

doi:10.12068/j.issn.1005-3026.2025.20240087

参数寻优自适应重构特征的高压辊磨机 运行故障诊断

孙洪硕^{1,2}, 张丹威¹, 徐泉¹, 柴天佑^{1,3}

(1. 东北大学 流程工业综合自动化全国重点实验室, 辽宁 沈阳 110819; 2. 酒泉钢铁(集团)有限责任公司, 甘肃 嘉峪关 735100; 3. 东北大学 国家冶金自动化工程技术研究中心, 辽宁 沈阳 110819)

摘要: 高压辊磨机的运行环境复杂且信号易受到噪声污染, 针对传统算法难以有效提取高压辊磨机故障特征以及随机共振系统参数选取困难的问题, 提出了一种基于参数寻优自适应重构特征的高压辊磨机运行故障诊断方法. 首先, 采用集合经验模态分解(ensemble empirical mode decomposition, EEMD)算法将高压辊磨机振动信号分解成若干个本征模态函数(intrinsic mode function, IMF)分量; 其次, 结合相关系数与互信息构建混合判别准则, 自适应地筛选出异常运行特征最强的分量信号进行重构; 在此基础上, 引入具有种群概率突变机制的樽海鞘群算法(salp swarm algorithm, SSA), 构建自适应的随机共振(stochastic resonance, SR)参数寻优策略; 最后, 提出基于自适应选取分量重构信号的高压辊磨机运行故障诊断方法. 仿真实验结果表明了所提方法的有效性.

关键词: 故障诊断; 集合经验模态分解; 樽海鞘群算法; 随机共振; 自适应策略

中图分类号: TD 50; TP 181 **文献标志码:** A **文章编号:** 1005-3026(2025)11-0001-11

Operation Fault Diagnosis of High-Pressure Grinding Roll Using Adaptive Reconstruction Features with Parameter Optimization

SUN Hong-shuo^{1,2}, ZHANG Dan-wei¹, XU Quan¹, CHAI Tian-you^{1,3}

(1. State Key Laboratory of Synthetical Automation for Process Industries, Northeastern University, Shenyang 110819, China; 2. Jiuquan Iron and Steel (Group) Co., Ltd., Jiayuguan 735100, China; 3. National Engineering Research Center of Metallurgy Automation, Northeastern University, Shenyang 110819, China. Corresponding author: CHAI Tian-you, E-mail: tychai@mail.neu.edu.cn)

Abstract: The operating environment of the high-pressure grinding roll is complicated, and the signal is easily polluted by noise. Traditional algorithms find it difficult to extract the fault characteristics of high-pressure grinding rolls effectively and select the parameters of the stochastic resonance system. To address these issues, an operation fault diagnosis method of high-pressure grinding roll based on adaptive reconstruction features with parameter optimization was proposed. First, the ensemble empirical mode decomposition (EEMD) method was employed to decompose the high-pressure grinding roll's vibration signal into several intrinsic mode function (IMF) components. Secondly, the mixed criterion of correlation coefficient and mutual information was used to adaptively screen the component signals with the strongest abnormal operation characteristics and reconstruct them. Then, the salp swarm algorithm (SSA) was introduced to build the adaptive stochastic resonance (SR) parameter optimization mechanism by combining the population probabilistic mutation mechanism. Finally, an operation fault diagnosis algorithm of high-pressure grinding roll based on an adaptively selected component reconstruction signal was proposed. Simulation results verify the effectiveness of the proposed

收稿日期: 2024-04-15

基金项目: 中央高校基本科研业务费专项资金资助项目(N2324003-05).

作者简介: 孙洪硕(1986—), 男, 河南封丘人, 东北大学博士研究生; 柴天佑(1947—), 男, 甘肃兰州人, 东北大学教授, 博士生导师, 中国工程院院士.

method.

Key words: fault diagnosis; ensemble empirical mode decomposition; salp swarm algorithm; stochastic resonance; adaptive strategy

在传统故障诊断方法中,通常通过消除振动信号噪声与利用噪声能量来增强特征信号能量和信噪比的方法提取故障特征.其中降噪方法主要包括奇异值分解(singular value decomposition, SVD)^[1]、经验模态分解(empirical mode decomposition, EMD)^[2]、局域均值分解^[3]和小波分析等.然而,传统EMD方法在特征分解过程中易发生混频现象.针对该问题,文献[4]提出了集合经验模态分解(EEMD)算法,该算法是在EMD算法的基础上为解决其在分解过程中容易发生混频现象而提出的一种针对非线性、非平稳信号的噪声辅助数据处理方法^[4],并受到学术界与工业界的广泛关注^[5-6].但是降噪方法在提取特征的过程中会对有用的故障特征信号进行削弱,且降噪得到的分量信号选取一般通过人工经验进行选择,导致在选择过程中存在不确定性.

利用噪声能量增强特征信号能量和信噪比的故障特征提取方法主要是随机共振法.随机共振由 Benzi 等^[7]在研究古气象冰川问题时提出的,其利用一定量的噪声能量增强系统的输出量.在非线性系统中,随机共振的基本原理在于利用噪声对微弱信号的协同与增强作用,从而提高信号的能量并改善其可检测性.当引入适当强度的噪声时,系统在微弱特征信号驱动下的输出信噪比可达到最优值^[8].随着研究的深入,随机共振技术已从最初适用于小幅值、低频率及弱噪声条件下的信号检测^[9-11],发展到通过自适应随机共振方法实现对大参数信号的检测^[12].然而,随机共振在借助噪声能量增强有用特征信号时,其效果受到系统参数的显著制约.由于缺乏有效的参数自适应选取机制,往往难以实现理想的共振状态,从而限制了噪声能量的充分利用.

高压辊磨机是选矿行业铁矿生产破碎工序的关键设备,其破碎效果直接影响后续磨选工序的精矿品位.由于生产工序的原料波动、强干扰等引入的综合复杂性和设备自身振动的影响,导致其运行过程中故障频发,直接影响了整个磨矿工序的运行质量.文献[13]通过力学机理完成了对高压辊磨机的磨损和柱钉断裂故障分析,但是针对不同破碎原料情况下的辊磨机故障无法给出通用的诊断方法.文献[14]通过构建高压辊磨

机生产模型完成了对高压辊磨机生产过程中的磨损分析,但是无法针对特定的生产状态完成对辊磨机关键部件的故障进行有效诊断,且上述通过构建模型方法来完成辊磨机故障诊断在建立时无法完全适应实际生产过程不同生产状态下的设备运行状态.因此,通过采用数据驱动的方法完成对高压辊磨机运行状态监测和故障诊断,对提高破碎工序生产效率以及对后续磨选的工作性能的提升具有重要的实际价值.为此,本文提出了一种基于参数寻优自适应重构特征的高压辊磨机运行故障诊断方法.首先利用EEMD算法对原始某钢铁选矿厂高压辊磨机振动信号进行分解,得到一系列本征模态函数(IMF);为准确筛选IMF分量,对不同IMF分量进行相关性分析,同时结合时域信号特点对IMF分量再次进行互相关分析,构造相关系数与互相关系数自适应判别机制;再自适应地选取异常运行特征最强的信号分量进行重构;然后将重构得到的信号输入到随机共振系统中,利用高斯-柯西种群概率突变机制的樽海鞘群算法(SSA)对参数进行自适应优化.在此基础上,提出基于自适应选取特征分量并对筛选出来的特征进行重构的方法,并最终实现对高压辊磨机运行过程的故障诊断.利用实际钢铁选矿厂高压辊磨机振动信号进行实验验证.

1 基于参数寻优自适应重构特征的故障诊断方法

1.1 集合经验模态分解(EEMD)

由于传统EMD在分解过程中产生的IMF分量存在严重的模态混叠现象^[15],且在单个IMF中混杂了不同时间尺度的特征,导致无法有效提取信号中的故障特征.由于EMD分解过程需要经过多次迭代才能得到最优的目标分量,随着迭代次数的增加,导致在分解过程中无法自适应地对整个信号进行迭代分解,且分解过程中得到的IMF分量个数直接与迭代次数相关.为解决这一问题,提出了集合经验模态分解(EEMD)算法,即在传统EMD分解过程中加入均值为0的高斯白噪声进行辅助分析.利用白噪声频谱的均匀分布特性,当信号加在遍布整个时频空间且分布一致

在白噪声背景上时,不同时间尺度的信号会分布到合适的参考尺度上.由于零均值噪声的特性,多次平均后噪声会相互抵消,从而可将集成均值的结果作为最终结果^[16-17].

1.1.1 EEMD分解原理

EEMD算法的具体分解过程如下^[16]:

步骤 1 设定一个总体平均次数 Q , 假设有原始信号 $X(t)$, 将每次随机生成均值为 0、服从标准正态分布的高斯白噪声 $W_i(t)$ 加入到原始信号, 得到混杂高斯噪声的信号 $X'(t)$, 如式(1)所示:

$$X'(t) = X(t) + W_i(t). \quad (1)$$

式中: t 为时间; $W_i(t)$ 表示第 i 次加入的噪声序列, 且 $i = 1, 2, \dots, Q$.

步骤 2 将混杂高斯噪声的信号 $X'(t)$ 进行 EMD 分解, 得到各阶 IMF 分量和最终的剩余分量 $r_n(t)$, 如式(2)所示:

$$X'(t) = \sum_{j=1}^n \text{IMF}_{i,j}(t) + r_n(t). \quad (2)$$

式中: $\text{IMF}_{i,j}(t)$ 为第 i 次加入噪声序列后分解得到的第 j 个 IMF 分量; $r_n(t)$ 为残差余项, 代表最终信号的平均趋势; n 是最终分解得到的残差余项个数; j 为分解得到的 IMF 分量个数.

步骤 3 改变每次加入的高斯白噪声序列幅值, 重复步骤 1 和步骤 2, 得到最终分解的分量集合:

$$\text{IMF}_{i,j}(t) = \{\text{IMF}_{1,j}(t), \text{IMF}_{2,j}(t), \dots, \text{IMF}_{Q,j}(t)\}. \quad (3)$$

步骤 4 根据不相关序列均值为 0 的原理, 对式(3)所示分量进行集合平均, 即

$$\text{IMF}_j(t) = \frac{1}{Q} \sum_{i=1}^Q \text{IMF}_{i,j}(t). \quad (4)$$

其中, $\text{IMF}_j(t)$ 为最终分解得到的 IMF 分量.

1.1.2 IMF 分量自适应筛选策略

相关系数 (correlation coefficient, CC)^[18] 是衡量两个向量之间线性相关性的指标, 当向量间的相似程度较高时, 其相关性就越大, 反之亦然^[19]. 根据式(3)所得的 IMF 分量集合, 其相关系数 CC 的计算公式如下:

$$\text{CC} = \frac{\sum_{i=1}^m (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^m (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^m (Y_i - \bar{Y})^2}}. \quad (5)$$

式中: X_i, Y_i 分别为两个信号向量; m 为两个向量的采样点数; \bar{X} 和 \bar{Y} 分别为 X_i 和 Y_i 的均值.

在概率论和信息论中, 互信息 (mutual information, MI)^[20] 可以反映时间序列分解过程中维数改变时不同变量之间的相互依赖程度. 其计算公式如下:

$$\text{MI} = \sum \sum p(X, Y) \lg \left(\frac{p(X, Y)}{p(X)p(Y)} \right). \quad (6)$$

式中: $p(X, Y)$ 为两个向量的联合概率分布函数; $p(X)$ 和 $p(Y)$ 分别为两个向量的边缘概率分布函数. 一般情况下, 相关系数只反映不同向量之间的线性相关性, 而基于概率分布的互信息则更多地表示不同变量之间的非线性相关性. 因此, 建立基于相关系数和互信息联合判别机制的 IMF 分量筛选机制, 判别准则指数 $R(p)$ 计算公式如下:

$$R(p) = \gamma \times \text{CC} + (1 - \gamma) \times \text{MI}. \quad (7)$$

式中: γ 为取值 0 到 1 之间的任意数, 根据最终分解层数设定. 最终根据联合判别机制筛选出的分量信号进行重构.

1.2 随机共振参数自适应优化策略

随机共振 (stochastic resonance, SR) 是包含非线性处理单元、输入和输出的非线性双稳系统模型, 其中输入包含原始信号和噪声, 经过非线性信号处理单元后得到最终的输出信号^[21]. 在双稳系统中, 非线性处理单元可以由一个郎之万方程进行描述:

$$\frac{dx}{dt} = ax(t) - bx^3(t) + S(t) + N(t). \quad (8)$$

式中: $x(t)$ 为输入信号; 参数 a 和 b 为大于 0 的非线性双稳系统结构参数; $S(t)$ 为单频正弦信号, 满足 $S(t) = A \cos(2\pi f_0 t)$, A 为输入信号的幅值, f_0 为原始频率; $N(t)$ 为高斯白噪声, 满足 $N(t) = \sqrt{2D} w(t)$, D 为输入噪声强度, $w(t)$ 为均值为 0 的白噪声. 双稳系统的势函数 $U(x)$ 为

$$U(x) = -\frac{1}{2} ax^2 + \frac{1}{4} bx^4. \quad (9)$$

上述高斯白噪声 $N(t)$ 满足:

$$E[N(t)] = 0, E[N(t)N(t-\tau)] = 2D\delta(t). \quad (10)$$

式中: $E[\cdot]$ 为噪声期望; τ 为时间间隔; 噪声满足 $\delta(t)$ 大小的冲击函数. 综上所述, 双稳系统势垒高度为 $\Delta U = a^2/4b$, 因此当信号比较微弱时, 微弱的信号能量无法诱导粒子跃过当前双稳系统势垒高度, 导致其只能在阱内发生振荡运动; 由于噪声能量的输入增强了微弱信号的能量, 利用一部分噪声能量弥补微弱信号能量, 此时信号便可以突破势垒高度的限制, 进而在双稳系统之间进行跃迁运动, 最终使系统达到良好的随机共振效果.

由式(8)和式(9)可知,参数 a 和 b 的选择对随机共振系统能否产生较好的共振效果至关重要.文献[21]利用蚁群算法完成了对随机共振参数的寻优,虽然优化结果参数可以使随机共振在一定程度上达到共振效果,但是蚁群信息素选择无法有效确定.文献[22]利用粒子群(particle swarm optimization, PSO)算法对随机共振参数进行寻优,但是搜索过程中由于种群多样性的限制导致其寻优困难.樽海鞘群算法^[23]是利用海洋生物樽海鞘觅食行为演变而来的优化算法,为了避免其在迭代过程中陷入局部最优解和无法搜索到全局最优解的问题,选择利用基于高斯-柯西种群概率突变机制增加其种群多样性.故采用基于高斯-柯西种群概率突变机制的樽海鞘群算法确定参数 a 和 b ,同时以信噪比(signal noise rate, SNR)^[24]函数作为樽海鞘群算法的目标函数,用来表征双稳系统对目标信号的判别能力.信噪比是衡量信号质量的一个重要指标,它表示信号功率与噪声功率的比值.信噪比越大,信号中的噪声成分越少,信号质量越高,因此利用寻优算法对信噪比函数中的参数进行寻优以得到较大的信噪比.传统目标 SNR 函数为

$$\text{SNR} = 10 \lg \frac{2|\mathbf{X}(t_0)|}{\sum |\mathbf{X}(t)|^2 - 2|\mathbf{X}(t_0)|^2}. \quad (11)$$

式中: $\mathbf{X}(t_0)$ 为 t_0 时刻的信号; $\mathbf{X}(t)$ 为 t 时刻的信号.而在小参数条件下,上述目标函数可近似表示为

$$\text{SNR} = \frac{\sqrt{2}(Aa)^2 e^{(-a^2/4bd)}}{(2D)^2 b}. \quad (12)$$

利用寻优算法对参数 a 和 b 进行寻优以得到较大的信噪比.最终的寻优步骤如下:

步骤 1 在有限的上下界空间内初始化樽海鞘群算法的跟随者与领导者位置:

$$L_{q,r} = \text{rand}(N, S) \times (\text{ub}(r) - \text{lb}(r)) + \text{lb}(r). \quad (13)$$

式中: $q \in N, r \in S. N$ 为初始化种群规模, S 为空间维度; ub 和 lb 为搜索上下界.

步骤 2 根据式(12)计算信噪比适应度函数值.

步骤 3 根据步骤 2 计算出的适应度函数值判定算法最佳的食物源位置.

步骤 4 划分樽海鞘群算法的领导者 and 跟随者位置,同时引入高斯-柯西变异概率机制进行更新:

$$L_{q,r}(d) = L_{q,r}(d-1) + (P_{\text{food}}(r) - L_{q,r}(d-1)) \times \text{GC}, \quad (14)$$

$$L_{q,r}(d) = \frac{1}{2}(L_{q,r}(d-1) \times \text{GC} + L_{q-1,r}(d-1)). \quad (15)$$

式中: $L_{q,r}(d)$ 为迭代次数 d 时领导者 q 在 r 维空间的位置; $P_{\text{food}}(r)$ 为食物源在 j 维空间的位置; $L_{q,r}(d-1)$ 和 $L_{q-1,r}(d-1)$ 分别为上一迭代时刻跟随者和上一代跟随者位置; GC 为高斯-柯西变异概率算子.

步骤 5 对领导者和跟随者位置分别作边界处理,根据上述领导者和跟随者位置更新食物源位置.

步骤 6 根据当前输出结果判断是否满足精度要求,若满足则返回步骤 4 继续更新迭代;若达到最大迭代次数,输出相应的结果.

1.3 基于自适应重构特征的随机共振故障诊断方法

EEMD 在分解过程中通过添加噪声消除模态混叠现象,保证分解得到的 IMF 分量信号可以表征原始信号的真实成分.原始故障信号等于所有 IMF 分量的线性相加之和,因此每个 IMF 均与原始故障信号存在一定相关性,利用式(7)的判别方式筛选出与源信号特征最接近的分量信号.由于双稳随机共振系统参数对信号能否跨越势垒高度起决定性作用,人工选取参数存在较大误差会导致双稳系统难以有效产生共振,因此建立以 SNR 为目标函数的双稳系统参数寻优算法.但传统粒子群算法由于种群多样性不足易陷入局部最优解,因此建立基于高斯-柯西种群概率突变机制的樽海鞘群算法,通过概率突变机制增强种群多样性,实现双稳系统参数的自适应优化.基于上述策略构建自适应重构随机共振诊断方法,对筛选的 IMF 分量进行重构后输入双稳系统实现故障诊断.本文故障诊断流程如图 1 所示.

2 实验研究

2.1 仿真实验

为了验证本文所提方法的有效性,采用模拟实际工业过程的含有噪声的仿真信号进行仿真分析.信号幅值为 $0.2 \text{ m} \cdot \text{s}^{-2}$,正弦频率为 0.01 Hz ,加入噪声强度为 10 的高斯白噪声,采样频率为 5 Hz ,样本数为 5 000.对仿真信号的原始波形进行频谱分析和基础的傅里叶变换(如图 2 所示).从原始波形中可以看出,噪声信号将原始数据的有用信息淹没,无法辨识实际信号中的特征频率.进而对原始信号使用 EEMD 进行分解,得到 IMF 分量结果

和残差余项趋势,仿真信号的分解结果如图 3 所示.

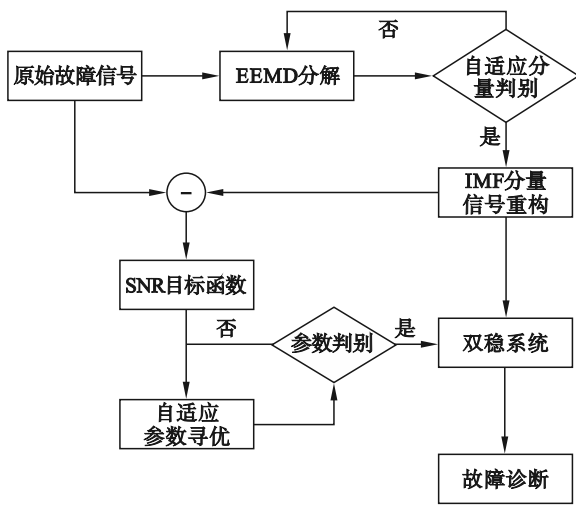


图 1 故障诊断流程图

Fig. 1 Fault diagnosis flowchart

由图 2 可以看出,在图 2a 中原始信号所包含的故障特征被噪声淹没,从原始波形中无法观察到任何异常波形;将原始波形进行初步傅里叶变换,但经过初步变换后的信号波形依然被噪声淹没而无法识别具体的故障特征;经过包络谱分析

后的信号波形也没有显示出任何特征.因此,无论是原始波形还是经过傅里叶变换和包络谱分析后的波形均无法判断出信号的特征频率,说明噪声淹没了原始信号的故障特征.为了有效提取原始信号的故障特征,首先需要将原始振动信号进行 EEMD 分解,并根据分解结果绘制所有 IMF 分量波形图和最终的残差余项,其结果如图 3 所示.





图 2 信号频谱图

Fig. 2 Signal spectrum diagram

(a) —原始波形; (b) —傅里叶变换; (c) —包络谱.







图3 原始仿真信号经过EEMD分解得到的IMF分量图

Fig. 3 IMF component diagram obtained from EEMD of original simulation signal

(a)—IMF1分量;(b)—IMF2分量;(c)—IMF3分量;(d)—IMF4分量;(e)—IMF5分量;(f)—IMF6分量;(g)—IMF7分量;(h)—IMF8分量;(i)—IMF9分量;(j)—IMF10分量;(k)—IMF11分量;(l)—IMF12分量;(m)—残差余项。

由图3可以看出,原始包含噪声分量的仿真信号经过EEMD分解得到了12个IMF分量和1个残差余项.虽然EEMD在分解过程中可以逐步减弱噪声对原始信号的冲击,但由图3可以看出经过EEMD分解之后的分量信号在IMF6~IMF8依然有较强的噪声冲击特征,而IMF1~IMF3更多地保留了原始信号中较丰富的有用信号,但是所包含的有用故障特征依然被淹没在噪声之中.因此,若只考虑重构那些保留原始信号信息较多的分量而忽略了保持故障冲击特征的分量,将导致大量的故障特征信息被忽略且后续的双稳系统无法有效识别出故障特征频率.由于包含故障特征信息的分量与原始数据之间存在一定的相关性,因此将得到的分量信号依据IMF分量根据筛选判别准则进行自适应的判别选择,最终筛选出相关性较高的IMF分量信号进行重构,可以保证重构后的信号能够最大限度地包含故障特征信息.自适应筛选IMF分量的相关性结果如图4所示.

图4 IMF分量信号的判别指数 $R(p)$ Fig. 4 Discriminant index $R(p)$ of IMF component signal

根据图4可以得到各个IMF分量的判别准则指数 $R(p)$ 的大小.将判别指数小于0.3的分量视为包含较少故障特征信息且噪声含量较大的分量,因此选择 $R(p) > 0.3$ 的IMF分量信号进行重构.根据判别准则筛选出的分量信号不仅能保留具有较强原始信号冲击特性的分量,同时可以避免因过多分量信号重构导致噪声强度过强而无

法有效提取原始信号的主导频率特征.因此,根据图4所示剔除第5,9,12这三个IMF分量,将剩余IMF分量进行筛选后重构,并将重构得到的信号作为输入输送至双稳随机共振系统.利用双稳系统完成对应的故障特征识别,最终结果如图5所示.




图5 重构信号经双稳随机共振系统时域波形图和频谱图

Fig. 5 Time-domain waveform and spectrum diagrams of reconstructed signal through bistable stochastic resonance system

(a)—时域波形图;(b)—频谱图.

本文双稳随机共振系统参数 a 和 b 的寻优范围设定为 $[0, 10]$,且樽海鞘群优化算法的初始种群数量设定为30个,算法中的幂系数值设定为2.5,跟随者与领导者更新迭代次数为100.对原始仿真信号进行100次迭代寻优计算得出双稳随机共振系统的参数 $a = 1.7325$,参数 $b = 0.4613$,此时信噪比为21.8769.说明此时的重构信号可以使双稳系统达到较好的共振状态,有效地使噪声信号能量转移到故障特征信号上,更有效地识别出故障特征频率.由图5可以看出,此时重构之后的信号达到了较好的共振效果,由于双稳系统的作用能力将重构信号包含的部分噪声能量转移到特征信号上,图5的频谱图显示仿真信号的特征频率被明显增强.表明所提方法可以有效提取信号的主导特征频率,也验证了所提算法对故障特征提取的有效性.

2.2 高压辊磨机运行故障实验验证

本文针对某铁矿选矿厂磨选工序高压辊磨

机实际运行生产过程,利用实际工业数据进行实验验证本文所提方法的有效性.本文选定 GM150-100 型高压辊磨机作为实验对象,在设备本体及电机等部位安装了 12 个振动信号传感器,具体安装位置见图 6 所示(由于高压辊磨机是对称结构,因此只展示了一侧①~⑥个传感器的安装位置).为避免环境及设备在生产过程中对振动信号传感器造成干扰,在传感器安装过程中选择磁吸与粘接相结合的方式安装.高压辊磨机易发生故障的部件主要有两种:一种是辊面磨损故障,这是由于辊面材料原因导致的;另一种是高压辊磨机液压系统单向阀磨损故障,该故障是由于运行过程中液压系统不稳定或两辊辊缝不等导致的.本文选定单向阀作为具体研究对象.为验证本文所提方法的准确性,在实际工业实验阶段将其与传统方法(如文献[21]利用蚁群算法对随机共振参数进行寻优和文献[22]利用粒子群算法对随机共振参数进行寻优)进行对比,以验证本文方法相对于传统蚁群算法和粒子群算法在参数寻优方面的有效性与准确性.实际工业实验采用高压辊磨机生产过程中发生过负荷工况(由辊缝不均导致单向阀故障)时的高压辊磨机振动信号作为原始信号.

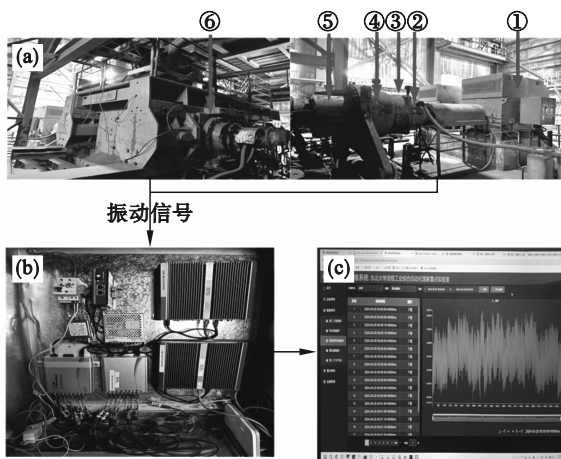


图 6 高压辊磨机振动信号传感器安装位置及采集装置

Fig. 6 Installation position and acquisition device of vibration signal sensor for high-pressure grinding roll

- (a)—现场设备; (b)—振动信号采集卡;
(c)—振动信号存储.

高压辊磨机液压传动系统的单向阀为单体锥形结构,通过往复式运动控制高压辊磨机动辊与定辊的转速及辊缝.整个单向阀可以看作是一个二阶振荡环节,其频率计算公式为

$$f = \frac{1}{2\pi} \sqrt{\frac{K}{M}} \quad (16)$$

式中: M 为单向阀伸缩运动整体等效质量; K 为单向阀伸缩部件刚度.根据单向阀的往复式运动状态,整个伸缩部件刚度可以设定为

$$K = 4\pi^2(2f)^2 M \quad (17)$$

式中: $2f$ 为单向阀正常运行频率.

由于设备在正常工作状态下振动信号的运行波形是在基准频率下稳定波动的,而当设备发生故障时,由于运行不稳,振动信号会受到较强冲击,导致波形产生较大的突变.因此当设备波形超过原始振动信号基准频率时即被判定为故障状态.整个实验过程中的高压辊磨机振动信号采集频率为 2 560 Hz,实验所需的振动信号数据采样点数为 5 000.首先对上述高压辊磨机原始振动信号作相应的频谱分析;同时为了更好地获取原始振动信号的波形特征,分别对其进行了傅里叶变换以及包络谱分析.因此原始振动信号波形图、傅里叶变换波形图和包络谱图结果如图 7 所示.




图 7 高压辊磨机振动信号频谱图

Fig. 7 Spectrum diagram of vibration signal of high-pressure grinding roll

- (a)—原始振动信号波形图; (b)—傅里叶变换波形图;
(c)—包络谱图.

从图 7 中可以看出,高压辊磨机原始信号波形在 0.9 s 时存在较强的冲击特征.结合实际生产过程,现场操作人员反馈此时高压辊磨机动定辊在运行过程中由于矿石堆积,导致在对矿石进行破碎时机械压力过大,高压辊磨机处于过负荷运行状态.同时,在傅里叶变换和包络谱结果中可以看出,原始信号频谱图虽然显示过负荷工况时的振动信号特征频率主要集中在 100 Hz 以内,但由于原始信号受到生产过程噪声以及环境噪声的影响,导致依然难以从变换后的波形图和包络

谱图中识别具体的高压辊磨机过负荷异常的特征主导频率.因此,需要将上述采集的高压辊磨机实际故障信号进行EEMD分解,得到如图8所

示的EEMD分解之后的所有包含残差分量的IMF分量信号波形图.




图8 原始振动信号经过EEMD分解的IMF分量图

Fig. 8 IMF component diagram of original vibration signal after EEMD

(a)—IMF1分量; (b)—IMF2分量; (c)—IMF3分量; (d)—IMF4分量; (e)—IMF5分量; (f)—IMF6分量; (g)—IMF7分量; (h)—IMF8分量; (i)—IMF9分量; (j)—IMF10分量; (k)—IMF11分量; (l)—IMF12分量; (m)—IMF13分量; (n)—残差余项.

由图8可以看出,高压辊磨机异常信号经过EEMD分解得到了13个IMF分量信号和1个残差信号.从图中可以观察到,第7个IMF分量信号波形图在2500s左右时依然具有较强的冲击特征.为了筛选出包含较丰富故障冲击特征信号的IMF分量信号进行重构,采用与仿真信号相同的自适应判别准则对上述分解得到的IMF分量进行自适应筛选判别,最终得到的判别准则指数 $R(p)$ 如图9所示.

根据图9可以得到实际生产过程数据的各个IMF分量的判别准则指数 $R(p)$ 的大小.同时根据

仿真信号判别准则,依然选择 $R(p) > 0.3$ 的IMF分量信号作为包含故障信号特征最多信息的特征信号进行重构.将筛选出的包含故障信息最多的特征信号进行重构,并将重构后的信号输入到双稳随机共振系统参数优化算法中,适当扩大随机共振参数 a, b 的寻优范围.为了验证本文寻优方法的有效性,将上述重构信号分别利用文献[21]、文献[22]和本文所提方法对双稳系统参数进行寻优,并对双稳系统响应时域波形图和频谱图进行分析,分析结果分别如图10~图12所示.其中,文献[21]采用的优化算法为传统蚁群算

法,文献[22]采用的优化算法为传统粒子群优化方法,本文采用的是高斯-柯西种群突变机制的樽海鞘群优化方法对双稳系统参数进行寻优.结合本文实际高压辊磨机运行振动信号,设定 3 种方法的实验参数以及实验结果如表 1 所示.




图 9 实际振动信号的 IMF 分量信号判别指数 $R(p)$
Fig. 9 IMF component signal discrimination index $R(p)$ of actual vibration signal

表 1 3 种方法对比结果
Table 1 Comparison results of three methods

方法	寻优次数	初始种群数/个	时间/s	特征频率/Hz
蚁群算法 ^[21]	150	50	0.04	4.163
粒子群算法 ^[22]	200	50	0.08	8.325
本文算法	100	30	0.01	2.081

在表 1 中可以看出,文献[21]和文献[22]在对高压辊磨机实际运行振动信号进行故障特征提取时,选定的优化算法的初始种群均为 50 个.从表中可以看出,蚁群算法寻优次数达到 150 时可以达到较好的参数状态,而粒子群算法寻优次数则达到 200,大幅增加了参数寻优过程中的时间消耗.本文方法与文献[21]和文献[22]相比,可以在 100 次迭代时便获得较好的参数寻优结果,且本文所提优化算法的初始种群数也低于文献[21]和文献[22],这既降低了寻优过程中的计算复杂度,又能有效减少寻优时间消耗,从而更快地识别出高压辊磨机故障的主导特征频率.由于生产过程的复杂性,对选矿过程设备运行状态变化进行及时识别的要求显著提高.表 1 显示 3 种方法在参数寻优过程中的时间消耗分别为 0.08, 0.04 和 0.01 s,进一步证明本文方法能更高效地获取最优参数.

由图 10~图 11 可以看出,虽然文献[21]和文献[22]方法的参数寻优可以使双稳系统达到一定的共振效果,但不能使双稳系统达到最佳共

振状态,导致信号中的噪声能量不能很好地转移到故障特征信号上,因而不能最优地达到共振效果,共振波峰存在一定的振荡.因此采用文献[21]和文献[22]方法对高压辊磨机异常信号特征频率提取时,仅能识别高压辊磨机异常信号特征主导频率的 2 倍频和 4 倍频等故障特征主导频率,而无法有效提取基频,导致难以及时发现高压辊磨机异常工况.




图 10 蚁群优化随机共振系统的时域波形图和频谱图

Fig. 10 Time-domain waveform and spectrum diagrams of ant colony-optimized stochastic resonance system

(a) 蚁群优化算法时域波形图;
(b) 蚁群优化算法频谱图.




图 11 粒子群优化随机共振系统时域波形图和频谱图

Fig. 11 Time-domain waveform and spectrum diagrams of particle swarm-optimized stochastic resonance system

(a) 粒子群优化算法时域波形图;
(b) 粒子群优化算法频谱图.

由图 10 可以看出,文献[21]所提蚁群优化方法在随机共振参数寻优过程中选定的参数虽然可以使双稳系统达到一定的共振效果,但不能使双稳系统达到最优的共振状态,这也导致无法充分利用高压辊磨机运行过程原始信号中的噪声能量.由图 10a 可以看出,此时的双稳系统产生

了较大的振荡,尤其在时域图中可以看出在 0.2 s 左右共振系统产生的振荡最为明显,导致其图 10b 中的频谱只能识别出实际信号的 2 倍特征主导频率.而对于高压辊磨机运行过程中的基频特征无法有效识别.这也说明了文献[21]方法在双稳系统参数寻优过程中的不足.

由图 11 可以看出,文献[22]所提粒子群优化方法在随机共振参数寻优过程中得到的参数虽然可以使双稳系统达到一定的共振效果,但同时也使双稳系统产生了较多的振荡.从图 11a 可以看出,在 0.1 s 就产生了一定的振荡,由于参数的选择不能达到较优的状态,导致后期的振荡越来越严重.对比文献[21]的时域图可以看出,在 0.2 s 左右共振系统产生的振荡相对有所增大,这也说明前期振荡的原因导致了后期的振荡无法得到收敛.从图 11b 中可以看出,此时双稳系统的功率谱图的波峰形成于 8.325 Hz,对比实际高压辊磨机运行过程中的基频,此时的主导特征频率为基频的 4 倍.这表明双稳系统不能很好地将噪声能量转移到故障特征信号上,导致其频谱只能识别出实际信号的 4 倍特征主导频率.

图 12 为本文所提参数寻优自适应重构特征的高压辊磨机运行故障诊断方法在实际高压辊磨机生产运行信号上的分析结果图.从图 12a 中可以看出,本文所提优化方法在随机共振参数寻优过程中可以有效地使双稳系统达到最优的共振效果.对比文献[19]和文献[22]的时域图可以看出,在 0.1 s 左右共振系统产生良好的共振效果,达到最优的双稳状态;同时,在 0.2 s 时刻的共振效果对比上述两种方法,此时双稳系统的振荡也被大大削弱,这表明双稳系统可以很好地将噪声能量转移到故障特征信号上.结合频谱图可以看出,双稳系统的频谱可以识别出高压辊磨机运行过程实际信号中的基频特征主导频率.因此,本文所提方法对比于另外两种方法在双稳系统参数寻优过程中表现出较好的寻优结果,同时可以使双稳系统达到较优的共振状态,可以有效地对高压辊磨机运行过程的故障进行识别与诊断.





图 12 本文优化随机共振系统的时域波形图和频谱图

Fig. 12 Time-domain waveform and spectrum diagrams of optimized stochastic resonance system in this paper

(a)—本文算法时域波形图;(b)—本文算法频谱图.

3 结 论

1) IMF 分量信号的自适应判别有效避免了人工选择 IMF 分量导致有用信号的丧失或者过多噪声的混入,有效实现了 IMF 分量信号选择,使得重构信号包含更多的原始振动信号信息.

2) 基于高斯-柯西种群概率突变机制的樽海鞘群算法在增加种群多样性的同时避免算法陷入局部最优解,完成全局最优搜索,可以最优地寻找到双稳随机共振的参数.

3) 通过对双稳随机共振系统参数优化实现了更好的共振效果,有效实现了高压辊磨机故障主导特征频率的提取.

参考文献:

- [1] Coussat A, Rit S, Clackdoyle R, et al. Region-of-interest CT reconstruction using object extent and singular value decomposition [J]. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 2022, 6(5): 537-551.
- [2] Chai M Y, Gao Z Y, Li Y Q, et al. An approach for identifying corrosion damage from acoustic emission signals using ensemble empirical mode decomposition and linear discriminant analysis [J]. *Measurement Science and Technology*, 2022, 33(6): 065018.
- [3] Smith J S. The local mean decomposition and its application to EEG perception data [J]. *Journal of The Royal Society Interface*, 2005, 2(5): 443-454.
- [4] Libanda B, Nkolola N B. An ensemble empirical mode decomposition of consecutive dry days in the Zambezi Riparian Region: implications for water management [J]. *Physics and Chemistry of the Earth, (Parts A/B/C)*, 2022, 126: 103147.
- [5] 曹源, 宋迪, 胡小溪, 等. 基于改进时域多尺度散布熵与支持向量机的转辙机故障诊断[J]. *电子学报*, 2023, 51(1): 117-127.
(Cao Yuan, Song Di, Hu Xiao-xi, et al. Fault diagnosis of railway point machine based on improved time-domain multiscale dispersion entropy and support vector machine [J]. *Acta Electronica Sinica*, 2023, 51(1): 117-127.)
- [6] Torres M E, Colominas M A, Schlotthauer G, et al. A complete ensemble empirical mode decomposition with adaptive noise [C]//2011 IEEE International Conference on

- Acoustics, Speech and Signal Processing (ICASSP). Prague, 2011: 4144–4147.
- [7] Benzi R, Sutera A, Vulpiani A. The mechanism of stochastic resonance [J]. *Journal of Physics A: Mathematical and General*, 1981, 14(11): L453–L457.
- [8] Peters K J H, Geng Z, Malmir K, et al. Extremely broadband stochastic resonance of light and enhanced energy harvesting enabled by memory effects in the nonlinear response.[J]. *Physical Review Letters*, 2021, 126(21): 213901.
- [9] Qiao Z J, Lei Y G, Lin J, et al. Stochastic resonance subject to multiplicative and additive noise: the influence of potential asymmetries [J]. *Physical Review E*, 2016, 94(5): 052214.
- [10] Su D X, Zheng R C, Nakano K, et al. On square-wave-driven stochastic resonance for energy harvesting in a bistable system[J]. *AIP Advances*, 2014, 4(11): 117140.
- [11] Qiao Z J, Chen S, Lai Z H, et al. Harmonic–Gaussian double-well potential stochastic resonance with its application to enhance weak fault characteristics of machinery [J]. *Nonlinear Dynamics*, 2023, 111(8): 7293–7307.
- [12] 孔德阳, 彭华, 马金全. 基于人工鱼群算法的自适应随机共振方法研究[J]. 电子学, 2017, 45(8): 1864–1872. (Kong De-yang, Peng Hua, Ma Jin-quan. Adaptive stochastic resonance method based on artificial-fish swarm optimization [J]. *Acta Electronica Sinica*, 2017, 45(8): 1864–1872.)
- [13] 瞿铁, 李詠侠, 伏坤, 等. 高压辊磨机用硬质合金柱钉的磨损和断裂行为[J]. 中国有色金属学报, 2024, 34(10): 3394–3405. (Qu Tie, Li Yong-xia, Fu Kun, et al. Wear and fracture behavior of cemented carbide column nails for high-pressure roller mills [J]. *The Chinese Journal of Nonferrous Metals*, 2024, 34(10): 3394–3405.)
- [14] 范威, 水沛, 谢传东, 等. 基于 Archard 模型与 DEM 仿真的高压辊磨机磨损演化规律研究与优化[J]. 金属矿山, 2024(6): 173–180. (Fan Wei, Shui Pei, Xie Chuan-dong, et al. Research and optimization of wear evolution law of high pressure roller mill based on archard model and DEM simulation [J]. *Metal Mine*, 2024(6): 173–180.)
- [15] Huang N E, Shen Z, Long S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 1998, 454(1971): 903–995.
- [16] Cao Y, Zhang Y Z, Wen T, et al. Research on dynamic nonlinear input prediction of fault diagnosis based on fractional differential operator equation in high-speed train control system [J]. *Chaos*, 2019, 29(1): 013130.
- [17] 张敏, 蔡振宇, 包珊珊. 基于 EEMD–Hilbert 和 FWA–SVM 的滚动轴承故障诊断方法[J]. 西南交通大学学报, 2019, 54(3): 633–639, 662. (Zhang Min, Cai Zhen-yu, Bao Shan-shan. Fault diagnosis of rolling bearing based on EEMD–Hilbert and FWA–SVM [J]. *Journal of Southwest Jiaotong University*, 2019, 54(3): 633–639, 662.)
- [18] 周平, 刘记平. 基于数据驱动多输出 ARMAX 建模的高炉十字测温中心温度在线估计[J]. 自动化学报, 2018, 44(3): 552–561. (Zhou Ping, Liu Ji-ping. Data-driven multi-output ARMAX modeling for online estimation of central temperatures for cross temperature measuring in blast furnace ironmaking [J]. *Acta Automatica Sinica*, 2018, 44(3): 552–561.)
- [19] Qiao Z J, Pan Z R. SVD principle analysis and fault diagnosis for bearings based on the correlation coefficient [J]. *Measurement Science and Technology*, 2015, 26(8): 085014.
- [20] Kamimura R. Cost-conscious mutual information maximization for improving collective interpretation of multi-layered neural networks [J]. *Neurocomputing*, 2020, 409: 259–274.
- [21] 张丹威, 王晓东, 黄国勇. 相关系数 SVD 增强随机共振的单向阀故障诊断[J]. 电子学, 2018, 46(11): 2696–2704. (Zhang Dan-wei, Wang Xiao-dong, Huang Guo-yong. Check valve fault diagnosis with correlation coefficient SVD enhanced stochastic resonance [J]. *Acta Electronica Sinica*, 2018, 46(11): 2696–2704.)
- [22] 牟竹青, 冯早, 黄国勇, 等. 自适应随机共振和 DEMD 的单向阀早期故障诊断[J]. 机械科学与技术, 2018, 37(4): 537–544. (Mu Zhu-qing, Feng Zao, Huang Guo-yong, et al. Early fault diagnosis of check valve with adaptive stochastic resonance and DEMD [J]. *Mechanical Science and Technology for Aerospace Engineering*, 2018, 37(4): 537–544.)
- [23] 李明宇, 张丹威. 高压辊磨运行工况识别算法研究[J]. 金属矿山, 2022(4): 188–194. (Li Ming-yu, Zhang Dan-wei. Research on conditions identification algorithm for high-pressure grinding roll [J]. *Metal Mine*, 2022(4): 188–194.)
- [24] Qiao Z J, Lei Y G, Li N P. Applications of stochastic resonance to machinery fault detection: a review and tutorial [J]. *Mechanical Systems and Signal Processing*, 2019, 122: 502–536.