定的优化中心频率为 $78\times$,带宽为 $52\times$,优化解调频带的阶次谱如图 10(b)所示。可见,转频阶次谱线的 3 倍频占主导地位,而滚动轴承内圈故障特征阶次谱线及其 2 倍频谱线并不显著。另外, MOMEDA 算法确定的优化周期点数和对应的阶次谱分别如图 10(c)和(d)所示,可见,滚动轴承内圈故障特征谱线无法被有效辨识。再者,采用 DRS 算法对仿真信号进行分析,如图 11(a)和(b)所示,可见,轴承内圈故障特征谱线无法被有效辨识。此外, SAM 算法确定的优化 MO 值如图 11(c)所示,对应的阶次谱如图 11(d)所示,可见,轴承故障特征谱线无法被有效辨识。因此,由于仿真信号的信噪比低以及编码器安装误差的干扰,应用传统方法无法有效增强 IAS 信号中滚动轴承故障特征。

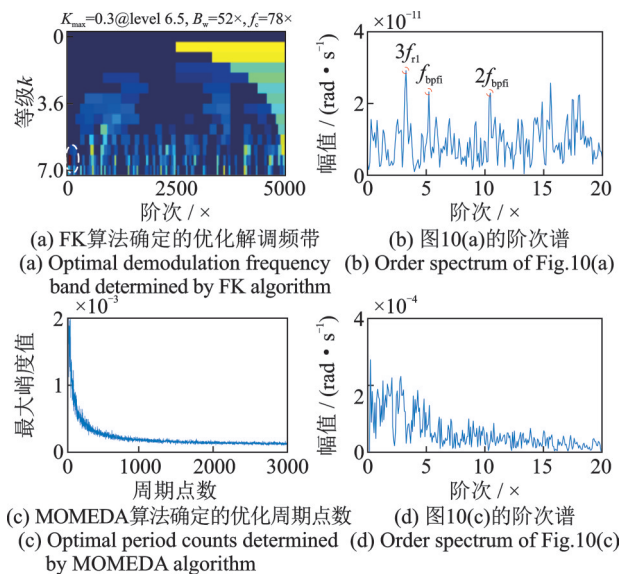


图 10 FK 和 MOMEDA 算法获得的结果

Fig. 10 Results obtained by FK and MOMEDA algorithm

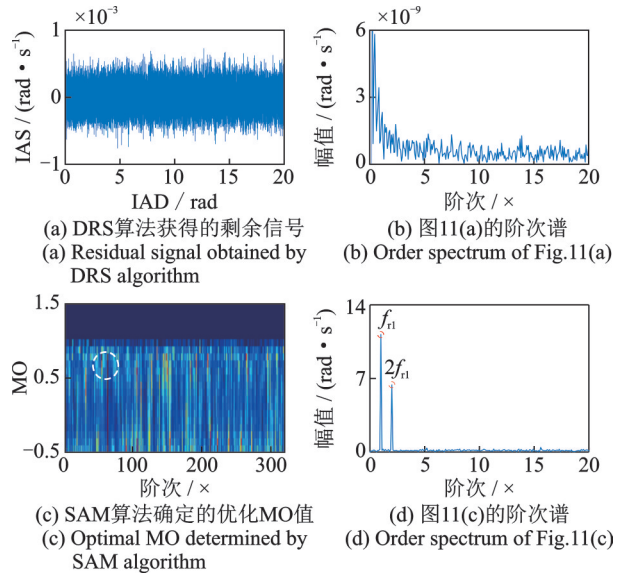


图 11 DRS 和 SAM 算法获得的结果

Fig. 11 Results obtained by DRS and SAM algorithm

另一方面,采用 ADSMPDM 算法对 IAS 信号进行分析,其中, $D=2, K=7, N_w=58, f_{\text{fault}}=5.15\times, \eta=2, R=1$,如图 12(a)和(b)所示,可见,滚动轴承故障阶次谱线可以被有效辨识,编码器安装误差分量和背景噪声分量得到有效抑制。通过与 FK, MOMEDA, DRS 和 SAM 算法进行对比,验证了本文所提算法的有效性。

5.2 无故障仿真信号

为进一步验证所提方法在无故障工况下的鲁棒性,本文采用无轴承故障分量的仿真信号作为测试对象,参数设置与 5.1 节中一致。无故障 IAS 波形及其对应的阶次谱分别如图 12(c)和(d)所示。可见,

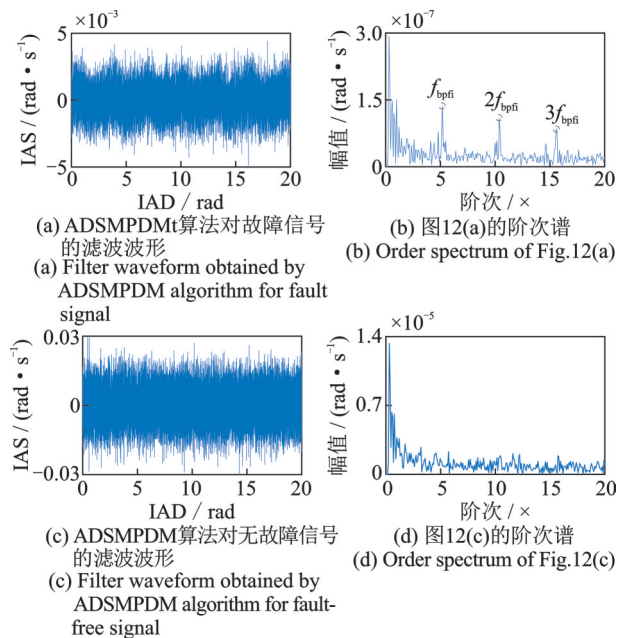


图 12 ADSMPDM 算法获得的结果

Fig. 12 Results obtained by ADSMPDM algorithm

ADSMPDM算法在无故障状态下无法增强轴承故障分量,即ADSMPDM算法具有较好的鲁棒性。

6 实验数据

本部分采用图 13 所示的试验台进行验证,通过采样率为 10^7 Hz 的自制高速计数器采集系统获取 IAD 信息和对应的时间信息,采用式(1)估计 IAS 信号,编码器型号为 ETF100-H851007B,编码器每圈光栅数为 5000,编码器安装在大齿轮轴上。




图 13 试验台

Fig. 13 Test bench

本实验使用的滚动故障轴承型号为 6202-2RZ,为模拟滚动轴承外圈故障,在轴承外圈上用线切割方法加工一宽度约为 0.3 mm,深度约为 0.28 mm 的小槽,如图 13 所示,滚子直径 d 为 9.52 mm,节圆直径 D_p 为 46 mm,滚子数目 n 为 9,接触角 α 为 0。齿轮箱中小齿轮齿数为 32,大齿轮齿数为 48,为模拟齿轮局部故障,小齿轮表面加工局部点蚀故障,如图 13 所示。综上所述,本实验中故障特征阶次如表 1 所示。

表 1 轴承和齿轮的故障特征阶次

Tab. 1 Fault feature order of bearing and gear

类型	特征阶次/ \times
大齿轮转频阶次 f_{t1} (编码安装位置)	1
小齿轮转频阶次 f_{t2}	1.5
轴承外圈故障阶次 f_{p10}	5.15
齿轮啮合阶次 f_{mesh}	48

6.1 正常状态数据

采用无故障数据验证 ADSMPDM 算法的有效性,估计的 IAS 波形和对应的阶次谱如图 14(a)和(b)所示,可见,转频阶次谱线 $1\times$ 和 $1.5\times$ 占主导地位。一方面,假设无故障数据中有轴承故障信息,采用 ADSMPDM 算法对无故障数据进行分析,其中, $f_{fault}=5.15\times, K=13, N_w=58, D=4, \eta=2, R=1$,如图 14(c)和(d)所示,可见,轴承故障谱线无法被有效辨识。另一方面,假设无故障数据中包含齿轮故障信号,采用 ADSMPDM 算法($f_{fault}=1.5\times, K=$

$5, N_w=10, D=4, \eta=2, R=1$)对无故障数据进行分析,如图 14(e)和(f)所示,可见,在啮合频率 $f_{mesh}=48\times$ 位置处无法有效辨识齿轮故障调制频率 $f_{gear}=1.5\times$ 。因此,ADSMPDM 算法无法从无故障数据中增强轴承、齿轮故障特征。

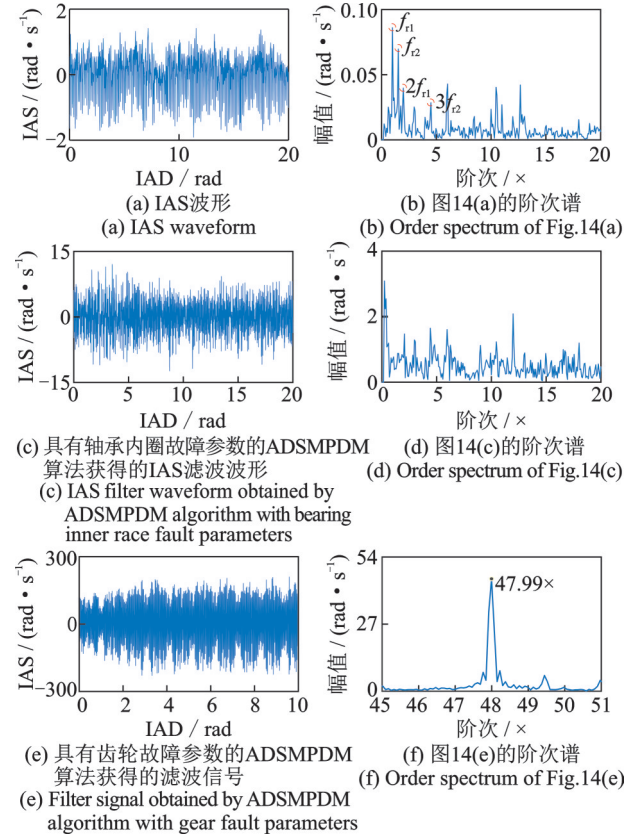


图 14 ADSMPDM 算法对无故障数据的分析结果

Fig. 14 Analysis results obtained by ADSMPDM algorithm for fault-free data

6.2 齿轮故障数据

为验证 ADSMPDM 算法的有效性,对小齿轮局部点蚀故障数据进行分析,估计的 IAS 波形和对应的阶次谱分别如图 15(a)和(b)所示,可见,啮合频率 $f_{mesh}=48\times$ 位置处的转频调制谱线 $1\times$ 及其倍频阶次谱线占主导地位。

首先,采用 FK 算法确定包含丰富齿轮故障信息的解调频带,如图 16(a)所示,优化中心频率为

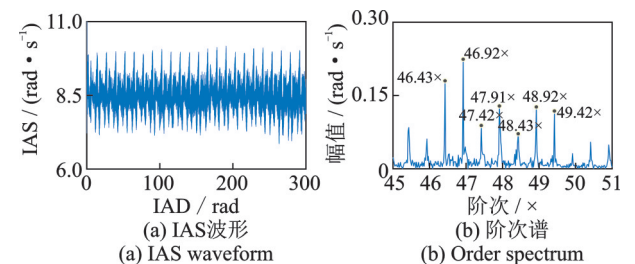


图 15 齿轮故障数据

Fig. 15 Fault data of gear

2187.5 \times , 频带宽度为 625 \times , 优化解调频带对应的阶次谱如图 16(b)所示。可见, 转频调制谱线 1 \times 占优, 而小齿轮故障谱线 1.5 \times 及其倍频无法被有效辨识。另外, MOMEDA 算法对齿轮故障数据分析的结果如图 16(c)和(d)所示, 其中, 滤波长度为 1000, 周期点数为 3333, 搜索范围为 [5, 3500], 大齿轮转频阶次谱线 1 \times 及其倍频谱线占优。其次, 分别采用 DRS(延迟为 500 点, 窗宽为 15 倍故障特征阶次) 和 SAM 算法(MO 的搜索范围为 [-0.5, 1.5]) 对齿轮故障数据进行分析, 确定的优化 MO 值为 0.7, 如图 17 所示。可见, 小齿轮局部故障阶次谱线 1.5 \times 及其倍频无法被有效辨识, 而大齿轮转频阶次谱线 1 \times 及其倍频谱线占优。以上算法无法有效增强齿轮故障特征的原因在于原始 IAS 信号中存在较大幅值编码器安装误差的干扰。

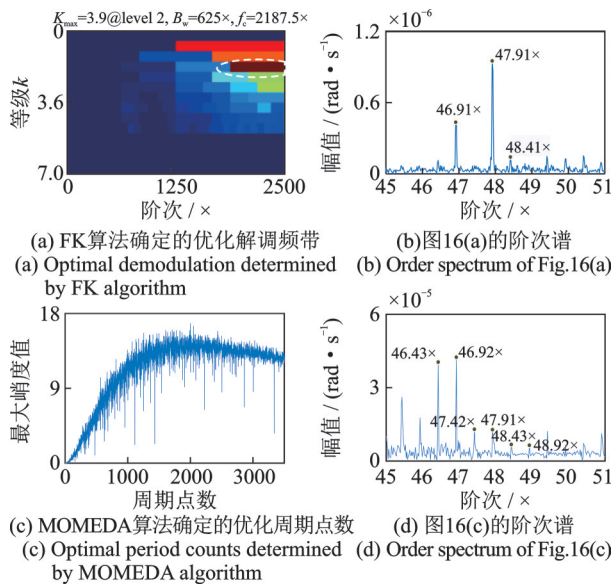


图 16 FK 和 MOMEDA 算法的分析结果

Fig. 16 Analysis results obtained by FK and MOMEDA algorithm

采用本文所提算法对齿轮故障数据进行分析, 其中, $f_{\text{fault}}=1.5 \times$, $K=5$, $N_w=10$, $D=4$, $\eta=2$, $R=1$, 如图 18 所示, 可见, 小齿轮故障阶次谱线 1.5 \times 及其倍频可被有效辨识。因此, 通过与 FK, MOMEDA, DRS 和 SAM 算法进行对比, 验证了 ADSMPDM 算法对增强 IAS 信号中齿轮故障特征的有效性。

6.3 滚动轴承故障数据

为验证 ADSMPDM 算法对增强齿轮故障特征的有效性, 采用滚动轴承外圈故障数据进行验证, 估计的 IAS 波形和对应的阶次谱如图 19 所示。可见, 转频谱线占主导地位, 而滚动轴承外圈故障特征谱线无法被有效辨识。因此, 原始 IAS 信号无法直接有效揭示轴承外圈故障特征。

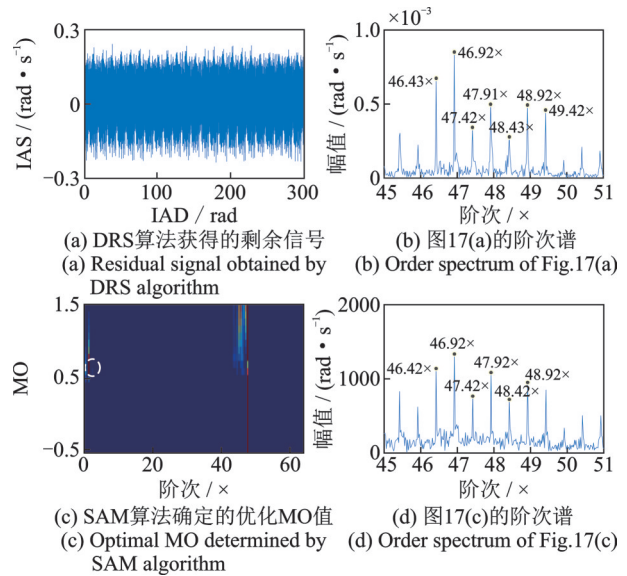


图 17 DRS 和 SAM 算法获得的结果

Fig. 17 Results obtained by DRS and SAM algorithm




图 18 ADSMPDM 算法获得的结果

Fig. 18 Results obtained by ADSMPDM algorithm

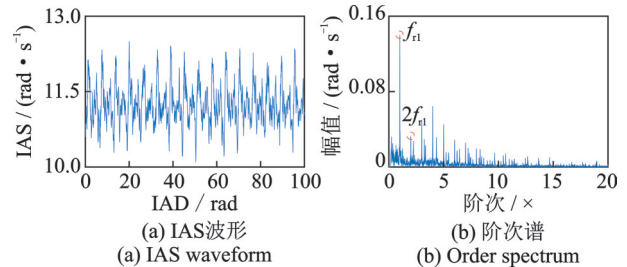


图 19 轴承外圈故障数据

Fig. 19 Fault data of bearing outer race

一方面, 采用 FK 算法对轴承外圈故障数据进行分析, 最大分解等级 k 为 7, 确定的优化解调频带(中心频率为 1393 \times , 频带宽度为 26 \times) 和对应的阶次谱分别如图 20(a)和(b)所示, 可见, 轴承外圈故障特征谱线无法被有效辨识; 采用 MOMEDA 算法获得的结果如图 20(c)和(d)所示, 其中, 滤波长度为 1000, 周期点数为 970, 搜索范围为 [5, 3000], 在图 20(d)中无法有效辨识轴承外圈故障特征谱线。此外, 分别采用 DRS 和 SAM 算法对原始 IAS 信号进行分析, 结果如图 21 所示。可见, 尽管图 21(b)中可以辨识滚动轴承外圈故障特征谱线, 但依然存在转频阶次谱线的干扰; 而 SAM 算法无法有效增强轴承故障特征。以上算法无法有效揭示轴承故障特

征的原因在于轴承故障信号微弱,编码器安装误差分量和齿轮啮合分量对轴承故障分量具有较强的干扰作用。

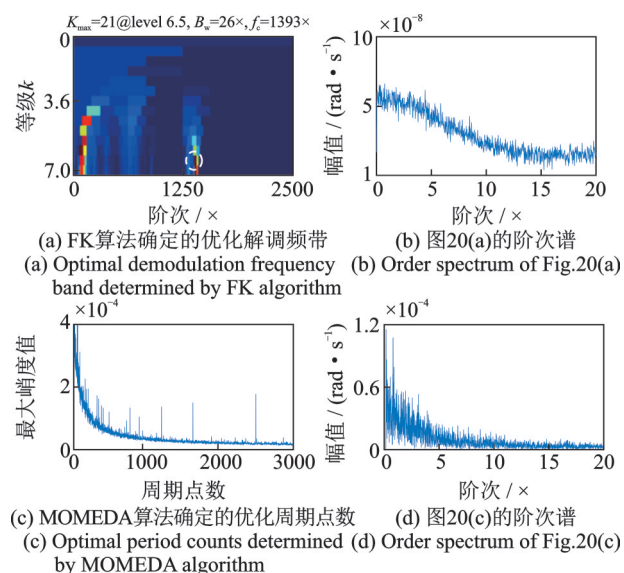


图 20 FK 和 MOMEDA 算法获得的结果

Fig. 20 Results obtained by FK and MOMEDA algorithm

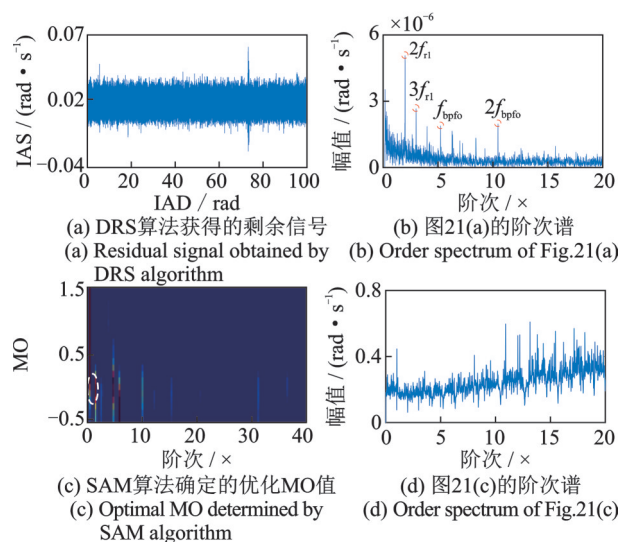


图 21 DRS 和 SAM 算法获得的结果

Fig. 21 Results obtained by DRS and SAM algorithm

另一方面,采用本文提出的 ADSMPDM 算法进行分析,结果如图 22 所示,其中, $f_{\text{fault}}=5.15 \times$, $K=13$, $N_w=58$, $D=4$, $\eta=2$, $R=1$ 。可见,滚动轴承外

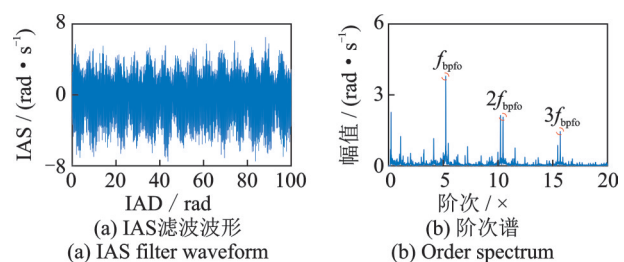


图 22 DSMPDM 算法获得的结果

Fig. 22 Results obtained by DSMPDM algorithm

圈故障特征谱线占优,而编码器安装误差分量和齿轮啮合分量得到有效抑制。通过与 FK, MOMEDA, DRS 和 SAM 算法进行对比,验证了 ADSMPDM 算法增强轴承外圈故障特征的有效性和优势。

7 结 论

为有效增强 IAS 信号中旋转部件的故障特征,本文提出一种 ADSMPDM 算法,可得出以下结论:

- (1) IAS 信号的平均降采样操作可降低 ADSMPDM 算法的计算成本和抑制随机噪声的能量幅值;
- (2) ADSMPDM 算法可有效增强旋转部件的故障特征;
- (3) 通过与 FK, MOMEDA, DRS 和 SAM 算法进行对比,验证了 ADSMPDM 算法增强 IAS 信号中旋转部件故障特征的优势。

参考文献:

- [1] 李志农, 刘跃凡, 胡志峰, 等. 经验小波变换-同步提取及其在滚动轴承故障诊断中的应用[J]. 振动工程学报, 2021, 34(6): 1284-1292.
Li Zhinong, Liu Yuefan, Hu Zhifeng, et al. Empirical wavelet transform-synchroextracting transform and its applications in fault diagnosis of rolling bearing[J]. Journal of Vibration Engineering, 2021, 34(6): 1284-1292.
- [2] Antoni J. Fast computation of the kurtogram for the detection of transient faults[J]. Mechanical Systems and Signal Processing, 2007, 21(1): 108-124.
- [3] Antoni J. The infogram: entropic evidence of the signature of repetitive transients[J]. Mechanical Systems and Signal Processing, 2016, 74: 73-94.
- [4] 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.
- [5] McDonald G L, Zhao Q. Multipoint optimal minimum entropy deconvolution and convolution fix: application to vibration fault detection[J]. Mechanical Systems and Signal Processing, 2017, 82: 461-477.
- [6] Antoni J, Randall R B. Unsupervised noise cancellation for vibration signals: part I — evaluation of adaptive algorithms[J]. Mechanical Systems and Signal Processing, 2004, 18(1): 89-101.
- [7] Antoni J, Randall R B. Unsupervised noise cancellation for vibration signals: part II — a novel frequency-domain algorithm[J]. Mechanical Systems and Signal Processing, 2004, 18(1): 103-117.
- [8] Borghesani P, Pennacchi P, Randall R B, et al. Application of cepstrum pre-whitening for the diagnosis of bearing

- faults under variable speed conditions[J]. *Mechanical Systems and Signal Processing*, 2013, 36(2): 370-384.
- [9] Moshrefzadeh A, Fasana A, Antoni J. The spectral amplitude modulation: a nonlinear filtering process for diagnosis of rolling element bearings[J]. *Mechanical Systems and Signal Processing*, 2019, 132(1): 253-276.
- [10] Zeng Q, Feng G J, Shao Y M, et al. An accurate instantaneous angular speed estimation method based on a dual detector setup[J]. *Mechanical Systems and Signal Processing*, 2020, 140: 106674.
- [11] Braut S, Žigulić R, Skoblar A, et al. Partial rub detection based on instantaneous angular speed measurement and variational mode decomposition[J]. *Journal of Vibration Engineering and Technologies*, 2020, 8(1): 351-364.
- [12] Li B, Zhang X N, Wu J L. New procedure for gear fault detection and diagnosis using instantaneous angular speed[J]. *Mechanical Systems and Signal Processing*, 2017, 85: 415-428.
- [13] Miao Y H, Zhao M, Liang K X, et al. Application of an improved MCKDA for fault detection of wind turbine gear based on encoder signal[J]. *Renewable Energy*, 2020, 151: 192-203.
- [14] Lizoul K, André H, Guillet F. Spectral precision of frequency demodulation method: influence of additive noise on instantaneous angular speed spectral estimation[J]. *Mechanical Systems and Signal Processing*, 2022, 164: 108178.
- [15] Gomez J L, Khelif I, Bourdon A, et al. Angular modeling of a rotating machine in non-stationary conditions: application to monitoring bearing defects of wind turbines with instantaneous angular speed[J]. *Mechanism and Machine Theory*, 2019, 136(1): 27-51.
- [16] Moustafa W, Cousinard O, Bolaers F, et al. Low speed bearings fault detection and size estimation using instantaneous angular speed[J]. *Journal of Vibration and Control*, 2016, 22(15): 3413-3425.
- [17] Randall R B, Antoni J. Rolling element bearing diagnostics—a tutorial[J]. *Mechanical Systems and Signal Processing*, 2011, 25: 485-520.

Fault feature enhancement method of rotating parts based on average down-sampling multi-period differential mean

CHEN Xin, GUO Yu

(Faculty of Mechanical and Electrical Engineering, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: To address the issue of weak features related to faulty rotating parts in Instantaneous Angular Speed (IAS) signal, this study proposes a Average Down-Sampling Multi-Period Differential Means (ADSMPDM) scheme to enhance fault features. Firstly, based on the estimation characteristics of the IAS, the average down-sampling of the IAS signal is studied and its features of suppressing random noise are obtained. Secondly, the ADSMPDM scheme is proposed to enhance the features related to the fault in the IAS signal based on the advantages of the average down-sampling (such as noise suppression, low computational cost and low storage space) and accumulative characteristic of multi-period differential means. Finally, the features related to the fault are revealed by order spectrum analysis. By using Simulations and experiments and comparing with fast kurtogram, multipoint optimal minimum entropy deconvolution adjusted, discrete random separation and spectral amplitude modulation, the effectiveness and advantages of the ADSMPDM algorithm in enhancing gear and bearing fault feature components are verified.

Key words: fault diagnosis; average down-sampling multi-period differential means; encoder signal; instantaneous angular speed; feature extraction

作者简介: 陈鑫(1995—),男,博士,讲师。E-mail: xin_chen@kust.edu.cn。

通讯作者: 郭瑜(1971—),男,博士,教授,博士生导师。E-mail: guoyu@kust.edu.cn。