

DOI: 10.19650/j.cnki.cjsi.J2209314

循环脉冲指数最大化的共振稀疏分解法及应用*

刘小峰, 黄洪升, 柏 林, 陈兵奎
(重庆大学机械与运载工程学院 重庆 400044)

摘 要:针对复杂多变工作环境下滚动轴承产生的微弱故障信息难以提取的问题,充分利用故障冲击的脉冲性与循环周期性,提出了循环脉冲度最大化的共振稀疏分解(RSD)方法。该方法以短时脉冲峰值矩的变异系数作为循环脉冲指数对轴承故障信号脉冲性与周期性进行综合表征。然后以循环脉冲指数最大化作为优化目标,采用多尺度简化粒子群算法对RSD的品质因子进行了组合优化。最后构建了最优RSD循环脉冲谱,实现了滚动轴承故障的自动辨识。仿真结果与动车轴箱轴承的故障诊断应用实例表明,提出的循环脉冲指数最大化的RSD能够有效避免强脉冲干扰造成的共振频带误判问题,实现复杂工况环境下的滚动轴承复合多故障同步诊断,具有良好的工程适用性。

关键词: 动车轴箱轴承;共振稀疏分解;循环脉冲谱;故障诊断

中图分类号: TH17 TN911 **文献标识码:** A **国家标准学科分类代码:** 460.40

A resonance sparse decomposition method based on maximizing cyclic pulse index and its application

Liu Xiaofeng, Huang Hongsheng, Bo Lin, Chen Bingkui

(College of Mechanical and Vehicle Engineering, Chongqing University, Chongqing 400044, China)

Abstract: It is difficult to extract the weak information of rolling bearing fault under complex and changeable operating environments. To address this issue, an optimized resonance sparse decomposition (RSD) based on maximizing the cyclic pulse index (CPI) is proposed, which takes full advantage of pulse characteristics and cycle period characteristics of fault impacts. Firstly, the variation coefficient of the short-time pulse peak moment is used as the CPI to comprehensively characterize the pulse and periodicity of the bearing fault signal. Then, the quality factors of RSD are optimized by the multi-scale simplified particle swarm optimization algorithm with the objective of maximizing the CPI. Finally, the cyclic pulse spectrum of the low-frequency resonance component is established to automatically identify the bearing faults. The results of simulation and applications in the fault diagnosis of EMU axle box bearings show that the proposed method effectively avoids the misjudgment of resonance frequency band caused by strong pulse interferences, and performs well in the synchronous diagnosis of bearing compound faults under complex working conditions, which demonstrates its engineering applicability in the field of bearing fault diagnosis.

Keywords: EMU axle box bearing; resonance sparse decomposition; cyclic pulse spectrum; fault diagnosis

0 引 言

轴箱轴承作为高速列车安全运行的关键部件之一,在列车高速运转中承载着各种高周交变载荷,其故障损伤易引发轴温报警,导致列车紧急停车,甚至诱发列车失稳,严重影响列车行驶安全^[1-2]。受转向架结构

和工况环境的影响,轴箱轴承滚动体与保持架的随机滑动频繁,产生的故障冲击形态各异,且时间间隔不一致,具有非典型循环周期性。轴箱轴承早期损伤产生的故障脉冲微弱,极易受到踏面损伤、轨道不平顺等引起的强烈异常冲击的干扰,且其故障脉冲形态多样、强弱不均,易出现强冲击对弱冲击的掩蔽效应导致的弱故障漏诊现象。

收稿日期:2022-02-18 Received Date: 2022-02-18

* 基金项目:国家自然科学基金(51975067, 52175077)项目资助

为了有效地对轴箱轴承故障信息进行提取,许多文献结合信号时频域变换及其改进方法对轴箱轴承的故障特征进行了挖掘。Li 等^[3]提出了一种改进的多尺度加权散度熵特征,提高了轴箱轴承故障的智能诊断精度。Xiong 等^[4]利用四项三阶导数 Nuttall 加窗快速傅里叶变换进行精细相位差校正,提取了轴箱轴承故障特征频率及其谐波的准确幅值。Wang 等^[5]采用了小波包分解的能量特征与复合多尺度置换熵对轴箱轴承进行了故障诊断。Cheng 等^[6]提出了自适应多点最优最小熵反褶积校正法对轴箱轴承的周期性故障脉冲进行了提纯。文献[7]采用了尺度空间引导的变分模态分解方法对机车轴轴承进行了故障辨识。文献[8]对轴箱轴承振动信号进行小波消噪后提取了多域特征,然后结合特征降维技术与模糊聚类算法对高速列车的轴箱轴承故障进行了自动辨识。以上文献采用的都是轴箱轴承振动信号的全局处理方法,主要根据故障状态下与正常状态下的轴承信号时频域特征差异性进行故障辨识,未针对轴承故障冲击的具体特性进行深入研究,因此无法保证其在时变复杂工况下的诊断准确率。

如何从综合振动中分离并凸显轴承缺陷激发的故障信号,是实现轴箱轴承故障诊断的关键所在。为了抑制噪声及干扰频率成分对轴承故障脉冲提取的影响,许多文献采用了最大相关峭度解卷积^[9]、快速谱峭度^[10]、可调 Q 因子小波变换^[11]等方法对轴承故障脉冲共振频带进行优化选择,但这些方法都需要一定的先验知识进行窗函数或小波函数、分解层数与中心频率的选择,输入参数较多且要求严格。共振稀疏分解(resonance sparse decomposition, RSD)方法突破了传统分解信号基于频段的技术局限,可有效提高信号的冲击特性。但 RSD 方法中品质因子的选择与低共振脉冲分量的提取密切相关,对此许多研究学者采用了 GA 优化^[12]、人工蜂群优化^[13]、蛙跳法^[14]、并行双参数优化法^[15]等对 RSD 的 Q 因子进行了优化。这些文献研究主要以低频段共振分量的峭度及其变体作为 RSD 优化的评价指标。轴箱轴承在运行过程中,轨道随机激励、车轮缺陷激励和轨道特殊区段激励所产生的高频冲击振动也都会被安装在轴箱处的振动传感器所采集^[16]。这些冲击振动往往频率更高、幅值更大,采用基于峭度最大化的共振频带滤波法难以得到有效滤除,易造成共振频带的误判,影响后端的轴承故障辨识准确性。

针对以上问题,提出了一种基于循环脉冲指数(cyclic pulse index, CPI)的 RSD 优化方法。该方法脱离了噪声抑制与脉冲共振解调的基本框架,充分利用故障冲击脉冲性与周期性,能够成功抑制干扰脉冲成分对循环周期性故障冲击的干扰,消除强故障冲击对弱故障冲击的掩蔽效应,实现轴承复合故障的同步诊断。

1 共振稀疏分解

RSD 通过调节品质因子将轴承故障信号 x 分解为包含谐波成分的高共振分量和包含瞬态冲击成分的低共振分量。经 RSD 分解后的信号可表示为:

$$x = S_H W_H + S_L W_L + n \quad (1)$$

式中: S_H, S_L 分别为高、低品质因子的可调小波基函数库; W_H, W_L 为 S_H, S_L 对应的匹配系数矩阵; n 为残余分量。选择合适的 Q_H, Q_L 、冗余因子、分解层数,得到对应小波基函数 S_H 和 S_L 。调节品质因子小波变换得到对应子带的初始稀疏矩阵,生成初始的高共振分量 $S_H W_H$ 和低共振分量 $S_L W_L$, 建立式(2)中的分解目标函数^[17]:

$$J(W_H, W_L) = \|x - S_H W_H - S_L W_L\|_2^2 + \lambda_H \|W_H\| + \lambda_L \|W_L\| \quad (2)$$

式中: λ_H 与 λ_L 为正则化参数,与对应小波函数的能量正相关,其数值决定了高低共振成分的能量分配。通过分裂增广拉格朗日收缩算法,得到式(2)最小时的最优系数矩阵 W_H^*, W_L^* 。最终重构获得原始信号中高低共振分量 x_H 与 x_L 的稀疏表达式:

$$x_H = S_H W_H^*, x_L = S_L W_L^* \quad (3)$$

RSD 分解过程中,以高品质因子 Q_H 和低品质因子 Q_L 决定的 S_H 与 S_L 作为与匹配信号相关的基函数库。要实现最大化的故障冲击分离,要求 Q_H, Q_L 与信号的高低共振属性相匹配,不匹配的 Q_H, Q_L 会导致小波基函数与信号的振荡特性不匹配,产生信号分解的奇异性。尽管正则化参数 λ_H 与 λ_L 会影响高低共振分量的能量分配,但共振分量的能量大小对故障脉冲的周期性与脉冲性影响不大,且优化目标参数过多会影响优化算法的收敛性和计算效率。因此,本文将正则化参数 λ_H 与 λ_L 设定为经验数值 0.2^[17],以循环脉冲指数的最大化为目标,结合不同故障冲击特征进行 Q_H, Q_L 的优化选择,以实现 RSD 的最佳分解。

2 多尺度简化粒子群优化算法

传统的粒子群优化算法及其改进策略大部分是从所有粒子趋近全局最优和局部最优的角度进行设计,处在同代的粒子往往采用同一惯性权重来进行位置更新,没有考虑同代粒子之间的差异性^[18]。实际上,在算法迭代前期,数值偏大的同代权重可能会导致位置更优的粒子更新步长过大,进而降低了粒子的局部寻优能力。在算法迭代中后期,数值偏小的同代权重可能会导致位置更劣的粒子更新步长过小,进而降低了粒子的全局寻优能力。

本文采用了多尺度简化粒子群优化算法(multiscale simplified particle swarm optimization, MSPSO)对RSD的 Q_H 与 Q_L 进行优化选择。根据 Q_H 和 Q_L 组成的最大内积充分小于1的规则^[17],设置 Q_H 和 Q_L 的粒子搜索范围,并在该范围内随机初始化一组粒子,组成大小为 N 的粒子种群,继而根据各个粒子的适应度大小来调整进化粒子搜索能力。当第 k 代种群中第 i 个粒子的适应度值 $f_{v_i}(k)$ 大于等于第 k 代种群适应度值的平均值 $f_{\text{avg}}(k)$,粒子越趋近于当代最优粒子时,则该粒子在下次更新应采用小尺度的惯性权重以增强粒子的局部搜索能力。小尺度惯性权重为:

$$\omega_i^s(k+1) = \omega_{\min} + \frac{f_{\max}(k) - f_{v_i}(k)}{f_{\max}(k) - f_{\text{avg}}(k)}(\omega_{\max} - \omega_{\min}) \quad (4)$$

式中: $\omega_i^s(k+1)$ 为第 $k+1$ 代种群中第 i 个粒子的小尺度惯性权重, $\omega_{\max}$ 为最大惯性权重,通常取0.9, $\omega_{\min}$ 为最小惯性权重,通常取0.4^[19], $f_{\max}(k)$ 为第 t 代种群中最大的适应度值。

反之,当 $f_{v_i}(k)$ 较小($f_{v_i}(k) < f_{\text{avg}}(k)$)时,粒子越趋近于当代最劣粒子,则该粒子在下次更新应采用大尺度的惯性权重,以增强粒子的全局搜索能力。大尺度惯性权重为:

$$\omega_i^m(k+1) = \omega_{\max} + \frac{f_{v_i}(k) - f_{\min}(k)}{f_{\text{avg}}(k) - f_{\min}(k)}(\omega_{\max} - \omega_{\min}) \quad (5)$$

则,多尺度惯性权重设置为:

$$\omega_i(k+1) = \begin{cases} \omega_i^s(k+1), & f_{v_i} \geq f_{\text{avg}}(k) \\ \omega_i^m(k+1), & f_{v_i} < f_{\text{avg}}(k) \end{cases} \quad (6)$$

假设第 i 个粒子在 j 维的位置表示为 $X_{ij}(k+1)$, $i=1,2,\dots,N$; $j=1,2,\dots,D$,当前搜索得到的个体最优解为 $\mathbf{Pb}_{ij}$ 以及整个种群迄今为止搜索到的全局最优解为 $\mathbf{Gb}_j$,则粒子位置的更新模型为:

$$X_{ij}(k+1) = \omega_i(k)X_{ij}(k) + c_1r_1(\mathbf{Pb}_{ij}(k) - X_{ij}(k)) + c_2r_2(\mathbf{Gb}_j(k) - X_{ij}(k)) \quad (7)$$

式中: k 为当前迭代次数; c_1, c_2 为学习因子,常取为2; r_1, r_2 为介于 $[0,1]$ 之间服从均匀分布的随机数; $\omega_i(k)$ 为权重系数,起着平衡全局寻优和局部寻优能力的作用。根据式(7)中更新的粒子位置,重新计算各个粒子的适应度值,最终输出的最优适应度值所对应的粒子位置即为 Q_H 与 Q_L 最优值。

3 循环脉冲指数

周期性冲击是旋转机械局部故障的主要特征,故障脉冲的循环频率是进行轴承故障辨识的关键。故障脉冲的出现会使信号的幅值急速增加后又急速衰减,波形呈

现陡峭山峰状,波形的尖峰程度表征了脉冲的能量变化情况,因此对于信号 $\{s(t), t=t_0 \sim t_1\}$,可以采用式(8)中的峰值矩(peak moment, PM)对单次脉冲进行表征:

$$PM = \frac{\int_{t_0}^{t_1} s(t) |t - t_{\text{peak}}| dt}{\int_{t_0}^{t_1} s(t) |t - t_0| dt} \quad (8)$$

式中: t_{peak} 为此次脉冲能量达到顶峰的时间。 PM 描述了信号的尖峰陡峭程度,其值越小,则 $s(t)$ 波形与脉冲的相似度越高。假如信号 $s(t)$ 包含故障频率为 f 的循环脉冲(即循环周期 $L=1/f$),则可采用时移可变窗函数 $w(t - \tau_i, L) = \begin{cases} 1, & \tau_i \leq t \leq L + \tau_i \\ 0, & \text{其他} \end{cases}$ 对 $s(t)$ 进行循环加窗截断,使得窗函数中心与脉冲峰值点重合时,即 $t_{\text{peak}} = (\tau_i + L/2)$ 且 $\tau_{i+1} = \tau_i + L$,如图1所示。




图1 滑动循环窗

Fig. 1 Sliding cycle window

提取图1中每个单脉冲分量的 PM ,并将所有循环窗内脉冲分量的 PM 和作为 $s(t)$ 的脉冲指数,表示为:

$$ID(t_s, f) = \sum_{\tau_i = t_s - 1/2f}^{t_1 - 1/2f} PM_w(\tau_i, f) \quad (9)$$

式中: t_s 为第1个循环窗函数的起始点。对于具有周期特性的故障脉冲,循环滑动窗长度一定时,第1个窗函数的起始点 t_s 对 $ID(t_s, f)$ 的取值会产生较大的影响。如图1所示,当实循环窗长 L (或频率 f)与起始点 t_s 设置恰当时,每个时移窗口恰好包含一个脉冲,每个窗函数内的截断分量的 PM 值都较小,则信号的 ID 值也较小。采用图1中虚线窗的 t_s 与 f , $t_s + L/2$ 恰好位于两次脉冲顶峰的正中间位置,对应 ID 最大值。若信号中存在周期性的脉冲分量, ID 会随着 t_s 的变化波动明显,否则波动较小。因此,当 t_s 在 $0 \sim 1/f$ 范围内变化时,可采用 ID 的变异系数表征信号 $s(t)$ 在频率 f 处的CPI,即:

$$CPI(f) = C. V(ID(t_s, f)) = \frac{\sum_{t_s=0}^{1/f} [ID(t_s, f) - \overline{ID(t_s, f)}]^2}{\overline{ID(t_s, f)}} \quad (10)$$

式中: $\overline{ID(t_s, f)}$ 表示信号在频率 f 下的脉冲指数的平均

值,不同频率处的 $CPI(f)$ 即构成了 $s(t)$ 的循环脉冲谱。由式 (10) 可知,对于存在周期性故障脉冲的 $s(t)$,其脉冲性越明显,在故障频率 f_d 处的 $\overline{ID}(t_s, f_d)$ 越小,脉冲周期性越突出,则 $ID(t_s, f_d)$ 的波动性越大,从而使得 $CPI(f_d)$ 值越大。反之,当 $s(t)$ 中的脉冲分量不具有周期性时,或当 $s(t)$ 分量仅具周期性而不具有脉冲性时, $CPI(f)$ 在每个频率处的取值都较小,不存在故障频率处的突出谱线。可见, $CPI(f)$ 在度量频率分量脉冲性的同时,也能度量脉冲的周期性,能够更好地对周期性故障脉冲进行有效表征。

4 基于最大化 CPI 的 RSD 循环脉冲谱

基于最大化 CPI 的 RSD 循环脉冲谱算法,根据轴承理论故障频率处的 CPI 构建 MSPSO 优化 RSD 的适应度函数,通过改变 RSD 的不同 Q 值组合对适应度函数值进行寻优,分解出故障脉冲性与周期性最为显著的低频共振分量,继而对故障冲击所在的低共振分量进行循环脉冲谱分析,即可实现对强弱不同的故障脉冲序列同步检测,解决强冲击分量对弱冲击分量的遮蔽效应造成的弱故障难以辨识的问题。该算法在轴承故障诊断的具体实施步骤如下:

1) 输入被分析信号,根据被分析轴承故障特征进行相关参数的初始设置。设置种群规模 N 、粒子维数 D 、最大迭代次数 $T_{\max}$ 、RSD 中 Q_H 与 Q_L 的寻优范围 $[Q_{L\min}, Q_{L\max}]$ 和 $[Q_{H\min}, Q_{H\max}]$, 在设定的寻优范围内随机初始化种群的初代位置。

2) RSD 分解。将粒子位置作为 RSD 中品质因子 Q_H 与 Q_L , 对被分析信号进行分解,提取低共振分量 x_L 。

3) 适应度值评价。设置 f_d 分别为滚动轴承的内圈、外圈及滚动体的故障频率 $f_{in}, f_{out}, f_{ball}$, 根据式 (8) ~ (10) 计算 x_L 在各个故障频率处的 CPI, 即, $CPI(f_{in}), CPI(f_{out}), CPI(f_{ball})$ 。为综合描述低频共振分量的整体脉冲性与对各个故障分量的敏感性,引入式 (11) 中的 CPI 增益作为 MSPSO 寻优的适应度函数:

$$L_{cpi} = \frac{\sum CPI(f_d)}{\sum P(f) - \sum P(f_d)} \quad (11)$$

式中: $f_d = f_{in}, f_{out}, f_{ball}$, $P(f)$ 为低频共振分量在频率 f 处的包络谱幅值。 L_{cpi} 表示输出的 f_d 处的 CPI 相对于其他频率处的包络谱幅值的强度,该值越大,表明在 f_d 处的循环脉冲性越明显。

4) 种群的分化及惯性权重的自适应调整。根据当代粒子种群适应度值的平均值进行优劣子群的分化,根据式 (3) ~ (4) 进行惯性权重的自适应调整。

5) 种群位置的更新。根据式 (6) 与 (7) 更新种群位

置,集合 L_{cpi} 最大化原则更新个体历史最优解和群体历史最优解。

6) 确定最优参数。重复步骤 3) ~ 5), 当迭代次数超过设定值 $T_{\max}$ 时,循环终止,此时系统 L_{cpi} 最大值对应的粒子位置,即为 RSD 最优 Q_H 与 Q_L 。

7) 循环脉冲谱计算。采用最优 Q_H, Q_L 进行 RSD 分解,提取低共振分量。变换不同的频率值,根据式 (8) ~ (10) 对低共振分量进行脉冲循环谱分析,参照轴承理论故障频率进行轴承故障辨识。

5 仿真分析

5.1 复合故障信号仿真

为了验证本文方法的有效性与优势性,采用基于优化 RSD 的脉冲循环谱方法,对脉冲干扰情况下的轴承复合故障仿真信号进行分析。滚动轴承元件发生复合局部损伤时传感器拾取到的振动信号的数学模型可表示为:

$$x_1(t) = \exp(-900t_1) \cdot \cos(2\pi f_1 t) + \exp(-700t_2) \cdot \cos(2\pi f_1 t) + 0.25\sin(2\pi f_2 t) + 0.4\sin(2\pi f_3 t) + r(t) \quad (12)$$

式中: $t_i = \text{bmod}(k, f_s/f_{mi})/f_s, k = 0, 1, \dots, N-1; \text{bmod}(\cdot)$ 表示取余数,采样点数 N 为 2 048; 信号的采样频率 f_s 为 12 kHz; $f_1 = 3\,500$ Hz 为轴承系统固有频率;滚动轴承的故障频率为 $f_{m1} = 100$ Hz, $f_{m2} = 150$ Hz; 干扰谐波分量频率为 $f_2 = 350$ Hz, $f_3 = 500$ Hz; $r(t)$ 为高斯白噪声,信噪比为 -6 dB。由于动车轴承运行环境的特殊性,轴承在运行过程可能受到非周期性的脉冲 $M(t)$ 的干扰,式 (12) 中的仿真信号可以转换为:

$$x_2(t) = x_1(t) + M(t) \quad (13)$$

5.2 强脉冲干扰对周期性故障脉冲的影响

仿真信号 $x_1(t)$ 与 $x_2(t)$ 的时域波形与快速谱峭度谱如图 2 所示。如图 2(a) 所示,周期性故障脉冲在强噪声的干扰情况下完全淹没在噪声中,但通过谱峭度法基本可确定脉冲共振频带中心频率 $f_c = 3\,500$ Hz,带宽 $B_w = 1\,000$ Hz,如图 2(c) 所示。图 2(b) 中 $x_2(t)$ 信号对比图 2(a) 中的 $x_1(t)$ 加入了随机干扰脉冲分量,其最大峭度对应的频带中心为 $f_c = 3\,375$ Hz,带宽 $B_w = 750$ Hz,表明脉冲干扰会导致故障冲击共振频带的迁移与误判,如图 2(d) 所示。在图 2(c) ~ (d) 基础上,采用最大峭度滤波提取出共振频带信号并进行解调分析,结果分别如图 2(e) ~ (f) 所示。图 2(e) 中故障频率 100 与 150 Hz 及其倍频都清晰可见,但图 2(f) 中只能识别出 76 与 152 Hz,这主要是由于强脉冲干扰,造成故障脉冲共振频带的误判,使得识别出的故障频率产生了较大的偏差。




图2 仿真信号时域图与谱峭度图

Fig. 2 Time domain and spectral kurtosis graph of simulated signal

5.3 RSD 的 MSPSO 优化

针对上述问题,采用 CPI 最大化的 MSPSO 算法对脉冲干扰情况下的轴承故障仿真信号进行 RSD 分解。MSPSO 优化算法中,本文设置种群规模 $N = 20$ 、粒子维数 $D = 2$ 、最大迭代次数 $T_{\max} = 150$ 、RSD 中 Q_H 与 Q_L 的寻优范围分别为 $[1, 10]$ 和 $[1, 30]$,在设定的寻优范围内随机初始化种群的初代位置,寻优结果如图 3(a)所示。可见,MSPSO 算法在每次迭代中指标 L_{cpi} 上升速度较快,能快速达到收敛,其平均迭代次数 23 次,收敛处的平均 L_{cpi} 为 0.002 5,最终得到的最优参数为高品质因子 $Q_H = 19.002$,低品质因子 $Q_L = 4.013$ 。为验证 MSPSO 算法在 RSD 参数的寻优中的优势性,分别采用遗传算法 (genetic algorithm, GA)^[20]、蚁群算法 (ant colony optimization, ACO)^[21] 及传统简化粒子群优化算法 (SPSO) 对 RSD 的 Q_H 与 Q_L 进行优化,每种优化算法分别单独运行 20 次,得到的寻优迭代带状图如图 3 所示。通过图 3 各子图的比较可知,MSPSO 相较于其他 3 种优化算法收敛速度更快,稳定性更好,收敛处的 L_{cpi} 值明显高于其他 3 种算法,

能够实现更有效的低频共振分量提取。在 64 位操作系统上搭建 Tensorflow 2.0 编程环境,CPU i7 9700,16 GB 内存的硬件环境下,MSPSO 运行迭代至收敛的计算耗时为 369 s,而 GA,ACO,SPSO 的计算耗时分别为 MSPSO 的 3.5 倍、2.5 倍与 2.0 倍。尽管 MSPSO 采用了惯性权重重的自适应调整策略,大幅降低粒子寻优时间,但由于 CPI 自适应度函数的计算需要确定各个故障频率处的脉冲循环度,造成其计算量增加,但仍在工程应用的可接受范围内。




图3 4种优化算法的寻优结果

Fig. 3 Optimization results of four optimization algorithms

5.4 CPI 最大化的循环脉冲谱

采用 MSPSO 优化后的 RSD 对 $x_2(t)$ 分解,得到图 4(a)中的低共振分量与图 4(b)中的高共振分量。对图 4(a)中提取的低共振分量进行平方预处理,使时域波形转化为具有能量特征的脉冲序列,再根据式(8)~(10)计算每个频率下的 CPI,最后得到如图 4(c)所示的循环脉冲谱。图 4(c)的循环脉冲谱中,仿真信号的两个故障频率(100 与 150 Hz)及其倍频谱线非常突出,完全与故障频率理论值吻合,且受周围谱线干扰小。同时采用 Hilbert 包络解调法对图 4(a)中的低频共振分量进行分析,结果如图 4(d)所示。可见,在优化 RSD 得到的 Hilbert 解调谱中,也能够准确地检测出故障频率 f_{m1} 及其倍频,故障频率 f_{m2} 非常接近 152 Hz 频率,基本可诊断出复合故障。对比图 4(c)与(d)可知,MSPSO 优化的 RSD 能更加准确地提取周期性的故障脉冲共振频带,有助于提高 Hilbert 包络解调确定故障频率的准确性;且在同等条件下,本文提出的循环脉冲谱比传统解调谱能更准确地检测出轴承的复合故障频率。




图 4 $x_2(t)$ 优化 RSD 分量及其分析结果

Fig. 4 Optimized RSD of $x^2(t)$ and its analysis results

6 在动车轴箱轴承故障诊断中的应用

6.1 轴箱轴承故障试验

整车重载试验过程在整车滚动综合性能试验台上完成,该试验平台可以容纳一节完整的列车,列车的前后装有反力装置,该装置可以让列车在试验过程中保持在相同的位置上,列车的侧面装有可以提供横向作用力的装置,该装置能够模拟侧向风力使列车车体偏移 5 mm。列车的 60 T 的自重会使车轮和驱动轮始终保持接触状态并且不会打滑。图 5(a) 为列车底部试验台的结构示意图,图 5(b) 给出了轴承的位置分布及对应的编号,试验轴箱轴承的类型为双列圆锥滚子轴承 CRI-2692,其节圆直径为 183.929 mm,滚子个数为 19,滚子直径为 26 mm,接触角为 10° 。两个加速度传感器分别布置在轴箱竖直方向和水平方向的位置,使用 NI InsightCM 系统进行数据采集管理和文件管理,采样频率为 20 000 Hz。试验中共存在 2 种工况,通过驱动轮驱动车轮的转速分别至 1 233 RPM、1 539.5 RPM,列车的速度将分别达到 200 km/h、250 km/h。在不同的时速下保持列车稳定运行 120 s,为保证采集到的加速度信号的有效性,截取其中车速波动最稳定的时间段进行分析。

6.2 200 km/h 的轴承信号分析

选取车速为 200 km/h 工况下的 2 号轴承为研究对象,该轴承外圈存在剥落且滚柱上由于剥落碎片的挤压产生了较深的凹痕。通过车轮竖直方向上传感器采集的 0.1 s 振动信号如图 6(a) 所示,其 Hilbert 包络谱




图 5 整车滚动综合性能试验台

Fig. 5 Complete vehicle rolling comprehensive performance test bench

如图 6(b) 所示。图 6(b) 中 Hilbert 包络解调谱中,频率 166 与 498 Hz 处幅值突出,与轴箱轴承外圈理论故障频率 168.05 Hz 及其倍频基本相符,而滚动体理论故障频率 71.26 Hz 及其倍频不够明显,无法识别滚动体故障。




图 6 复合故障轴承信号

Fig. 6 Compound fault bearing signal

以式(11)中的故障频率处的 CPI 增益作为 MSPSO 的适应度函数,对 RSD 进行优化,结果如图 7 所示。由图 7(a) 可知 MSPSO 算法迭代 54 次之后就开始收敛,得

到的最优参数分别为 $Q_H = 10.072$, $Q_L = 1.302$ 。图 7(b) 中的不同 Q_H 与 Q_L 取值处的 L_{cpi} 值可以看出, MSPSO 优化后的低共振频带具有最大 CPI。采用最优 RSD 得到如图 7(c) ~ (d) 所示的高共振分量与低共振分量。




图7 试验信号优化 RSD

Fig. 7 Test signal optimization RSD

将所得的低共振分量进行平方预处理,对所得的能量脉冲序列进行各个频率下的 CPI 计算,得到图 8(a) 所示的循环脉冲谱。图 8(a) 中频率 72 Hz 与 168 Hz 非常突出,与外圈故障、滚动体故障频率理论值 (168.05, 71.26 Hz) 几乎完全相符,可以准确地辨识出外圈故障与滚动体故障,并且循环脉冲谱除理论故障频率及其倍频处有显著突起外周围无其他解调频率的干扰。同样,采用 Hilbert 包络解调法对图 7(d) 中的低频共振分量进行解调分析,得到如图 8(b) 中的解调谱。尽管图 8(b) 中 78 与 166 Hz 分别与轴箱轴承滚动体故障频率理论值 (71.26 Hz) 与外圈故障频率理论值 (168.05 Hz) 比较接近,但故障频率检测的准确性逊色于图 8(a) 中的循环脉冲谱。图 8(c) 为 SPSO 优化 RSD 后的循环脉冲谱,图中谱峰 166 Hz 接近于外圈故障频率理论值,但无法识别出滚动体故障频率。图 8(d) 为人工蜂群优化 RSD 后的循环脉冲谱,图中尽管外圈故障频率突出,74 Hz 接近于滚动体故障频率,但频率偏差大于 MSPSO 算法。这说明, MSPSO 优化的 RSD 的不仅能更快速地提取出周期故障脉冲所在的低共振分量,在此基础上建立的循环脉冲谱能更全面准确地识别出 2 号轴承外圈与滚动体的复合故障。




图8 试验信号低共振分量分析结果

Fig. 8 Analyzed result of low resonance component of experimental signal

6.3 250 km/h 的轴承信号分析

由于列车在高速运行时对故障特征有掩蔽效应,增加了故障诊断的难度,为了验证所提方法在高速运行工况下复合故障检测中的优越性,采用运行速度为 250 km/h 的 4 号轴承为研究对象,该轴承故障类型为外圈裂纹和滚动体磨损。在该工况环境下,轴承外圈故障、内圈故障与滚动体故障所对应的故障频率理论值分别为 209.82, 277.69 和 88.97 Hz。为了进行比较,图 9(a) ~ (c) 分别给出故障信号最大谱峭度包络谱、传统稀疏共振解调谱及未经优化的 RSD 循环脉冲谱。图 9(a) 和 10(b) 中与轴承外圈理论故障频率 209.82 Hz 接近的频率谱线 (206 与 210 Hz) 及其倍频非常突出,但滚动体理论故障频率 88.97 Hz 及其倍频无法识别。图 9(c) 中,较易识别出外圈理论故障频率及其 2 倍频和 3 倍频,尽管 162 Hz 谱线与滚动体故障频率的 2 倍频比较接近,但幅值并不突出,因此无法有效地对滚动体故障进行辨识。采用 MSPSO 对 RSD 的参数进行优化,算法迭代 27 次之后收敛,得到品质因子寻优参数分别为 $Q_H = 6.3676$, $Q_L = 1.100$ 。对优化 RSD 得到的低频共振分量进行循环脉冲谱分析,结果如图 9(d)。在该循环脉冲谱中,在频率 210 Hz 及其二倍频 419 Hz 和三倍频 626 Hz 处,循环脉冲度非常突出,与轴承外圈故障的理论值 209.82 Hz 及相应倍频几乎完全相符。在图 9(d) 中 89 Hz 及其 2 倍频 166 Hz 与 3 倍频 266 Hz 处循环脉冲度非常突出,与轴承滚动体故障的理论值 88.97 Hz 及其相应倍频成分相吻

合,可确定高速轴箱轴承同时出现了外圈与滚动体的复合故障。




图9 运行速度为250 km/h时的轴承故障信号分析结果

Fig.9 Bearing fault signal at running speed 250 km/h

7 结 论

针对强噪声干扰下故障冲击伪循环特性、最优频段选择困难、脉冲形态各异等问题,在充分考虑故障冲击的脉冲性与周期性的基础上,提出了基于循环脉冲谱与共振稀疏分解的轴承故障诊断方法,得出如下结论:

1) 引入了 MSPSO 优化算法对 RSD 的品质因子进行优化选择,采用多尺度惯性权重对粒子位置进行更新迭代,考虑同代粒子之间的差异性,充分发挥了粒子局部寻优能力与全局寻优能力。

2) 提出了故障信号的循环脉冲谱分析方法,充分利用了故障冲击的脉冲性与周期性,能够对强干扰环境下的轴承故障频率进行准确提取,对故障脉冲的类型与非周期性的脉冲干扰或信号奇异点具有较好的鲁棒性。

3) 结合 MSPSO 优化算法,以故障频率处的 CPI 增益作为适应度函数,对复合故障仿真信号与高铁轴承实测复合故障信号进行了最优 RSD 分解,并对提取出的低频共振分量进行了循环脉冲谱分析,实现复合故障的准确辨识。

但要指出的是,由于本文的循环脉冲谱的实现需要对全频域内的各频率 CPI 进行逐一计算,导致整个故障诊断算法的计算负荷较大。论文下一步研究工作拟通过优化 CPI 计算的扫频范围与振动信号降采样方法来提升算法的计算效率,拟通过在不同类型轴承复合故障诊断应用实例以增强本文方法的泛化能力,进而提高该方法的实际工程应用价值。

参考文献

- [1] 宋志坤,徐立成,胡晓依,等. 基于改进型 shapelets 算法的动车组轴箱轴承故障诊断方法研究[J]. 仪器仪表学报, 2021, 42(2): 66-74.
SONG ZH K, XU L CH, HU X Y, et al. Research on fault diagnosis method of axle box bearing of EMU based on improved shapelets algorithm[J]. Chinese Journal of Scientific Instrument, 2021, 42(2): 66-74.
- [2] 张文颢. 基于稀疏表示的高速列车轴箱轴承故障诊断研究[D]. 成都:西南交通大学, 2018.
ZHANG W H. Research on fault diagnosis of high-speed train axle box bearing based on sparse representation [D]. Chengdu: Southwest Jiaotong University, 2018.
- [3] LI Y, SONG H, MIAO B, et al. Improved multiscale weighted-dispersion entropy and its application in fault diagnosis of train bearing[J]. Measurement Science and Technology, 2021, 32(7): 075002.
- [4] XIONG Q, ZHANG W, XU Y, et al. Diagnosing axle box bearings' fault using a refined phase difference correction method[J]. Journal of Mechanical Science and Technology, 2019, 33(1): 95-108.
- [5] WANG X CH, LU ZH G, WEI J Y, et al. Fault diagnosis for rail vehicle axle-box bearings based on energy feature reconstruction and composite multiscale permutation entropy [J]. Entropy, 2019, 21(9): 112-124.
- [6] CHENG Y, CHEN B, ZHANG W. Adaptive multipoint optimal minimum entropy deconvolution adjusted and application to fault diagnosis of rolling element bearings[J]. IEEE Sensors Journal, 2019, 19: 12153-12164.
- [7] 黄衍. 基于变分模态分解与形态学滤波的高速列车轴箱轴承故障诊断方法研究[D]. 成都:西南交通大学, 2020.
HUANG Y. Research on fault diagnosis method of high-speed train axle box bearing based on variational modal decomposition and morphological filtering [D]. Chengdu: Southwest Jiaotong University, 2020.
- [8] 乔宁国. 基于多传感器数据融合的高速列车传动系统故障诊断与健康状态预测[D]. 长春:吉林大学, 2019.
QIAO N G. High-speed train transmission system fault diagnosis and health prediction based on multi-sensor data fusion [D]. Changchun: Jilin University, 2019.
- [9] 唐贵基,王晓龙. 自适应最大相关峭度解卷积方法及其在轴承早期故障诊断中的应用[J]. 中国电机工程学报, 2015, 35(6): 1436-1444.

- TANG G J, WANG X L. Adaptive maximum correlation kurtosis deconvolution method and its application in bearing early fault diagnosis [J]. Chinese Journal of Electrical Engineering, 2015, 35 (6): 1436-1444.
- [10] 刘泽锐,邢济收,王红军,等. 基于VMD与快速谱峭度的滚动轴承故障诊断[J]. 电子测量与仪器学报, 2021, 35(2): 73-79.
- LIU Z R, XING J H, WANG H J, et al. Fault diagnosis of rolling bearing based on VMD and fast spectral kurtosis [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 73-79.
- [11] 唐贵基,王晓龙. 可调品质因子小波变换在滚动轴承微弱故障特征提取中的应用[J]. 中国电机工程学报, 2016, 36(3): 746-754.
- TANG G J, WANG X L. Application of adjustable quality factor wavelet transform in weak fault feature extraction of rolling bearing [J]. Chinese Journal of Electrical Engineering, 2016, 36 (3): 746-754.
- [12] CHAI N, YANG M, NI Q, et al. Gear fault diagnosis based on dual parameter optimized resonance-based sparse signal decomposition of motor current [J]. IEEE Transactions on Industry Applications, 2018, 54: 3782-3792.
- [13] CHEN B, SHEN B, CHEN F, et al. Fault diagnosis method based on integration of RSSD and wavelet transform to rolling bearing [J]. Measurement, 2018, 131: 400-411.
- [14] WANG C, LI H, OU J, et al. Identification of planetary gearbox weak compound fault based on parallel dual-parameter optimized resonance sparse decomposition and improved MOMEDA [J]. Measurement, 2020, 165: 108079.
- [15] 况增平,佟庆彬,杜婧,等. 蛙跳算法优化品质因子的共振稀疏分解方法[J]. 机械传动, 2020, 44(11): 34-40.
- KUANG Z P, TONG Q B, DU J, et al. Resonance sparse decomposition method for optimization of quality factor by leapfrog algorithm [J]. Mechanical Transmission, 2020, 44(11): 34-40.
- [16] 黄晨光. 基于奇异值特征提取的高速列车轴箱轴承故障诊断方法研究[D]. 成都:西南交通大学, 2019.
- HUANG CH G. Research on fault diagnosis method of high-speed train axle box bearing based on singular value feature extraction [D]. Chengdu: Southwest Jiaotong University, 2019.
- [17] SELESNICK I W. Resonance-based signal decomposition: A new sparsity-enabled signal analysis method[J]. Signal Processing, 2011, 91(12): 2793-2809.
- [18] 柏林,闫康,刘小峰. 基于状态追踪特征相空间重构的轴承寿命预测方法[J]. 振动与冲击, 2019, 38(23): 119-125.
- BO L, YAN K, LIU X F. Bearing life prediction method based on phase space reconstruction of state tracking characteristics [J]. Journal of Vibration and Shock, 2019, 38(23): 119-125.
- [19] SHI Y, EBERHART R C. Parameter selection in particle swarm optimization [C]. International Conference on Evolutionary Programming, 1998: 591-600.
- [20] KWON Y C, KANG S, CHOI Y S, et al. Evolutionary design of molecules based on deep learning and a genetic algorithm [J]. Scientific Reports, 2021, 11(1): 17304.
- [21] ZHANG Y P, CHEN X, LV D J, et al. Optimization of urban heat effect mitigation based on multi-type ant colony algorithm [J]. Applied Soft Computing Journal, 2021, 112: 107758.


作者简介



刘小峰(通信作者), 2002年于重庆大学获得学士学位, 2007年于重庆大学获得博士学位, 现为重庆大学教授、博士生导师。主要研究方向为工程信号处理、设备监测与故障诊断, 智能测试与仪器。

E-mail: liuxfeng0080@126.com

Liu Xiaofeng (Corresponding author) received his B.Sc. degree from Chongqing University in 2002. She received his Ph.D. degree from Chongqing University in 2007. She is now a professor and a Ph.D. advisor at Chongqing University. Her main research interests include engineering signal processing, equipment monitoring and fault diagnosis, intelligent testing and instruments.



黄洪升, 2020年于沈阳工业大学获得学士学位, 现为重庆大学硕士研究生, 主要研究方向为工程信号处理, 机械非平稳信号处理。

E-mail: huanghs1218@163.com

Huang Hongsheng received his B.Sc. degree from Shenyang University of Technology in 2020. He is currently a master student at Chongqing University. His main research interests include engineering signal processing, mechanical non-stationary signal processing.