

基于INRBO优化FMD的风电齿轮箱故障诊断

龙霞飞¹,刘伟强¹,罗朝旭¹,何志成¹,张彬¹,谢昕好¹,伍席文²

(1.湖南工业大学交通与电气工程学院,湖南株洲 412007;

2.国电电力湖南新能源开发有限公司,湖南长沙 410125)

摘要:针对行星齿轮箱故障特征提取困难的问题,提出一种改进牛顿拉夫逊算法(INRBO)优化特征模态分解(FMD)参数的齿轮箱故障诊断方法。首先,提出一种多策略改进方法以全面提升牛顿拉夫逊算法(NRBO)的寻优性能;然后,利用INRBO优化FMD自适应参数,构建基于INRBO-FMD的风电齿轮箱故障诊断模型;最后,采用改进后的方法对齿轮箱原始振动信号进行自适应特征模态分解,开展行星齿轮箱的故障诊断研究。实验结果表明,所提INRBO-FMD方法能有效提取故障信号特征频率和倍频谐波成分,验证了该方法的准确性和实用性。

关键词:齿轮箱;故障诊断;特征模态分解;牛顿拉夫逊优化算法;复合混沌映射;小生境技术

0 引言

在全球能源结构向低碳化快速转型的关键时期,风力发电凭借其清洁性与规模化潜力,已成为构建新型电力系统的核心支柱^[1-3]。作为风电机组传动系统的核心部件,齿轮箱长期承受复杂交变载荷与恶劣工况,成为整机故障率最高的组件之一^[4-6]。因此,齿轮箱故障诊断与状态监测技术作为提高机组可靠性及保证机组安全运行的重要手段,起着举足轻重的作用。然而,运行环境的复杂性导致风电齿轮箱的早期故障特征信息微弱,具有高度非线性特征且包含大量噪声,难以有效提取故障特征信息,从而引发诊断偏差^[7]。因此,及时准确对风电齿轮箱进行故障诊断并做好预防性维护,对缩减企业生产维护费用和提升机组运行效能,有着至关重要的作用^[8-9]。

针对齿轮箱故障信号非线性和非平稳的特点,研究人员提出小波变换^[10]、经验模态分解(Empirical Mode Decomposition, EMD)^[11]、变分模态分解(Variational Mode Decomposition, VMD)^[12]等主流时频域信号处理策略。文献[13]构建一种复合评价指标对产生的分量进行筛选重组,实现故障特征信息的有效增强。文献[14]利用补偿距离评估技术并结合能量比变异系数增加特征分量的选取。文献[15]提出将包络谱谱峰因子作为信号中冲击成分的衡

量指标,有效抑制了偶发干扰的问题。文献[16]利用黏菌优化算法优化VMD的重要参数分解模态个数和惩罚因子,但VMD并未考虑信号的脉冲特性和冲击特性,易出现虚假干扰成分。文献[17]提出特征模态分解(Feature Mode Decomposition, FMD),该方法可对非平稳信号进行处理,一定程度上弥补了现有信号分解算法的缺点。然而FMD方法不具备参数自适应特性,需根据先验知识对其相关参数进行预先设定,参数设定不合理将对处理效果产生不利影响。文献[18-19]分别利用灰狼优化算法(Grey Wolf Optimizer, GWO)、鲸鱼优化算法(Whale Optimization Algorithm, WOA)来确定FMD关键参数的选取,以解决该方法需依靠人工设置参数的缺点,但此类算法在多维参数搜索中具有易陷入局部最优、收敛速度慢、结果随机性大等问题。文献[20]提出牛顿-拉夫逊优化算法(Newton-Raphson Based Optimizer, NRBO),该方法构建了两条规则以提升NRBO在探索阶段的灵活性和收敛速率,从而降低出现早熟收敛现象的概率。文献[21]引入精英化思想将复合混沌映射与反向学习结合,优化了种群分布以此强化算法的局部搜索能力和寻优精确度。文献[22]利用小生境技术改善遗传算法在遗传、选择过程中容易趋同而陷入早熟的问题。

综上,本文提出了基于改进牛顿拉夫逊算法(Improved Newton-Raphson Based Optimizer, INRBO)-FMD的齿轮箱故障诊断方法。该方法采用INRBO参数优化的FMD对原始信号进行分解,引入复合混沌映射初始化种群位置,并加入自适应参数控制、嵌入局部搜索和小生境技术3种策略,以提高寻优能

基金项目:国家自然科学基金资助项目(5247071640);湖南省教育厅科学研究项目(23B0537)

Project Supported by the National Natural Science Foundation of China (5247071640); Hunan Provincial Department of Education Scientific Research Project(23B0537)

力和改善局部收敛不足的问题。根据包络谱峰值因子筛选有效分量,并对最优分量进行包络谱分析,测试结果验证所提方法具备出色的故障识别能力。

1 FMD与NRBO理论基础及模型原理

1.1 FMD基本原理

FMD结合反卷积理论,通过对有限冲激响应(Finite-impulse Response, FIR)滤波器组初始化,可自适应调整滤波器系数,从而实现模态选择。该方法通过迭代优化滤波器参数,使滤波输出逐步逼近反卷积目标函数,经处理后成功提取到特征信息充足的模态分量,具体过程为:

1)自适应FIR滤波器组的设计。将原始信号的频带划分为 K 段,并将均匀分布的FIR滤波器组覆盖整个频带。滤波器组的表达式为:

$$\begin{cases} f_k = [f_k(1) \cdots f_k(l) \cdots f_k(L)]^T \\ f_1 = k \cdot f_s / 2K \\ f_u = (k+1) \cdot k \cdot f_s / 2K \end{cases} \quad (1)$$

式中: f_s 为原始信号的采样频率; $f_k(l)$ 为第 k 个滤波器的频率, $k=0,1,\dots,K-1$, l 为滤波器长度, $l \in [1, L]$, L 为最大长度; f_l, f_u 分别为滤波器的下限和上限截止频率。

2)滤波器更新与周期估计。为解决同一故障分量可能会被分解到不同模态,FMD的解被视为一个带约束的优化问题。约束模型的表达式为:

$$\begin{cases} \arg \max_{\{f_k(l)\}} \left\{ \frac{CK_M(u_k) = \sum_{n=1}^N \left(\prod_{m=0}^M u_k(n - mT_s) \right)^2}{\left(\sum_{n=1}^N u_k(n)^2 \right)^{M+1}} \right\} \\ \text{s.t. } u_k(n) = \sum_{l=1}^L f_k(l)x(n-l+1) \end{cases} \quad (2)$$

式中: $u_k(n)$ 为第 k 个滤波器经分解后的输出; $CK_M(u_k)$ 为目标函数的相关峭度,体现模态的周期性; T_s 为故障周期; $x(n-l+1)$ 为第 n 个采样点对应的信号, $n \in [1, N]$, N 为最大采样点数; m 为位移阶次的索引, $m \in [0, M]$, M 为最大位移阶数。

通过迭代特征值分解算法处理式(2)可得:

$$u_k = X \cdot f_k \quad (3)$$

$$u_k = \begin{bmatrix} u_k(1) \\ \vdots \\ u_k(N-L+1) \end{bmatrix} \quad (4)$$

$$X = \begin{bmatrix} x(1) & \cdots & x(L) \\ \vdots & \ddots & \vdots \\ x(N-L+1) & \cdots & x(N) \end{bmatrix} \quad (5)$$

$$f_k = \begin{bmatrix} f_k(1) \\ \vdots \\ f_k(L) \end{bmatrix} \quad (6)$$

式中: X 为数据矩阵。

3)模态分量选择。为剔除模态混叠与冗余分量,优先选择互相关系数(Correlation Coefficient, CC)最大的模态分量。同时,为确保故障特征完整性,在CC值最高的2个模态中选择相关峭度较大的2组分量,分别为 u_p 和 u_q 。求解最大模态分量 CC_{pq} 如式(7)所示:

$$CC_{pq} = \frac{\sum_{n=1}^N (u_p(n) - \bar{u}_p)(u_q(n) - \bar{u}_q)}{\sqrt{\sum_{n=1}^N (u_p(n) - \bar{u}_p)^2} \sqrt{\sum_{n=1}^N (u_q(n) - \bar{u}_q)^2}} \quad (7)$$

式中: \bar{u}_p, \bar{u}_q 为2组模态分量的平均值。

1.2 NRBO基本原理

NRBO是受牛顿-拉夫逊法启发的一种新型元启发式优化算法。通过引入牛顿-拉夫逊搜索规则(Newton-Raphson Search Rule, NRSR)强化NRBO的全局搜索能力与收敛效率,并添加陷阱避免算子(Trap Avoidance Operator, TAO)改变解的更新方式,以此增加随机性和多样性,从而避免局部最优陷阱。

1.2.1 种群初始化

NRBO将随机生成一组解来构成初始种群,其中每一个解都代表解空间中随机位置的一个点 x_i^j ,即:

$$x_i^j = lb + \text{rand} \times (ub - lb) \quad (8)$$

式中: x_i^j 为种群中第 i 个个体在第 j 个维度上的坐标位置, $i=1,2,\dots,N_p$, N_p 为搜索种群中所含个体的总量, $j=1,2,\dots,\text{dim}$, dim 为这个种群所具有的维度总数; lb, ub 分别对应搜索空间中个体位置的下、上边界约束; rand 为生成均匀分布的随机变量。

1.2.2 NRSR基本原理

通过牛顿拉夫逊算法设定一个假定初始解,并从一个确定的方向开始更新至下一位置,其位置表达式为:

$$x_{n+1} = x_n - \frac{(f(x_n + \Delta x) - f(x_n - \Delta x)) \times \Delta x}{2 \times (f(x_n + \Delta x) - f(x_n - \Delta x)) - 2 \times f(x_n)} \quad (9)$$

$$\Delta x = \text{randn}(1, \text{dim}) \times |x_b - x_i^j| \quad (10)$$

式中: x_{n+1}, x_n 分别为泰勒级数中第 $n+1, n$ 项的解,即为第 $n+1, n$ 项的位置; $f(x_n)$ 为泰勒级数; Δx 为理论解与计算解的差值; $\text{randn}(1, \text{dim})$ 为与维度参数 dim 相关的正态分布随机变量; x_b 为最优解的位置。

推导式(9)可得出 NRSR 的表达式为:

$$S_{\text{NRR}} = \text{randn} \times \frac{(y_w - y_b) \times \Delta x}{2 \times (y_w + y_b - 2 \times x_i)} \quad (11)$$

$$y_w = r_1 \times (\text{Mean}(z_{i+1} + x_i) + r_1 \times \Delta x) \quad (12)$$

$$y_b = r_1 \times (\text{Mean}(z_{i+1} + x_i) - r_1 \times \Delta x) \quad (13)$$

$$z_{i+1} = x_i - \text{randn} \times \frac{(x_w - x_b) \times \Delta x}{2 \times (x_w + x_b - 2 \times x_i)} \quad (14)$$

式中: x_w 为最劣位置; x_i 为当前位置; z_{i+1} 为第*i*+1次迭代后的新解的空间位置; y_w, y_b 为基于 z_{i+1} 和 x_i 2个坐标确定的位置; $\text{Mean}(\cdot)$ 为坐标均值; r_1 为[0,1]的随机变量。

为了保持探索阶段和开发阶段之间的平衡,维持 NRSR 与自适应参数 ρ 的协同融合,既要考虑随机动作也要增加搜索过程的多样性,以达到规避局部最优问题。自适应参数 ρ 的表达式为:

$$\rho = \omega \times (x_b - x_i') + \phi \times (x_i' - x_{r_2}') \quad (15)$$

式中: ω, ϕ 为[0,1]之间的权重系数; r_2 为[0,1]的随机变量; x_i' 为第*t*次迭代中第*i*个个体更新后的解; x_{r_1}', x_{r_2}' 为第*t*次迭代中随机选取的2个解。

自适应调节系数 δ 的功能是在算法中实现探索多样性与收敛集中性的平衡,其表达式为:

$$\delta = (1 - \frac{2t}{T_{\text{max}}})^5 \quad (16)$$

式中: t 为当前迭代次数; T_{max} 为最大迭代次数。

在 NRSR 中,基于当前最优位置,分别构建出具备突出全局探索能力与局部开发能力的探索参数 $x1_i^t$ 与开发参数 $x2_i^t$,通过融合两者的动态特性建立式(19)和式(20):

$$x1_i^t = x_i^t - S_{\text{NRR}} + \rho \quad (17)$$

$$x2_i^t = x_b - S_{\text{NRR}} + \rho \quad (18)$$

$$x3_i^t = x_i^t - \delta \times (x2_i^t - x1_i^t) \quad (19)$$

$$x_i^{t+1} = r_2^t \times x1_i^t + (1 - r_2^t) \times (r_2^t \times x2_i^t + x3_i^t) \quad (20)$$

式中: $x3_i^t$ 为中间参数; x_i^{t+1} 为第*t*+1次迭代中第*i*个个体更新后的解。

1.2.3 陷阱避免算子

为了有效提升 NRBO 算法处理实际问题的能力且避免其陷入局部最优,引入 TAO 策略,通过改变最新位置 x_i^{t+1} ,结合最优位置 x_b 和当前位置 x_i^t 生成 x_{TAO}^t ,即:

$$x_{\text{TAO}}^t = x_i^{t+1} \quad (21)$$

$$\begin{cases} x_i^{t+1} = x_i^t + \theta_1 \times (\mu_1 \cdot x_b - \mu_2 \cdot x_i^t) + \\ \quad \theta_2 \times \gamma \times (\mu_1 \cdot \text{Mean}(x^t) - \mu_2 \cdot x_i^t), \text{if } \mu_1 < 0.5 \\ x_i^{t+1} = x_b + \theta_1 \times (\mu_1 \cdot x_b - \mu_2 \cdot x_i^t) + \\ \quad \theta_2 \times \gamma \times (\mu_1 \cdot \text{Mean}(x^t) - \mu_2 \cdot x_i^t), \text{if } \mu_1 \geq 0.5 \end{cases} \quad (22)$$

式中: x_{TAO}^t 为 TAO 策略生成的第*t*次迭代时中间解的坐标; θ_1, θ_2 分别为[-1,1],[−0.5,0.5]之间的权重系数; γ 为步长因子; μ_1, μ_2 为权重系数。

$$\mu_1 = \beta \times 3 \times \text{rand} + (1 - \beta) \quad (23)$$

$$\mu_2 = \beta \times \text{rand} + (1 - \beta) \quad (24)$$

$$\beta = \begin{cases} 0, \Delta \geq 0.5 \\ 1, \Delta < 0.5 \end{cases} \quad (25)$$

式中: β 为二元开关变量; Δ 为0到1之间的随机数。

1.3 包络谱峰值因子

峭度指标存在两方面局限:一是无法区分周期性冲击与随机脉冲,难以有效量化故障的周期性;二是对偶发性高幅值干扰极为敏感,易导致共振频带选择偏离真实故障特征频段。因此,本文采用包络谱峰值因子 E_c 作为评判指标,用于筛选最优分量并评估故障特征信息的提取效果,其表达式为:

$$E_c = \frac{\max(|E_m(i)|)}{R_{\text{MS}}(E_m(i))} \quad (26)$$

$$R_{\text{MS}}(E_m(i)) = \sqrt{\frac{1}{N} \sum_{i=1}^N (E_m(i))^2} \quad (27)$$

式中: $E_m(i)$ 为原始信号包络谱幅值序列; $\max(\cdot)$ 为包络谱中最大峰值幅值; $R_{\text{MS}}(\cdot)$ 为包络谱的均方根值。

2 INRBO 算法及测试函数对比

2.1 复合混沌映射初始化

复合混沌映射融合了 Logistic 映射与 Tent 映射的优点,其生成的初始种群兼具良好的分布特性与复杂的动态行为,可有效规避算法的早熟收敛问题。相较于传统随机初始化方法,该方法在高维空间的探索能力更为突出,能够有效维持种群多样性,进而提升算法的整体搜索性能。根据复合混沌映射生成新的个体位置 X_{n+1} ,表达式为:

$$X_{n+1} = \begin{cases} \left[\varepsilon X_n (1 - X_n) + \frac{4 - \varepsilon}{2} \cdot X_n \right] \bmod 1, & X_n < 0.5 \\ \left[\varepsilon X_n (1 - X_n) + \frac{(4 - \varepsilon)(1 - X_n)}{2} \cdot X_n \right] \bmod 1, & X_n \geq 0.5 \end{cases} \quad (28)$$

式中: X_n 为种群个体的初始位置; ε 为控制参数; $\bmod 1$ 为取模运算。

2.2 自适应参数控制

在传统的 TAO 策略中,其触发概率(Trigger Probability, TP)通常被设定为固定值,这种静态机制可能导致算法在全局探索与局部开发之间的不平

衡。为解决这一问题,本文提出一种基于种群多样性的动态 TP 调整策略:当种群多样性较低(表现为适应度方差较小)时,增加 TP 以强化全局探索能力;当种群多样性较高(表现为适应度方差较大)时,则降低 TP 以侧重局部开发,具体表达式为:

$$\sigma^2 = \frac{1}{Q} \sum_{i=1}^N (f_i - \bar{f})^2 \quad (29)$$

$$TP = TP_{base} + \nabla \times (1 - \frac{\sigma}{\sigma_{max}}) \quad (30)$$

式中: σ 为适应度方差; f_i 为种群个体适应能力均值; \bar{f} 为种群平均适应能力均值; Q 为种群大小; TP_{base} 为基准值,取值常为 0.6; ∇ 为调整幅值; σ_{max} 初始种群适应度标准差的最大估计值。

2.3 嵌入局部搜索

NRBO 根据牛顿-拉夫逊规则进行全局搜索时缺乏对最优解的精细化调整,这将导致收敛精度不足且在平坦区域易停滞等问题。因此,本文在全局搜索中嵌入局部搜索策略,设置周期迭代数和自适应步长,通过计算局部搜索步长 $L_{ocalStep}$ 对当前最优解进行微调,表达式为:

$$L_{ocalStep} = \lambda \cdot \frac{1}{\sqrt{\dim}} \cdot (ub - lb) \cdot \varepsilon(0,1) \quad (31)$$

式中: λ 为步长系数; $\varepsilon(0,1)$ 即服从标准正态分布的随机数。

2.4 小生境技术

针对 NRBO 算法在多峰优化问题中易陷入局部最优的缺陷,本文引入生物进化理论中的小生境技术,构建了一种多模态协同优化机制。该机制通过模拟生物种群在生态环境中的竞争与共享行为,有效维持种群多样性,并提升算法的全局搜索能力。具体实现步骤如下:

步骤 1:小生境识别与种群划分。依据式(32)所定义的个体间空间距离准则,对种群进行小生境划分:

$$d_{ij} = \sqrt{\sum_{\substack{c=1 \\ c \neq j}}^n (x_i - x_j)^2} \quad (32)$$

式中: d_{ij} 为个体间空间距离; x_i, x_j 为 2 个个体的位置; c 为个体位置的向量维度, $c = [1, n]$ 且 $c \neq j$ 。

步骤 2:建立共享-排挤策略。对同一小生境个体,通过共享函数 $sh(d_{ij})$ 调节个体适应度以平衡种群分布密度,即:

$$sh(d_{ij}) = \begin{cases} 1 - \frac{d_{ij}}{\eta}, & d_{ij} < \eta \\ 0, & d_{ij} > \eta \end{cases} \quad (33)$$

式中: η 为小生境共享半径。

当 $d_{ij} < \eta$ 时,粒子聚类至同一小生境,形成独立搜索子空间。每个子群内独立执行 NRBO 算法的梯度更新,且在保持局部寻优能力的同时通过空间隔离抑制种群趋同,反之则取 0。

步骤 3:精英跨域迁移。在每次迭代中,记录各子种群的最优解并构建精英库,通过跨域迁移策略实现优质解的定向传播,实施精英保留策略。算法终止时,采用层次聚类整合各子群最优解,输出全局解集。

综上所述,INRBO 算法首先引入复合混沌映射理论初始化种群位置以提高全局搜索能力;其次,加入自适应参数控制、嵌入局部搜索两种策略解决 NRBO 中可能出现的探索与开发平衡不足的问题;最后,加入小生境技术改善 NBRO 算法容易因趋同化产生局部收敛的不足的问题。INRBO 算法流程图如图 1 所示。

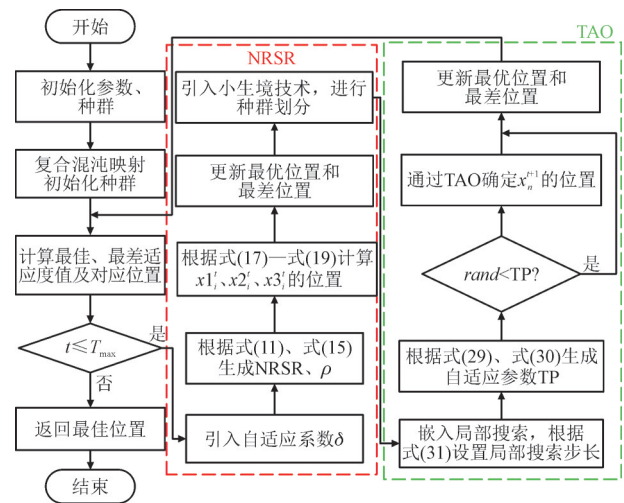


图1 INRBO 算法流程图

Fig.1 Flowchart of INRBO algorithm

2.5 测试函数对比

2.5.1 实验环境

实验基于 Windows11 64 位操作系统,采用 Matlab 2018b 款软件,在硬件配置为 AMD R5-4600H CPU,主频 3.00GHz,内存 16GB 的环境下进行测试。

2.5.2 实验结果

为验证本文所提方法 INRBO 的有效性,在 4 种标准测试函数环境下,将该方法与 NRBO, GWO, WOA 3 种算法开展对比实验研究。所有算法的种群规模设置为 100,迭代次数设置为 500,重复进行 30 次独立测试。统计测试后各个标准函数的平均值、最优值和标准差。其标准测试函数的具体参数如表 1 所示,算法在标准测试函数运行所得的平均

收敛曲线如图 2 所示。

表 1 标准测试函数
Table 1 Standard test functions

测试函数	维度	自变量范围	最优值
$F_1(x) = \sum_{i=1}^n ix_j^4 + random(0,1) \frac{\partial^2 \Omega}{\partial u^2}$	30	[-1.28, 1.28]	0
$F_2(x) = \sum_{j=1}^n -x_j \sin(\sqrt{ x_j })$	30	[-500, 500]	-12 569.48
$F_3(x) = \sum_{j=1}^{11} \left[a_i - \frac{x_1(b_i^2 + b_i x_2)^2}{b_i^2 + b_i x_3 + x_4} \right]$	4	[-5, 5]	0.000 3
$F_4(x) = \sum_{j=1}^n u(x_j, 5, 100, 4) + 0.1 \left\{ \sum_{i=1}^n (x_j - 1)^2 [1 + \sin^2(3\pi x_j + 1)] + (x_n - 1)^2 [1 + \sin^2(2\pi x_n)] + \sin^2(3\pi x_1) \right\}$	30	[-50, 50]	0

表 1 中, x_j 为自变量的第 f 个分量; $\frac{\partial^2 \Omega}{\partial u^2}$ 为辅助函数 Ω 对变量 u 的二阶偏导数; $\sin(\sqrt{|x_j|})$ 为正弦函数与平方根; a_i 为实验响应值, b_i 为因子水平, 两者均为预设的常数参数; $u(x_j, 5, 100, 4)$ 为惩罚函数, 若 $x_j < 5$ 或 $x_j > 100$, 则触发惩罚项, 系数取 4; 否则惩罚项为 0; $\sin^2(3\pi x_1)$ 用于增加函数的多峰性。

图 2 中 4 个测试函数的收敛曲线表明, 相比于其它 3 种方法, INRBO 算法具备更快的收敛速度和计算效率。不同算法用于各测试函数的结果如表 2 所示。




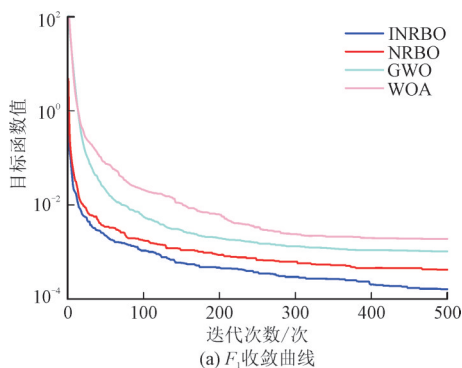


图 2 各个测试函数的收敛曲线
Fig.2 Convergence curves of each test function

表 2 各算法测试统计结果
Table 2 Statistical results of of algorithms on test functions

函数	算法	平均值	最优值	标准差
$F_1(x)$	INRBO	$1.616 5 \times 10^{-4}$	$2.136 4 \times 10^{-5}$	$1.212 9 \times 10^{-4}$
	NRBO	$4.175 9 \times 10^{-4}$	$3.203 5 \times 10^{-5}$	$2.754 9 \times 10^{-4}$
	GWO	$1.016 0 \times 10^{-3}$	$3.105 6 \times 10^{-4}$	$5.672 8 \times 10^{-4}$
	WOA	$1.887 6 \times 10^{-3}$	$8.134 5 \times 10^{-5}$	$2.025 4 \times 10^{-3}$
$F_2(x)$	INRBO	$-1.110 7 \times 10^4$	$-1.256 9 \times 10^4$	$7.503 2 \times 10^2$
	NRBO	$-9.413 1 \times 10^3$	$-1.256 1 \times 10^4$	$1.843 8 \times 10^3$
$F_3(x)$	GWO	$-5.941 7 \times 10^3$	$-7.462 8 \times 10^3$	$9.458 6 \times 10^2$
	WOA	$-5.323 1 \times 10^3$	$-7.203 2 \times 10^3$	$7.459 5 \times 10^2$
	INRBO	$3.995 8 \times 10^{-4}$	$3.074 9 \times 10^{-4}$	$2.792 6 \times 10^{-4}$
$F_4(x)$	NRBO	$1.128 6 \times 10^{-3}$	$3.074 9 \times 10^{-4}$	$3.649 3 \times 10^{-3}$
	GWO	$3.073 2 \times 10^{-3}$	$3.074 9 \times 10^{-4}$	$6.903 3 \times 10^{-3}$
	WOA	$6.616 5 \times 10^{-4}$	$3.101 0 \times 10^{-4}$	$3.429 5 \times 10^{-4}$
	INRBO	$1.623 1 \times 10^{-3}$	$2.471 3 \times 10^{-4}$	$3.423 8 \times 10^{-3}$
$F_4(x)$	NRBO	1.685 6	1.147 3	$3.480 4 \times 10^{-1}$
	GWO	$2.007 6 \times 10^{-1}$	$2.505 5 \times 10^{-5}$	$1.344 5 \times 10^{-1}$
	WOA	$4.072 1 \times 10^{-2}$	$2.666 5 \times 10^{-3}$	$4.183 3 \times 10^{-2}$

表 2 中的计算结果进一步说明, INRBO 算法平均值最优值和标准差都全面优于 NRBO, GWO 和 WOA 算法, 表明该算法不仅具有更高的收敛精度, 还具有更好的稳定性。

3 实验验证

3.1 故障诊断流程

为解决 FMD 输入参数依靠人工经验且不具备自适应的缺陷, 本文提出基于 INRBO 优化 FMD 参

数的齿轮箱故障诊断模型,诊断流程为:

步骤 1:输入采集的齿轮箱振动信号。设置 $Q = 30, T_{\max} = 50$ 。

步骤 2:使用 INRBO 优化 FMD 参数。选用最小包络熵 (Minimum Enclosing Entropy, MEE) 作为 INRBO 算法寻优 FMD 参数的适应度函数,执行寻优运算,当迭代次数达到最大设定值时寻优结束,输出最优影响参数,表达式为:

$$\begin{cases} E_p = -\sum_{i=1}^{\psi} p_i \lg p_i \\ p_i = \frac{a(i)}{\sum_{i=1}^{\psi} a(i)} \end{cases} \quad (34)$$

式中: E_p 为包络熵; p_i 为第 i 个采样点对应的概率值,是包络信号归一化后的统计量; ψ 为采样点数; $a(i)$ 为计算后的包络信号。

步骤 3:FMD 分解。根据寻优所得结果对原始振动信号进行 FMD 分解,得到多个本征模态函数 (Intrinsic Mode Function, IMF) 分量。

步骤 4:实验分析。构建包络谱峰值因子作为筛选最优分量的评价指标,对模态分量进行包络解调运算,提取故障特征频率,通过分析齿轮转频、啮合频率及调制边频带信息实现故障诊断。

3.2 实验分析

为验证本文所提方法在齿轮箱故障诊断中的有效性,使用型号为 QPZZ-II 的机械故障试验平台采集的齿轮箱数据信息为依据,模拟齿轮箱齿牙磨损、齿牙断裂、齿牙缺失、齿根裂纹 4 种故障类型。齿轮箱工况参数如表 3 所示,试验平台结构示意图如图 3 所示,齿轮故障状态示意图如图 4 所示。

表 3 齿轮箱工况参数

Table 3 Gearbox operating parameters

齿轮状态	故障部位	负载/A	实测转速/rpm
断齿	大齿轮(75齿)	0.1	860
磨损	小齿轮(55齿)	0.1	854




图 3 试验平台
Fig.3 Test platform




图 4 齿轮故障状态示意图

Fig.4 Schematic diagram of gear fault states

根据表 3 的参数信息可以求出该齿轮箱的转频 f_r 和啮合频率 f_c ,表达式为:

$$f_r = \frac{f_0}{60} \quad (35)$$

$$f_c = f_r \times Z \quad (36)$$

式中: f_0 为实测转速; Z 为故障点齿轮数。

因而当发生齿轮断齿故障时,转频 $f_r = 14.333$ Hz, 啮合频率 $f_c = 1075$ Hz; 当发生齿轮磨损故障时,转频 $f_r = 14.233$ Hz, 啮合频率 $f_c = 782.833$ Hz。

本文以断齿和磨损故障状态下的齿轮箱振动信号数据为例进行分析,设置数据采样频率为 5 120 Hz,采样时间为 10 s。其断齿故障状态下时域图如图 5 所示。




图 5 断齿故障振动信号时域图

Fig.5 Time-domain diagram of vibration signal for tooth breakage fault

以最小包络熵作为 INRBO 算法寻优 FMD 参数的适应度函数,INRBO 算法对 FMD 参数进行自适应寻优。种群更新迭代过程中适应度函数的收敛变化特性如图 6 所示。其中,INRBO 算法在大约 11 次迭代后适应度值趋于稳定(约 7.525),表明其具有较快的收敛速度。




图 6 INRBO 算法寻优过程适应度值变化曲线

Fig.6 Variation curve of fitness value during INRBO optimization

实验数据显示,算法在第 11 次迭代时达到收敛状态,目标函数趋于稳定,此时所达到的最小函数值为 7.525。

经寻优后最优参数组合分别为模态个数为 5, 滤波器最大长度为 42, FMD 计算得到对应 5 个 IMF 分量, 如图 7 所示。




图7 基于FMD的分解信号时域图

Fig.7 Time-domain diagram of decomposed signals based on FMD

本研究采用包络谱谱峰因子最大化准则筛选主模态分量, 根据式(26)计算各个分量的 E_c 值, $E_c(\text{IMF}_1) = 3.282$, $E_c(\text{IMF}_2) = 6.855$, $E_c(\text{IMF}_3) = 5.364$, $E_c(\text{IMF}_4) = 7.891$, $E_c(\text{IMF}_5) = 12.105$ 。选取 E_c 值最大的 IMF_5 分量进行包络谱分析, 如图 8 所示。




图8 IMF₅包络谱

Fig.8 Envelope spectrum of IMF_5

图 8 中, 1 表示 f_r , 2 表示 $4f_r$, 3 表示 $5f_r$, 4 表示 $16f_r$, 5 表示 $32f_r$, 6 表示 $33f_r$, 7 表示 $34f_r$, 8 表示 $37f_r$, 9 表示 $40f_r$, 10 表示 $f_c - 9f_r$, 11 表示 f_c , 12 表示 $f_c + 5f_r$, 13 表示 $f_c + 6f_r$, 14 表示 $f_c + 16f_r$, 15 表示 $f_c + 20f_r$, 16 表示 $f_c + 35f_r$ 。

由图 8 可知, 最优分量 IMF_5 的包络谱中包含清晰、高幅值的转频和谐波峰值, 并以齿轮啮合频率和谐波为载波频率, 出现间隔为故障转频的调制边频带, 且边频带宽度广、幅值高。因此, 通过图 8 特征

频率信息可以判断该齿轮箱出现齿轮断齿故障。

同断齿故障研究分析一样, 对出现磨损故障的齿轮箱振动信号进行分析, 其原始信号时域图如图 9 所示。




图9 磨损故障振动信号时域图

Fig.9 Time-domain diagram of vibration signal for wear fault

选取最优分量后对其进行包络谱分析, 包络谱结果如图 10 所示。




图10 最优分量包络谱

Fig.10 Envelope spectrum of the optimal component

图 10 中, 1 表示 f_r , 2 表示 $4f_r$, 3 表示 $6f_r$, 4 表示 $17f_r$, 5 表示 $18f_r$, 6 表示 $32f_r$, 7 表示 $33f_r$, 8 表示 $37f_r$, 9 表示 $41f_r$, 10 表示 f_c , 11 表示 $f_c + 5f_r$, 12 表示 $f_c + 21f_r$, 13 表示 $f_c + 25f_r$, 14 表示 $f_c + 37f_r$, 15 表示 $f_c + 41f_r$, 16 表示 $2f_c$, 16 表示 $2f_c + 25f_r$ 。

由图 10 可知, 包络谱中啮合频率及其高次谐波的幅值明显增大, 且阶数越高, 谐波增大的幅度越大。出现较稀疏的调制边频带, 振动信号与断齿相比更弱, 但动能量有较大幅度的增加。因此, 通过图 10 特征频率信息可以判断该齿轮箱出现齿轮磨损故障。

3.3 实验对比

为进一步验证所提方法的优越性, 分别采用 NRBO-FMD, GWO-FMD 和 WOA-FMD 对上述齿轮箱断齿故障数据进行研究, 寻优过程中适应度函数的收敛变化特性如图 11 所示。




图11 不同算法适应度值收敛曲线对比

Fig.11 Comparison of fitness value convergence curves for different algorithms

由图 11 可知,INRBO 在收敛速度和收敛精度上均具备一定的优势,可以更快的完成收敛。选用各方法中的最优分量进行包络谱分析,如图 12 所示。

图 12 所示,3 种方法虽然都可以提取到一定数量的转频和边频带,但是提取效果与 INRBO-FMD 均有较大差距,转频及其倍频数量更少,边频带较为稀疏且存在大量干扰谱线,故障特征不明显。




图 12 各方法所选分量的包络谱

Fig.12 Envelope spectrum of the component selected by each method

5 结论

针对齿轮箱故障诊断中故障特征难以检测的问题,本文提出了 INRBO-FMD 的齿轮箱故障诊断方法,实例验证表明该方法具有较强的故障分类能力。主要工作和成果为:

1) 利用 INRBO 优化 FMD 参数,可以缓解由于参数选择不当而影响信号分解性能的问题。有利于提高 FMD 的分解效果。

2) 引入四种改进策略后的 INRBO 与 NRBO, GWO, WOA 算法相比,该方法能以更少的迭代次数找到最优的参数组合,收敛速度和寻优效果更加显著。

3) 通过公开数据集进行验证分析表明,相比于 NRBO-FMD, GWO-FMD 和 WOA-FMD,本文所提 INRBO-FMD 方法,包络谱更加清晰,倍频成分更加明显,在提取故障特征方面更具有优势。

参考文献

- [1] 徐楚琦,孙辰昊,詹明宇,等.基于 IGWO-Seq2Seq 的风电故障预测方法[J].电力科学与技术学报,2024,39(6):203-211.
XU Chuqi, SUN Chenhao, ZHAN Mingyu, et al. Wind power fault prediction method based on IGWO-Seq2Seq[J]. Journal of Electric Power Science and Technology, 2024, 39(6): 203-211.
- [2] 孙怡文,邢海军,梅丘梅,等.计及风电-光伏出力相关性的新型电力系统可靠性评估[J].浙江电力,2025,44(9):13-20.
SUN Yiwen, XING Haijun, MEI Qiumei, et al. Reliability assessment of modern power systems accounting for the correlation of wind-PV output correlation[J]. Zhejiang Electric Power, 2025, 44(9): 13-20.
- [3] 周涛,姚嘉辰,倪俊,等.基于改进模糊自适应控制的风电机组逐步惯性最优控制策略[J].浙江电力,2025,44(11):35-47.
ZHOU Tao, YAO Jiachen, NI Jun, et al. An optimal stepwise inertial control strategy for wind turbines based on improved fuzzy adaptive control[J]. Zhejiang Electric Power, 2025, 44(11): 35-47.
- [4] 李俊卿,韩小平,黄涛,等.基于 ISDP 和膨胀胶囊网络的风电机组齿轮箱故障诊断[J].智慧电力,2025,53(3):27-34.
LI Junqing, HAN Xiaoping, HUANG Tao, et al. Fault diagnosis of wind turbine gearbox based on ISDP and dcapsnet[J]. Smart Power, 2025, 53(3): 27-34.
- [5] 李丰能,杨苹,隗知初,等.考虑风机调频能量差异的风电场频率主动支撑控制策略[J].电力建设,2025,46(11):145-157.
LI Fengneng, YANG Ping, WEI Zhichu, et al. Active frequency support control strategy for wind farm considering the energy discrepancy of wind turbines[J]. Electric Power Construction, 2025, 46(11): 145-157.
- [6] 马强,尹纯亚,秦艳辉,等.考虑暂态过电压约束的直流闭锁故障下送端风电调切策略[J].电力建设,2025,46(12):159-169.
MA Qiang, YIN Chunya, QIN Yanhui, et al. Considering the switching strategy of the transmitting wind power to deal with the dc blocking fault under the constraint of transient overvoltage[J]. Electric Power Construction, 2025, 46(12): 145-157.
- [7] 陈小乾,尹亮,展宗辉,等.基于注意力机制和 RCN-BiLSTM 融合的风电机组故障识别[J].中国电力,2025,58(8):94-102.
CHEN Xiaoqian, YIN Liang, ZHAN Zonghui, et al. Fault identification for wind turbine based on attention mechanism and rcn-bilstm fusion[J]. Electric Power, 2025, 58(8): 94-102.
- [8] 王晓东,李清,付德义,等.基于卷积双向长短期记忆网络的风电机组传动系统疲劳载荷预测[J].中国电力,2025,58(4):90-97.
WANG Xiaodong, LI Qing, FU Deyi, et al. Fatigue load prediction of wind turbine drive train based on cnn-bilstm[J]. Electric Power, 2025, 58(4): 90-97.
- [9] 樊家伟,郭瑜,伍星,等.基于 LSTM 神经网络和故障特征增强的行星齿轮箱故障诊断[J].振动与冲击,2021,40(20):271-277.
FAN Jiawei, GUO Yu, WU Xing, et al. Fault diagnosis of planetary gearbox based on LSTM neural network and enhanced fault feature[J]. Journal of Vibration and Shock, 2021, 40(20): 271-277.
- [10] ZHANG D. Fundamentals of image data mining: analysis, features, classification and retrieval[M]. Cham: Springer International Publishing, 2019.
- [11] REHMAN N, MANDIC D. Multivariate empirical mode

- decomposition[J]. Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2010, 466(2117):1291-1302.
- [12] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2013, 62(3):531-544.
- [13] 雷春丽, 焦孟萱, 樊高峰, 等. 基于SSA-IWT-EMD的滚动轴承故障诊断方法[J]. 北京航空航天大学学报, 2025, 51(4): 1152-1162.
- LEI Chunli, JIAO Mengxuan, FAN Gaofeng, et al. Rolling bearing fault diagnosis method based on SSA-IWT-EMD[J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(4): 1152-1162.
- [14] 向明胜, 冯坤, 贾韶辉, 等. 强噪声条件下基于EMD-AE优选特征的离心泵多故障诊断方法[J]. 振动与冲击, 2024, 43(23): 66-74.
- XIANG Mingsheng, FENG Kun, JIA Shaohui, et al. Multi-fault diagnosis method for centrifugal pumps based on EMD-AE optimal selected features under strong noise conditions[J]. Journal of Vibration and Shock, 2024, 43(23): 66-74.
- [15] 张龙, 毛志德, 熊国良, 等. 滚动轴承故障诊断的自适应包络谱谱峰因子算法[J]. 机械科学与技术, 2019, 38(4): 507-514.
- ZHANG Long, MAO Zhide, XIONG Guoliang, et al. Adaptive fault diagnosis of rolling bearings based on crest factor of envelope spectrum[J]. Mechanical Science and Technology for Aerospace Engineering, 2019, 38(4): 507-514.
- [16] 范兴明, 许洪华, 李涛, 等. 基于SMA-VMD和能量熵的高压断路器故障诊断[J]. 高压技术, 2024, 50(12): 5248-5258.
- FAN Xingming, XU Honghua, LI Tao, et al. Fault diagnosis of high-voltage circuit breakers based on SMA-VMD and energy entropy[J]. High Voltage Engineering, 2024, 50(12): 5248-5258.
- [17] MIAO Y, ZHANG B, LI C, et al. Feature mode decomposition: new decomposition theory for rotating machinery fault diagnosis[J]. IEEE Transactions on Industrial Electronics, 2022, 70(2): 1949-1960.
- [18] 李国洪, 李智, 王鹏, 等. 基于IEGWO-VMD的滚动轴承故障诊断策略[J]. 天津理工大学学报, 2025, 41(6): 21-28.
- LI Guohong, LI Zhi, WANG Peng, et al. Rolling bearing fault diagnosis strategy based on IEGWO-VMD[J]. Journal of Tianjin University of Technology, 2025, 41(6): 21-28.
- [19] WANG L, SONG X, JIANG W. Differential protection scheme for distribution network with distributed generation based on improved feature mode decomposition and derivative dynamic time warping [J]. Frontiers in Energy Research, 2024, 12: 1369880.
- [20] SOWMYA R, PREMKUMAR M, JANGIR P. Newton-Raphson-based optimizer: A new population-based metaheuristic algorithm for continuous optimization problems[J]. Engineering Applications of Artificial Intelligence, 2024, 128: 107532.
- [21] 黄琦, 陈海洋, 刘妍, 等. 基于多策略融合灰狼算法的移动机器人路径规划[J]. 空军工程大学学报, 2024, 25(3): 112-120.
- HUANG Qi, CHEN Haiyang, LIU Yan, et al. A mobile robot path planning based on multi-strategy fusion gray wolf algorithm[J]. Journal of Air Force Engineering University, 2024, 25(3): 112-120.
- [22] 刘智飞, 马可欣. 柔性车间双资源集成调度的小生境遗传算法优化[J]. 制造技术与机床, 2023(8): 32-38.
- LIU Zhifei, MA Kexin. Integrated scheduling optimization of two resources in flexible job-shop based on niche genetic algorithm[J]. Manufacturing Technology & Machine Tool, 2023(8): 32-38.

(责任编辑 钱文姝)

收稿日期: 2025-04-21; 修改日期: 2025-12-25

作者简介: 龙霞飞(1986), 女, 湖南邵阳人, 博士、讲师, 主要从事新能源运维、新能源故障诊断方面的研究。E-mail: 304010851@qq.com

刘伟强(2001), 男, 通信作者, 湖南娄底人, 硕士研究生, 主要研究新能源故障诊断方面等方向。E-mail: 2219473428@qq.com

Wind Turbine Gearbox Fault Diagnosis Based on INRBO-optimized FMD

LONG Xiafe¹, LIU Weiqiang¹, LUO Zhaoxu¹, HE Zhicheng¹, ZHANG Bin¹,
XIE Xinyu¹, WU Xiwen²

(1. College of Transportation and Electrical Engineering, Hunan University of Technology, Zhuzhou 412007, China; 2. Guodian Power Hunan New Energy Development Co., Ltd., Changsha 410125, China)

Abstract: To address the difficulty in extracting fault features of planetary gearboxes, this paper proposes a gearbox fault diagnosis method that uses an improved Newton-Raphson-based optimization (INRBO) algorithm to optimize the parameters of feature mode decomposition (FMD). First, a multi-strategy improvement approach is proposed to comprehensively enhance the optimization performance of NRBO. Then, the adaptive parameters of FMD are optimized using INRBO to construct a wind turbine gearbox fault diagnosis model based on INRBO-FMD. Finally, the improved method is applied to perform adaptive feature mode decomposition on the raw vibration signals of the gearbox, and fault diagnosis research is conducted on the planetary gearbox. Experimental results show that the proposed INRBO-FMD method can effectively extract the characteristic fault frequencies and harmonic components, verifying its accuracy and practicability.

Key words: gearbox; fault diagnosis; feature mode decomposition; INRBO; composite chaotic mapping; niching technology