基于智能优化算法的变分模态分解参数 优化对比研究

楼志鹏^{1,2},杨丹丹²,陈思源²,赵 军^{1,2},孔维宾^{2*},邵宇成²

1盐城工学院优培学院,江苏 盐城 2盐城工学院信息工程学院,江苏 盐城

收稿日期: 2024年10月18日; 录用日期: 2024年11月11日; 发布日期: 2024年11月18日

摘要

变分模态分解(Variational Mode Decomposition, VMD)作为一种有效的信号分解工具,已被广泛应用。 然而,VMD的分解效果高度依赖于其参数的选择,参数优化对提高信号分解能力至关重要。本研究旨 在通过智能优化算法对VMD的关键参数进行优化,并对比不同算法的性能表现。具体而言,本文采用 了海洋掠食者算法、小龙虾算法和非洲秃鹰优化算法来优化VMD的参数,并将其应用于机械故障诊断。 通过对比实验结果,分析各算法在故障诊断中的应用效果与优劣,为VMD参数优化提供了理论依据和 实践指导。

关键词

变分模态分解,参数优化,智能优化算法,故障诊断

Comparative Study on Parameter Optimization of Variational Mode Decomposition Based on Intelligent Optimization Algorithm

Zhipeng Lou^{1,2}, Dandan Yang², Siyuan Chen², Jun Zhao^{1,2}, Weibin Kong^{2*}, Yucheng Shao²

¹Youpei College, Yancheng Institute of Technology, Yancheng Jiangsu ²School of Information Engineering, Yancheng Institute of Technology, Yancheng Jiangsu

Received: Oct. 18th, 2024; accepted: Nov. 11th, 2024; published: Nov. 18th, 2024

*通讯作者。

文章引用: 楼志鹏,杨丹丹,陈思源,赵军,孔维宾,邵宇成.基于智能优化算法的变分模态分解参数优化对比研究 [J]. 建模与仿真,2024,13(6):6009-6018. DOI: 10.12677/mos.2024.136550

Abstract

Variational Mode Decomposition (VMD) has been widely used as an effective signal decomposition tool. However, the decomposition effect of VMD is highly dependent on the selection of its parameters, and parameter optimization is crucial for improving signal decomposition capability. This paper aims to optimize the key parameters of VMD through intelligent optimization algorithms and compare the performance of different algorithms. Specifically, this paper uses the Marine Predators Algorithm (MPA), Crayfish Algorithm (COA), and African Vulture Optimization Algorithm (AVOA) to optimize the parameters of VMD and apply them to mechanical fault diagnosis. By comparing experimental results, the application effects and advantages and disadvantages of various algorithms in fault diagnosis are analyzed, providing theoretical basis and practical guidance for VMD parameter optimization.

Keywords

Variational Mode Decomposition, Parameter Optimization, Intelligent Optimization Algorithm, Fault Diagnosis

Copyright © 2024 by author(s) and Hans Publishers Inc. This work is licensed under the Creative Commons Attribution International License (CC BY 4.0). <u>http://creativecommons.org/licenses/by/4.0/</u>

CC Open Access

1. 引言

在机械设备故障诊断、地震信号分析以及生物医学信号处理等领域,信号分解技术[1]作为一种有效的工具,得到了广泛的应用。变分模态分解(Variational Mode Decomposition, VMD) [2]作为一种新的自适应信号分解方法,能够将复杂的非平稳信号分解为若干个具有物理意义的本征模态函数(Intrinsic Mode Functions, IMFs),因此在处理多分量信号方面展现出良好的性能。然而,VMD 的性能在很大程度上依赖于其参数的选取,尤其是分解模态数与惩罚因子的设置[3]。参数选择不当可能导致分解结果失真或模态 混叠,从而影响故障诊断与信号分析的准确性。

为了解决 VMD 参数优化问题,近年来,智能优化算法[4]逐渐引起了研究者的关注。这些算法以群体智能和随机搜索为基础,能够有效避免传统优化方法易陷入局部最优的缺陷,具有全局寻优能力强、 计算效率高等优点。王洪涛等人[5]为了改善 VMD 在单通道语音增强中关键参数选择难、声学特征缺失 多的问题,提出了一种 BDO 与 VMD-EAM 算法融合的单通道语音增强模型,具有良好的效果。唐宇峰 等人[6]提出一种改进的白鲸优化算法(Beluga Whale Optimization with Stranding Phase, BWOSP),利用 BWOSP-VMD 得到(*K*,*α*)最优参数组合进行信号分解,最后采用深度学习方法进行机械故障诊断,实验 表明,这种方法能够有效对含有噪声的机械信号降噪,并准确故障诊断。杨浩越等人[7]提出了一种基于 星鸦优化算法(Nutcracker Optimization Algorithm, NOA)优化 VMD 的炮口冲击波谐振噪声降噪算法,也具 有不错的效果。常见的智能优化算法包括遗传算法(Genetic Algorithm, GA) [8]、粒子群优化算法(Particle Swarm Optimization, PSO) [9]等。然而,随着优化需求的不断增加,新的优化算法不断涌现并表现出优越 的性能。

本研究拟采用三种新型的智能优化算法,即海洋捕食者算法(Marine Predators Algorithm, MPA) [10]、 小龙虾算法(Crayfish Optimization Algorithm, COA) [11]以及非洲秃鹫算法(African Vulture Optimization Algorithm, AVOA) [12],对 VMD 的关键参数进行优化。通过这三种算法的对比分析,探讨其在信号分解中的表现及优缺点,从而为实际应用中 VMD 参数的优化提供新的思路和参考。这些算法不仅各自具备独特的优化机制,还能够在复杂、多模态的优化问题中展现出良好的适应性和稳健性,因而非常适合用于 VMD 参数的优化任务。

2. 理论基础

2.1. 变分模态分解

变分模态分解(VMD)通过构建一个变分问题,将原始信号分解为若干个本征模态函数(IMFs)。信号 f(t)分解为 K 个本征模态函数(IMF) $u_k(t)$,每个 IMF 为幅度调制 – 频率调制信号,其形式为:

$$u_{k}(t) = A_{k}(t)\cos\left[\phi_{k}(t)\right] \tag{1}$$

其中, $A_k(t)$ 为瞬时幅度, $\phi_k(t)$ 为瞬时相位。

通过最小化每个模态的带宽来进行分解,带宽通过模态的 Hilbert 变换来估计。VMD 构建的变分模型为:

$$\min_{u_{k},\omega_{k}}\left\{\sum_{k=1}^{K}\left\|\partial_{t}\left[\left(\delta(t)+\frac{j}{\pi t}\right)*u_{k}(t)\right]e^{-j\omega_{k}t}\right\|^{2}\right\}$$
(2)

约束条件为:

$$f(t) = \sum_{k=1}^{K} u_k(t)$$
(3)

其中, ω_k 为各模态分量的中心频率, $\delta(t)$ 为单位脉冲函数。

为解决上述带约束的优化问题,引入拉格朗日乘子 $\lambda(t)$ 和惩罚因子 α ,构造拉格朗日函数:

$$L(\lbrace u_k \rbrace, \lbrace \omega_k \rbrace, \lambda(t)) = \alpha \sum_{k=1}^{K} \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \left\| f(t) - \sum_{k=1}^{K} u_k(t) \right\|_2^2 + \left\langle \lambda(t), f(t) - \sum_{k=1}^{K} u_k(t) \right\rangle$$
(4)

式中:L为拉格朗日函数; $\langle \bullet \rangle$ 表示两个函数的内积。

利用交替方向乘子法(ADMM)算法进行迭代更新,分别更新模态函数 u_k 和中心频率 ω_k 。更新公式为:模态更新:

$$\hat{u}_{k}^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_{i}^{n}(\omega) + \hat{\lambda}(\omega)/2}{1 + 2\alpha \left(\omega - \omega_{k}^{n}\right)^{2}}$$
(5)

拉格朗日乘子更新:

$$\lambda^{n+1}(t) = \lambda^n(t) + \tau \left(f(t) - \sum_{k=1}^K u_k^{n+1}(t) \right)$$
(6)

式中, \hat{u}_k^{n+1} 为第n+1次迭代的第k个 IMF 在频域中的表示, $\hat{f}(\omega)$ 为f(t)的傅里叶变换。 $\lambda^{n+1}(t)$ 为第n+1次迭代的拉格朗日乘子在频域中的表示, τ 为 λ 的更新步长。

当模态更新的误差小于设定的阈值 ε 时,停止迭代。

2.2. 小龙虾优化算法

COA 算法的设计灵感来源于淡水小龙虾在觅食、夏季避暑和竞争中的行为。该算法的执行过程分为 三个阶段: 避暑、竞争和觅食阶段。

2.2.1. 避暑阶段

环境的变化会使小龙虾感受到不同的刺激量。在适应环境的过程中,小龙虾对温度变化表现出高度 敏感。COA 算法中,细胞刺激量由 *temp* 参数进行定义。当环境温度低于 25℃时,小龙虾的感知能力降 低,运动较为缓慢;当温度高于 25℃时,感知能力增强,运动加快。其计算公式如下:

$$temp = 15 \times rand + 20 \tag{7}$$

其中, rand 是取值范围为0到1之间的随机数。

当温度超过 30℃时,小龙虾会进入避暑模式,表现出趋向避开危险区域的行为。此时,它会根据自身位置与猎物位置进行移动调整,其计算公式如下:

$$X_{shade} = \frac{X_G + X_L}{2} \tag{8}$$

其中, *X_L*表示小龙虾当前位置, *X_G*是迭代过程中产生的最佳位置。通过这一公式,小龙虾会逐渐向安全区域移动。同时,小龙虾的速度和位置更新公式如下:

$$X_{i,j}^{t+1} = X_{i,j}^{t} + C_2 * rand * \left(X_{shade} - X_{i,j}^{t}\right)$$
(9)

$$C_2 = 2 - \frac{t}{T} \tag{10}$$

其中, *C*₂表示趋向系数, *t* 是当前迭代次数, *T* 是总迭代次数。这个阶段模拟了小龙虾在感知危险后进行的躲避行为。

2.2.2. 竞争阶段

当温度高于 30℃且 rand ≥0.5 时,小龙虾会进入竞争模式。此时,小龙虾之间会相互竞争,争夺食物 资源。每只小龙虾会根据其周围同类的位置信息调整自己的位置,计算公式如下:

$$X_{i,j}^{t+1} = X_{i,j}^{t} - X_{z,j}^{t} - X_{shade}$$
(11)

$$z = round (rand * B - 1) + l \tag{12}$$

其中, *X^t_{z,j}*表示其他小龙虾的位置, *z*表示另一种随机的小龙虾个体, *B*为小龙虾种群数量。通过这一策略, 小龙虾能够在竞争中不断更新位置, 提高食物资源的获取效率。

2.2.3. 觅食阶段

当温度低于 30℃时,小龙虾将进入觅食阶段。小龙虾在觅食过程中,会不断更新其位置以最大化食物的摄入量。此时,移动策略为随机选择目标位置进行移动,其更新公式为:

$$X_{food} = X_{good} + rand \times F \times (2 \times \pi - rand)$$
⁽¹³⁾

$$X_i^{j+1} = X_i^j + p \times F \times \left(X_{food} - X_i^j\right)$$
⁽¹⁴⁾

其中, X_{good} 表示食物源的最佳位置, p 为自适应系数, F 为环境适应度。通过这一策略, 算法可以有效 模拟小龙虾的觅食行为, 并在搜索过程中持续更新位置, 提高搜索效率。

2.3. 海洋捕食者算法

海洋捕食者算法(MPA)模拟了捕食者和猎物在海洋中不同速度比下的运动差异。根据迭代的时间进程,该算法将搜索过程划分为高速比、单位速比和低速比三个阶段,以模拟捕食者捕捉猎物的行为。其优化过程如下。

2.3.1. 高速比阶段

此阶段发生在*t* < T/3时(t 表示当前迭代次数,T 是最大迭代数),其位置更新如下所示:

$$\begin{cases} stepsize_i = R_B \otimes (E_i - R_B \otimes Prey_i) \\ Prey_i = Prey_i + P \times R \otimes stepsize_i \end{cases} i = 1, 2, \dots, N$$
(15)

其中, Prey_i 为通过初始化种群形成猎物矩阵, stepsize_i 表示移动步长, R_B 表示布朗运动, 是基于非正态 分布的随机向量。P 是常数, 数值为 0.5, R 表示[0, 1]之间的随机均匀分布值。

2.3.2. 单位速度比阶段

此阶段为迭代中期,发生在*T*/3≤*t*≤2*T*/3时,猎物种群通过莱维方式移动,捕食者种群通过布朗运动进行移动。模型如下所示:

$$\begin{cases} stepsize_i = R_L \otimes (Elite_i - R_L \otimes Prey_i) \\ Prey_i = Prey_i + P \times R \otimes stepsize_i \end{cases} i = 1, 2, \dots, N/2$$
(16)

$$\begin{cases} stepsize_i = R_B \otimes (Elite_i - R_B \otimes Prey_i) \\ Prey_i = Elite_i + P \times CF \otimes stepsize_i \end{cases} i = N/2, \dots, N$$
(17)

$$CF = \left(1 - \frac{t}{T}\right)^{\frac{2t}{T}} \tag{18}$$

其中 $Elite_i$ 为精英个体初始位置。 R_L 是基于莱维运动生成的随机向量,CF 为自适应参数, $stepsize_i$ 表示 控制捕食者的移动步长。

2.3.3. 低速比阶段

该阶段发生在t>2T/3时,此时捕食者以莱维方式运动,其位置更新的数学模型如下所示:

$$\begin{cases} stepsize_i = R_L \otimes (Elite_i - R_L \otimes Prey_i) \\ Prey_i = Elite_i + P \times CF \otimes stepsize_i \end{cases} i = 1, 2, \dots, N$$

$$(19)$$

2.3.4. FADs 效应或涡流

在捕食者的捕食过程中,涡流的形成和鱼类聚集装置(FADs)会改变捕食者觅食行为,导致捕食者可能陷入局部最优解。为了解决这一问题,策略中引入了较长的跳跃,以克服早熟收敛的现象,避免陷入局部最优。其数学模型如下所示:

$$Prey_{i} = \begin{cases} Prey_{i} + CF \times (X_{min} + R_{L} \otimes (X_{max} - X_{min})) \otimes U, r \leq FADs \\ Prey_{i} + [FADs(1 - r) + r](Prey_{r1} - Prey_{r2}), r > FADs \end{cases}$$
(20)

其中, *X_{min}*和 *X_{max}*为维度的上下边界, *FADs* 是优化过程的影响概率,取 0.2, *r* 是[0, 1]中均匀分布的随 机数, *Prey_{r1}*和 *Prey_{r2}*为随机猎物位置。

2.4. 非洲秃鹫优化算法

非洲秃鹫优化算法(AVOA)是通过模拟非洲秃鹫的觅食行为和生活习性提出的一种优化算法。在 AVOA 中,秃鹫的行为被分为四个主要阶段。

2.4.1. 随机选择最佳秃鹫

在种群初始化后,首先计算每个个体的适应度值,根据适应度值选择最优秃鹫和次优秃鹫。计算公 式如下:

$$R(i) = \begin{cases} BestV_1, \ p_i = L_1 \\ BestV_2, \ p_i = L_2 \end{cases}$$
(21)

其中, $BestV_1$, $BestV_2$ 分别为最优和次优秃鹫。 L_1 和 L_2 为0和1之间的数,且两个参数之和为1,为搜 索操作之前给定的参数。 p_i 为概率参数。

2.4.2. 计算秃鹫的饥饿率

秃鹫的饥饿率计算如下。

$$t_1 = h \times \left(\sin \omega \left(\frac{\pi}{2} \times \frac{t}{T} \right) + \cos \left(\frac{\pi}{2} \times \frac{t}{T} \right) - 1 \right)$$
(22)

$$F = \left(2 \times rand_1 + 1\right) \times z \times \left(1 - \frac{t}{T}\right) + t$$
(23)

其中, F 表示饥饿率, t 表示当前迭代次数, T 表示最大迭代次数, $z \in [-1,1]$, $h \in [-2,2]$, $rand_1 \in [0,1]$ 。

2.4.3. 探索阶段

当 F 的绝对值大于 1 时,算法进入探索阶段。其迭代过程如下:

$$P(i+1) = \begin{cases} R(i) - |XR(i) - P(i)|F, P_1 \ge rand_{p_1} \\ R(i) - F + r_2(ub - lb)r_3 + lb, P_1 < rand_{p_1} \end{cases}$$
(24)

其中, X 为秃鹫随机移动的位置, P(i) 为当前位置, lb 和ub 分别为寻优边界的上下界。 r_2 为 0 和 1 之间 随机数, r_3 是用于增加随机性系数。

2.4.4. 开发阶段

当 0.5≤|F|<1时, AVOA 进入开发阶段的第一阶段。在第一阶段, 如果 *rand*_{p2} 小于 P_2 则实施缓慢围 攻策略;反之则执行旋转飞行策略。

$$P(i+1) = \begin{cases} XR(i) - P(i) | (F+r_4) - R(i) + P(i), \text{ if } P_2 \ge rand_{p_2} \\ R(i) - \left[R(i) \frac{r_5 P(i)}{2\pi} \cos P(i) + R(i) \frac{r_6 P(i)}{2\pi} \sin P(i) \right], \text{ if } P_2 < rand_{p_2} \end{cases}$$
(25)

在开发的第二阶段,秃鹫开始聚集开始围攻和争夺食物。该过程如下。 当 *rand*_{p3} < *P*₃ 时,秃鹫在食物源处聚集,表现形式如下:

$$P(i+1) = \frac{A_1 + A_2}{2}$$
(26)

$$A_{1} = BestV_{1}(i) - \frac{BestV_{1}(i) \times P(i)}{BestV_{1}(i) - P(i)^{2}} \times F$$

$$A_{2} = BestV_{2}(i) - \frac{BestV_{2}(i) \times P(i)}{BestV_{2}(i) - P(i)^{2}} \times F$$
(27)

当 $rand_{n3} \ge P_3$ 时,秃鹫进入争夺食物阶段。

$$P(i+1) = R(i) - |R(i) - P(i)| \times F \times Levy(d)$$
⁽²⁸⁾

其中, Levy(d)为莱维飞行函数。

2.5. 基于智能算法的 VMD 参数优化过程

在信号分解中,包络熵(Envelope Entropy, EE)是一种用于衡量信号复杂性和信息量的指标[13]。较低的包络熵意味着信号的模态分解结果更加集中和清晰,因此可以作为 VMD 参数优化的目标。本文以最小包络熵为目标函数,通过三种智能算法进行 VMD 参数优化,找到一组最优的参数。参数优化 VMD 流程如下:

初始化:根据每种智能优化算法的机制,初始化 VMD 参数 $\{K, \alpha\}$ 。

VMD 分解:进行 VMD 分解,获取每个模态的瞬时包络。

包络熵计算:计算当前分解结果的包络熵值。

优化迭代:智能优化算法根据当前包络熵的大小调整参数,继续迭代,直到找到最优解。

终止条件: 当达到最大迭代次数时停止优化, 输出最优的 VMD 参数。

3. 参数优化 VMD 分析

3.1. 实验设置

本文使用一段长度为 2048 的信号数据作为分解对象,设置每种算法迭代次数为 15,初始种群数量 为 10,惩罚因子 α 范围为[200, 3500],分解数 K 为[2, 10]。如图 1 所示为该信号的时域波形图。



Figure 1. Time domain waveform of the signal 图 1. 信号的时域波形

3.2. 信号分解结果

三种算法优化的 VMD 参数结果如表 1 所示。其迭代曲线如图 2 所示。

 Table 1. Results of VMD parameters optimised by the three algorithms

 表 1. 三种算法优化的 VMD 参数结果

算法	最优参数		叶问八、
	α	K	口J [HJ(S)
СОА	257	6	76.9
MPA	253	6	143.1
AVOA	950	6	82.3

从表 1 中可以看出,通过 COA、MPA、AVOA 三种算法对 VMD 参数的优化,得到了不同的最优参数组合。COA 与 MPA 参数寻优结果几乎相同,AVOA 为α=950、*K*=6。三种算法在计算时间上的差异也较为明显,COA 的计算时间最短,仅为 76.9 秒,AVOA 次之为 82.3 秒,而 MPA 的时间最长,达到 143.1 秒。



Figure 2. Convergence profile of parameter optimised VMDs 图 2. 参数优化 VMD 的收敛曲线图

从图 2 的迭代曲线可以看出, COA 算法在整个迭代过程中表现出极高的收敛效率, 目标函数值趋于 稳定且波动较小。相比之下, AVOA 的收敛速度相对较慢, 且精度最低。MPA 收敛精度最高。

总体而言,尽管 MPA 能够取得最优的收敛精度,但其所用时间最长,因此,COA 在优化 VMD 参数时表现出了最好的收敛效果和效率。

4. 在轴承故障诊断中的应用

为了验证参数优化 VMD 方法在实际工程中的应用,本文基于此方法进行了轴承故障信号的诊断实验。

4.1. 数据集介绍

凯斯西储大学(Case Western Reserve University, CWRU)轴承数据集是旋转机械故障诊断领域中广泛 使用的标准数据集之一[14][15]。该数据集通过在电机驱动端和风扇端安装故障轴承,并在不同运行工况 下采集振动信号。故障类型包括内圈故障、外圈故障、滚动体故障,以及健康轴承状态。故障程度通过 在轴承上加工不同直径的缺陷(如 0.007、0.014、0.021 英寸)来模拟。数据集包含多个工况下的采样数据, 转速为 1797、1772、1750 和 1730 RPM,采样频率为 12 kHz 和 48 kHz,覆盖了不同负载条件下的运行状 态。本文选择 1PH 负载工况下的内圈,外圈,滚动体和正常状况下的四种信号进行实验,每种信号采集 100 组样本,每组样本由 2048 个采样点组成。

4.2. 故障诊断结果

首先基于三种不同的优化算法对 VMD 进行参数优化,并基于优化结果提取各 IMF 分量;接着,计

算每个 IMF 的能量熵作为故障特征,按照 7:3 的比例划分训练集与测试集,最后采用支持向量机(SVM) 对能量熵特征进行故障分类。同时,为了验证基于智能优化算法参数优化方法的有效性,本文采用未经 参数优化的 VMD 的故障诊断实验进行对比,实验结果如下。

方法	准确率
COA-VMD-SVM	99.67
MPA-VMD-SVM	98.33
AVOA-VMD-SVM	99.17
VMD-SVM	94.67

 Table 2. Comparison of fault diagnosis experiments of VMD optimized by different algorithms

 表 2.
 不同算法优化的 VMD 的故障诊断实验对比

从表 2 中可以看出,经过参数优化的 VMD 显著提升了故障诊断的准确率,尤其是 COA-VMD-SVM 和 AVOA-VMD-SVM 的准确率接近 100%。这说明智能优化算法在提升 VMD 分解效果及故障诊断准确 性方面具有重要作用。未经优化的 VMD-SVM 方法表现相对较差,进一步验证了优化算法在参数选择中 的有效性。

5. 结论

本文通过对多种智能优化算法在变分模态分解参数优化中的应用进行了深入研究,分别采用了海洋 捕食者算法、小龙虾算法和非洲秃鹫算法(AVOA)对 VMD 的关键参数进行优化。实验结果表明,不同的 优化算法在收敛速度、全局搜索能力以及对不同故障信号的适应性上表现各异。通过真实信号的故障诊 断实验对比分析,基于智能优化算法的参数优化 VMD 方法能够显著提高故障诊断准确率,具有良好的 效果。

随着机器学习和深度学习技术的快速发展,智能优化算法与 VMD 相结合的故障诊断技术将具有更 广阔的应用前景。未来研究可以在以下几个方面进一步探索:1) 开发更高效的混合智能优化算法,结合 不同算法的优势以提高参数优化的精度和效率;2) 考虑非平稳、非线性信号的特征,设计自适应 VMD 算法,以应对复杂工况下的信号分析;3) 引入深度学习模型,结合 VMD 进行多层次特征提取和故障分 类,提高诊断系统的智能化水平和鲁棒性。总之,通过智能优化与 VMD 技术的深度融合,能够进一步推 动故障诊断领域的发展,为旋转机械及其他复杂系统的健康管理提供更加精准和高效的解决方案。

基金项目

大学生创新创业训练计划资助项目(202410305127Y)。

参考文献

- [1] 李宏仲, 叶翔宇, 付国. 信号分解技术在新能源发电功率预测中的应用评述[J]. 南方电网技术, 2023, 17(4): 3-15.
- [2] Dragomiretskiy, K. and Zosso, D. (2014) Variational Mode Decomposition. *IEEE Transactions on Signal Processing*, 62, 531-544. <u>https://doi.org/10.1109/tsp.2013.2288675</u>
- [3] 张晓莉, 黄嘉谞. 参数优化 VMD 结合改进小波包阈值的去噪方法[J]. 噪声与振动控制, 2024, 44(5): 128-132.
- [4] 翁志明, 高玺炜, 李晓英. 基于改进智能算法水库群防洪优化调度研究[J]. 人民黄河, 2024, 46(9): 132-135, 155.
- [5] 王洪涛, 毛露露. BDO 与 VMD-EAM 算法融合的单通道语音增强模型[J]. 自动化与仪表, 2024, 39(9): 131-137.

- [6] 唐字峰,曹睿,胡光忠,等.融合 BWOSP-VMD-TOPSIS 降噪和深度学习的旋转机械故障诊断[J/OL]. 安全与环 境学报: 1-12. https://doi.org/10.13637/j.issn.1009-6094.2024.0537, 2024-09-27.
- [7] 杨浩越, 孟祥瑞, 鞠明池, 等. 基于 NOA-VMD 的炮口冲击波谐振噪声降噪算法[J]. 弹箭与制导学报, 2024, 44(4): 9-17.
- [8] 龙艳. 基于改进遗传算法的饲料配方多目标优化研究[J]. 粮食与饲料工业, 2024(3): 47-51.
- [9] Marini, F. and Walczak, B. (2015) Particle Swarm Optimization (PSO). A Tutorial. Chemometrics and Intelligent Laboratory Systems, 149, 153-165. <u>https://doi.org/10.1016/j.chemolab.2015.08.020</u>
- [10] Faramarzi, A., Heidarinejad, M., Mirjalili, S. and Gandomi, A.H. (2020) Marine Predators Algorithm: A Nature-Inspired Metaheuristic. *Expert Systems with Applications*, **152**, Article ID: 113377. <u>https://doi.org/10.1016/j.eswa.2020.113377</u>
- [11] Jia, H., Rao, H., Wen, C. and Mirjalili, S. (2023) Crayfish Optimization Algorithm. Artificial Intelligence Review, 56, 1919-1979. <u>https://doi.org/10.1007/s10462-023-10567-4</u>
- [12] Abdollahzadeh, B., Gharehchopogh, F.S. and Mirjalili, S. (2021) African Vultures Optimization Algorithm: A New Nature-Inspired Metaheuristic Algorithm for Global Optimization Problems. *Computers & Industrial Engineering*, 158, Article ID: 107408. <u>https://doi.org/10.1016/j.cie.2021.107408</u>
- [13] 单玉庭, 刘韬, 褚惟, 等. 遗传算法优化变分模态分解在轴承故障特征提取中的应用[J]. 噪声与振动控制, 2024, 44(1): 148-153, 204.
- [14] 夏逸飞,皋军,邵星,等. 基于多尺度知识蒸馏与增量学习的滚动轴承故障诊断方法[J]. 振动与冲击, 2024, 43(12): 276-285.
- [15] Smith, W.A. and Randall, R.B. (2015) Rolling Element Bearing Diagnostics Using the Case Western Reserve University Data: A Benchmark Study. *Mechanical Systems and Signal Processing*, 64, 100-131. <u>https://doi.org/10.1016/j.ymssp.2015.04.021</u>