Nov. 2024

DOI: 10. 13718/j. cnki. xdzk. 2024. 11. 016

袁耀, 黄克捷, 陈建兴, 等. 基于 WSO-VMD 样本熵和 SSA-SVM 算法的有载分接开关故障诊断方法研究 [J]. 西南大学学报(自然科学版), 2024, 46(11): 203-216.

# 基于 WSO-VMD 样本熵和 SSA-SVM 算法的 有载分接开关故障诊断方法研究

袁耀1, 黄克捷1, 陈建兴2, 鲍连伟1, 周渠2

1. 南方电网科学研究院有限责任公司,广州 510530; 2. 西南大学 工程技术学院,重庆 400715

摘要:有載分接开关(On-Load Tap-Changer, OLTC)作为变压器的重要机械结构部件,负责变压器分解绕组切换调压,随着服役时间增加或出厂缺陷等原因容易使其发生机械故障并造成电力系统重大经济损失,开展 OLTC 故障诊断方法研究对确保变压器本体及电力系统安全稳定运行具有重要意义. 搭建了 10 kV OLTC 典型缺陷模拟实验平台,开展了正常、弹簧断裂、弹簧疲软以及触头松动 4 种工况下的模拟实验,获得了 4 种不同工况的振动信号样本库. 针对 OLTC 振动信号特征提取不完整及故障识别准确率低的问题,以模态分量(IMF)的包络熵为目标函数,提出了基于大白鲨(WSO)优化变分模态分解(VMD)和样本熵的特征构建方法,利用 WSO 优化后的 VMD 模型对原始振动信号进行模态分解并构建样本熵特征向量,作为支持向量机(SVM)的输入开展 OLTC 故障识别研究. 研究结果表明:与经验模态分解(EMD)、集成经验模态分解(EEMD)、给定参数 VMD 的振动信号分解方法相比,基于 WSO-VMD 样本熵的 OLTC 振动信号特征信息更加丰富,故障识别准确率高达 95.83%. 为进一步提高OLTC 故障识别准确率,选用麻雀搜索(SSA)、粒子群(PSO)以及灰狼优化(GWO)算法分别对 SVM 进行参数寻优、结果表明:基于 WSO-VMD 样本熵和 SSA-SVM 算法的 OLTC 运行状态识别效果最好,对正常、弹簧断裂、弹簧疲软以及触头松动 4 种运行工况样本测试集的识别准确率为 100%,该算法具有较高的可行性以及有效性.

关键词: WSO-VMD 算法; 样本熵; SSA-SVM 算法;

有载分接开关;故障诊断

中图分类号: TM835 文献标志码: A

开放科学(资源服务)标识码(OSID): ☐

文章编号: 1673-9868(2024)11-0203-14

## Fault Diagnosis Method of OLTC Based on WSO-VMD Sample Entropy and SSA-SVM

YUAN Yao<sup>1</sup>, HUANG Kejie<sup>1</sup>, CHEN Jianxing<sup>2</sup>, BAO Lianwei<sup>1</sup>, ZHOU Qu<sup>2</sup>

收稿日期: 2024-02-02

基金项目: 南方电网科技项目(SEPRI-K22B030); 国家自然科学基金项目(52077177).

作者简介: 袁耀,博士,正高级工程师,主要从事电力设备智能检测研究.

- 1. South China Power Grid Scientific Research Institute Co. Ltd., Guangzhou 510530, China;
- 2. College of Engineering and Technology, Southwest University, Chongqing 400715, China

**Abstract:** On-Load Tap-Changer (OLTC), as an important mechanical structural component of transformer, is responsible for transformer decomposition winding switching and voltage regulation. With the increase of service time or factory defects, mechanical failure is prone to cause major economic losses in the power system. Research on fault diagnosis of OLTC is of great significance to ensure the safety and stability operation of power transformer. In this study, experimental test platform for typical defects of 10 kV OLTC was built, and four simulation experiments under normal condition, spring break, spring weakness and contact loosening were carried out and vibration signal samples were obtained. Aiming at the problems of incomplete feature extraction and low fault identification accuracy of OLTC vibration signals, this study took the envelope entropy of modal component IMF as the objective function and proposed a feature construction method based on Great White Shark (WSO) to optimize variational modal decomposition VMD and sample entropy. Based on the optimized VMD model of WSO, the original vibration signal was decomposed into modes and the sample entropy eigenvector was constructed, which was used as input of SVM to carry out OLTC fault identification research. It was found that compared with EMD, EEMD and VMD, the OLTC based on WSO-VMD sample entropy had more characteristic information, and the fault identification accuracy was as high as 95.83%. In order to further improve the accuracy of OLTC fault identification, SSA, PSO and GWO algorithm were selected to optimize the parameters of SVM respectively. The results showed that the OLTC operating state identification based on WSO-VMD sample entropy and SSA-SVM had the best effect. The recognition accuracy of the test set of four operating conditions, normal, spring break, spring weakness and contact loosening, was 100%. The proposed fault identification method based on WSO-VMD sample entropy feature extraction and SSA-SVM is feasible and effective for OLTC operating condition monitoring.

Key words: WSO-VMD; sample entropy; SSA-SVM; on-load tap-changer; fault diagnosis

有载分接开关(On-Load Tap-Changer, OLTC)作为变压器唯一可动的机械结构零部件,负责变压器带负载条件下改变分解绕组位置进而实现电压调节功能,其运行可靠性与电网供电稳定安全息息相关<sup>[1-3]</sup>. 但随着电网结构日益复杂以及服役时间增加或出厂缺陷等原因,导致 OLTC 机械故障频发,比如紧固件松动、机械卡涩、弹簧疲软断裂等故障<sup>[4]</sup>. 为了及时发现 OLTC 机械故障,保证电力系统供电安全稳定,有必要开展对 OLTC 机械故障诊断方法的研究. 尽管 OLTC 内部参与调压切换的机械结构复杂,但在进行切换时主要的零部件状态信息均可在检测到的振动信号波形中体现出来,例如槽轮制动异常产生开关滑动的故障导致出现 2 个振动脉冲,弹簧弱化导致振动峰值减小,驱动机构润滑不足导致振动波形出现毛刺现象<sup>[4-5]</sup>,因此基于振动信号的 OLTC 工况识别研究成为当前研究热点. 对 OLTC 振动信号进行分析不难发现,内部机械结构状态信息分布在多频率尺度上,因而选用合理、高效的特征提取方法成为 OLTC 故障诊断的关键点<sup>[6-7]</sup>.

近年来,随着自适应分解方法在非线性信号分析领域的广泛应用,许多学者提出了基于递归分解原理的非线性信号模态分解方法并应用于 OLTC 特征提取. 阳瑞霖等<sup>[8]</sup>采用 EMD 对原始 OLTC 振动信号进行模态分解,并选取前 5 个本征模态分量的能量特征作为 SVM 的输入样本对其机械故障进行诊断研究. 传统 EMD 虽能够自适应分解非线性信号,但是在分解过程中多次采用三次样条插值拟合,导致端点极值包络线发散从而使信号失真(端点效应),以及在求解包络时局部极值点在短时间内发生多次跳变,导致特征时间尺度划分不准确引起的子模态分量中心重叠现象(模态混叠)<sup>[8-10]</sup>. 杨波等<sup>[10]</sup>向原始信号中加入高斯白

噪声减小局部极值间距来解决 EMD 分解模态混叠的问题,这便是互补集合经验模态分解(CEEMD)方法.目前也有学者利用该方法对 OLTC 振动信号进行分析研究,但该方法仍难以对 OLTC 进行有效分解<sup>[11-12]</sup>.随着 Dragomiretskiy 等<sup>[13]</sup>提出基于非递归分解的变分模态分解方法,该方法能够在不丢失原始信号特征情况下,自适应更新各模态分量(IMF)的最优中心频率以及带宽,在处理非线性稳定信号方面得到了广泛的应用<sup>[14]</sup>.上述几种方法虽然在 OLTC 振动信号模态分解领域得到了广泛的应用,但都有模态分解时产生虚假分量、特征提取不完整等问题,从而导致 OLTC 故障模式识别存在误差.

目前针对基于振动信号的 OLTC 故障诊断主要有聚类分析、人工神经网络、隐马尔可夫模型、支持向量机(SVM)等模式识别算法. 周翔等<sup>[15]</sup>基于相空间重构法并利用 K-means 聚类法能够有效识别 OLTC 的故障隐患,但是相空间重构后样本维数增加导致计算量增大. 上海交通大学的曾全昊团队基于 OLTC 振动信号的相空间分布构建距离映射递归图作为 CNN 的特征输入,其训练的人工神经网络模型对 OLTC 故障模型具有良好的识别性能,对于轻微故障的识别表现出优异的识别准确率<sup>[16-18]</sup>. SVM 自身的算法学习能力强,具有优异的泛化性以及鲁棒性被逐渐引入 OLTC 振动信号模式识别领域中<sup>[7]</sup>.

针对 OLTC 状态特征提取不完整导致故障诊断识别准确率低的问题,本文提出了基于大白鲨(WSO)算法优化 VMD 参数模型和样本熵的 OLTC 振动信号特征提取方法,并利用 SVM 对 OLTC 不同工况进行分类识别。首先以 IMF 的最小包络熵作为目标函数,利用 WSO 优化 VMD 中的参数 K 和 a , 获得 OLTC 不同工况下振动信号最优分解 VMD 模型。利用优化后的 VMD 模型对 OLTC 振动信号进行分解获得 IMF 分量,并利用 IMFs 分量求解样本熵构建样本特征向量。最后利用 SVM 对 OLTC 运行工况进行分类识别。实验结果表明:相比于传统模态分解以及经验确定 VMD 模态分解法,WSO-VMD 法能够提取更丰富的 OLTC 内部机械零部件工作状态特征参数,并且搭建的 SSA-SVM 算法模型对 OLTC 不同工况表现出了优异的识别准确率。

## 1 方法原理分析

#### 1.1 变分模态 VMD 分解原理

VMD 分解的本质是通过寻找一组子模态分量并限制其中心频率和带宽,以实现非线性信号的自适应分解. 该分解法将经典维纳滤波器推广至多个适应波段,并采用交替方向乘子法对变分模型进行有效优化,使其对采样噪声的鲁棒性更强. VMD 以模态分量中心频率带宽  $\omega_k$  之和最小以及模态分量之和等于原始信号为约束条件,将原始信号分解为不同频率段的 K 个子模态,其约束方程如下:

$$\begin{cases}
\min\left\{\sum_{k=1}^{u_{k}, w_{k}} \| \partial_{t} \left[\delta(t) + j/(\pi t) \times u_{k}(t)\right] e^{-jw_{k}t} \|_{2}^{2}\right\} \\
\text{s. t. } \sum_{k=1}^{\infty} u_{k} = f
\end{cases} \tag{1}$$

式中: K 为模态数;  $u_k$  为模态分量;  $w_k$  为各模态分量对应中心频率. 引入惩罚因子 a 以及 Largrange 算子  $\lambda$ , 将变分约束问题转化为非约束性问题进行求解. Largrange 函数为:

$$L(\{u_{k}, w_{k}, \lambda\}) = a \sum \|\partial_{t}[\delta(t) + j/(\pi t) \times u_{k}(t)] e^{-jw_{k}t} \|_{2}^{2} + \|f(t) - \sum_{k} u_{k}(t)\|_{2}^{2} + \langle \lambda(t), f(t) - \sum_{k} u_{k}(t) \rangle$$
(2)

采用交替乘子方向法(Alternate Direction Method of Multipliers, ADMM) 对  $u_k^{n+1}$ ,  $\omega_k^{n+1}$ ,  $\lambda_k^{n+1}$  进行迭代优化, 为求解 Largrange 鞍点, 采用如下步骤:

步骤 1 初始化 $\{u_k^1\}$ ,  $\{\omega_k^1\}$ ,  $\lambda_k^1$  以及令 n=0;

步骤 2 利用下式对 $\{u_k^1\}$ ,  $\{\omega_k^1\}$ ,  $\lambda_k^1$  进行更新:

$$u_k^{n+1} = \frac{f(\omega) - \sum_{i \neq k} u_i(\omega) + \lambda(\omega)/2}{1 + 2a(\omega - \omega_k^n)^2}$$
(3)

$$\boldsymbol{\omega}_{k}^{n+1} = \frac{\int_{0}^{\infty} \boldsymbol{\omega} \mid \boldsymbol{u}_{k}(\boldsymbol{\omega}) \mid^{2} d\boldsymbol{\omega}}{\int_{0}^{\infty} \mid \boldsymbol{u}_{k}(\boldsymbol{\omega}) \mid^{2} d\boldsymbol{\omega}}$$
(4)

$$\lambda^{n+1}(\omega) = \lambda^{n}(\omega) + \tau \left[ f(\omega) - \sum_{k=1}^{k} u_{k}^{n+1}(\omega) \right]$$
 (5)

步骤3 重复步骤2直至满足迭代条件:

$$\sum_{k} \frac{\parallel u_{k}^{n+1} - u_{k}^{n} \parallel_{2}^{2}}{\parallel u_{k}^{n} \parallel_{2}^{2}} < \varepsilon \tag{6}$$

式中:ε为判别精度.

步骤 4 获得 K 个模态分量.

在对 OLTC 振动信号进行模态分解时,其分解个数 K 和惩罚因子 a 的选择决定着分解效果. K 值过大,则会造成原始信号过分解而产生虚假分量;反之 K 值过小,则会造成信号分解不彻底,使模态分量中心频率重叠,无法分解出主要频率信号. 为了准确提取原始振动信号中丰富的特征信息,本文采用 WSO 算法对 VMD 进行参数寻优.

### 1.2 基于大白鲨 WSO 算法的 VMD 参数优化

大白鲨优化算法是 Braik 等<sup>[19]</sup> 在 2022 年根据大白鲨跟踪和捕食猎物的行为特征而提出的新型群智能优化算法. 该算法全局搜索能力强、参数少,具有较强的鲁棒性和适应性,被广泛运用于参数寻优. 大白鲨有着敏锐的嗅觉、听觉以及对猎物游动水波的感知,使其更加快速锁定猎物位置. 大白鲨捕猎行为分为以下 3 种:

- ① 包围猎物:大白鲨依靠自身听觉、嗅觉以及感知猎物移动产生的水流波动,向猎物靠近.
- ② 搜寻猎物:为了防止寻优过程中陷入局部最优,大白鲨种群还会在搜索空间内的边界附近进行随机搜索.
  - ③ 捕食猎物: 鲨群会向最佳捕猎位置靠近.

在进行 VMD 参数优化前需要对大白鲨种群进行参数初始化,包括大白鲨种群数量 N、搜索空间维度 d、最大迭代次数 T 以及种群初始位置  $X = (x_1, x_2, \dots, x_i)$ . 其中大白鲨种群  $x_i = [a_i, b_i]$  中, $a_i$  和  $b_i$  分别表示搜索空间的上界和下界,第 i 条大白鲨在第 j 维  $(j = 1, 2, \dots, d)$  的初始位置由下式定义:

$$x_i^j = b_i + r(a_i - b_i) \tag{7}$$

式中:r表示[0,1]之间的随机数.

根据大白鲨捕猎行为 ① 可知,大白鲨会根据猎物移动产生的气味、水流波动来感知猎物方向,并以速度 v 向猎物进行移动,其速度更新如下式所示:

$$v_{t+1}^{i} = 0.7035 \times \left[ v_{t}^{i} + p_{1} (x_{\text{gbest}} - x_{t}^{i}) \times r_{1} + p_{2} (x_{\text{best}}^{v_{t}^{i}} - x_{t}^{i}) \times r_{2} \right]$$
(8)

式中: t 表示大白鲨位置更新次数; $v_t^i$  表示迭代 t 次时第 i 条大白鲨的速度; $x_{\rm gbest}$  和  $x_{\rm best}$  分别表示大白鲨种群全局最佳位置和第 t 次迭代的大白鲨种群中第 i 条大白鲨的全局最佳位置; $r_1$  和  $r_2$  表示[0,1] 之间的随机数; $v_{k+1}^i$  表示下一次迭代过程中第 i 条大白鲨的速度,设置  $v_0^i$ ; $p_1$  和  $p_2$  分别表示大白鲨种群运动控制参数,其计算如下式所示:

$$p_1 = p_{\text{max}} + (p_{\text{max}} - p_{\text{min}}) \times e^{-(4t/T)^2}$$
(9)

$$p_2 = p_{\min} + (p_{\max} - p_{\min}) \times e^{-(4t/T)^2}$$
 (10)

式中:  $p_{\min}$  和  $p_{\max}$  分别表示大白鲨最佳运动状态下的最小速度和最大速度.

依据大白鲨搜寻猎物行为机制进行位置更新,在区域边界附近进行搜索,防止进入局部最优.在行为①和行为②中,其位置更新表达式如下式所示:

$$x_{t}^{i} \begin{cases} x_{t}^{i} \times \gamma \oplus x_{0} + u \cdot a + l \cdot b, \ rand < mv \\ x_{t}^{i} + v_{t}^{i} / f, \ rand \ge mv \end{cases}$$

$$(11)$$

$$u = \operatorname{sgn}(x_t^i - a) > 0 \tag{12}$$

$$l = \operatorname{sgn}(x_t^i - b) < 0 \tag{13}$$

$$x_0 = \bigoplus (u, l) \tag{14}$$

$$f = f_{\min} + (f_{\max} - f_{\min}) / (f_{\max} + f_{\min})$$
(15)

其中:  $\neg$  表示负运算符;  $\oplus$  表示向量的逐位异或运算; a 和 b 表示搜索空间的上下界限; rand 表示 [0,1] 之间的随机数; f 表示波浪的频率; 参数 mv 表示大白鲨嗅觉、听觉灵敏度, 其参数设置决定了大白鲨算法的全局以及局部搜索能力, 其计算如下式所示:

$$mv = 1/(a_0 + e^{(T/2-t)/a_1})$$
 (16)

式中:常数  $a_0$  和  $a_1$  分别用于决定 WSO 探索和开发能力. mv 设置过大将导致进行全局搜索,搜索次数变 多;反之过小将导致进行局部搜索,搜索强度变大,但也容易陷入局部最优.

大白鲨通过行为特征③向最佳鲨群位置移动,其位置更新如下式所示:

$$\hat{\mathbf{x}}_{k+1}^{i} = x_{\text{best}} + r_{1} \mathbf{D}_{w} \operatorname{sgn}(r_{2} - 0.5), r_{3} < S$$
 (17)

$$\mathbf{D}_{w} = | rand \times (x_{\text{ghest}} - x_{k}^{i}) | \tag{18}$$

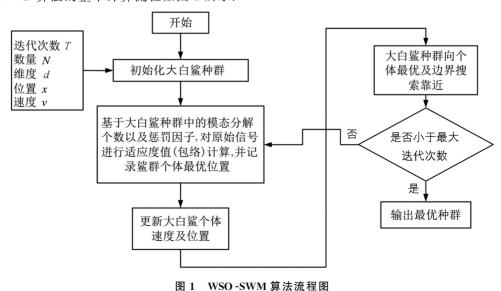
其中:  $\overset{\sim}{\boldsymbol{x}}_{k+1}$  为第 k 条大白鲨在经过下次迭代后相对于猎物的位置向量;  $r_1$ ,  $r_2$  和  $r_3$  分别为[0,1] 范围内的随机数;  $\boldsymbol{D}_w$  为猎物与大白鲨之间的距离向量; S 表示大白鲨靠近最优猎物位置时的嗅觉和视觉强度. 其他大白鲨根据鲨群行为向最优位置运动, 其最终位置位于搜索空间内最优猎物位置附近.

在利用 WSO 对 VMD 进行参数寻优时,需要选取合适的适应度函数用于评估变分模态分解效果,本文采用唐贵基等<sup>[18]</sup> 提出的包络熵作为评判标准. 包络熵可用于表征 OLTC 振动信号的中特征信息量,当信号中的特征信息被噪声信息淹没时,则包络熵值较大,反之则较小. 长度为 N 的时间信号 x(i) 经 Hilbert解调得到包络信号 a(i). 为了避免模态分量之间包络幅值的不同影响以及增强抗干扰能力,需对 a(i) 进行归一化处理,随后依据信息熵计算规则获得包络熵  $E_o$ ,其计算如下式所示:

$$p_i = a(i)/(\sum_{i=1}^{N} a(i))$$
 (19)

$$E_{p} = -\sum_{i=1}^{N} p_{i} \lg p_{i} \tag{20}$$

WSO-VMD 算法的整个计算流程如图 1 所示.



#### 1.3 基于样本熵的 OLTC 振动信号特征向量构建

熵值是用于表征信号序列复杂度、信息量以及不确定性的无量纲指标,熵值越大则代表信号越复杂. 研究人员为了度量时间序列产生新模式的概率大小提出样本熵算法,该方法适用于非线性信号中不稳定冲击性信号的特征表达. 样本熵值大小与时间序列复杂度正相关,而对 OLTC 振动信号分析不难发现,由于 OLTC 切换时内部机械部件的突然性动作导致其振动波形大多表现为冲击性,因此利用样本熵表征 OLTC 的故障特征是有效的. 虽然样本熵有着和近似熵一样的物理意义,但是样本熵的计算不依赖时间序列长度,具有更好的一致性以及普适性,抗干扰能力也优于近似熵,因此选择样本熵对 OLTC 振动信号的模态分量构建特征向量. 对于 N 个数据构成的时间序列 $\{x(1),x(2),\cdots,x(N)\}$ ,其序列样本熵的计算步骤如下所示:

步骤 1 将原始信号重构为 m 维向量序列  $X_m(1)$ , …,  $X_m(N-m-1)$ , 其中  $X_m(i) = \{x(i), x(i+1), \dots, x(i-m+1)\}$ ,  $1 \le i \le N-m+1$ , 也可理解为采用窗长为 m、设置步长为 1 对原始序列进行采样重构.

步骤 2 定义  $d[X_m(i), X_m(j)]$  为不同向量之间最大差值的绝对值,即:

$$d[\mathbf{X}_{m}(i), \mathbf{X}_{m}(j)] = \max(|x(i+k) - x(j+k)|)$$
(21)

步骤 3 对于  $i,j \in [1,N-m]$ 定义距离 r,对于给定  $X_m(i)$ ,统计其与  $X_m(j)$  中距离小于等于 r (相似容限) 的 j 的数目并记为  $B_i$ ,定义:

$$B_{i}^{m}(r) = \frac{B_{i}}{N - m - 1} \tag{22}$$

步骤 4 定义  $B^{(m)}(r)$ :

$$B^{(m)}(r) = \frac{1}{N - m} \sum_{i=1}^{N - m} B_i^m(r)$$
 (23)

**步骤 5** 增加序列重构维数到 m+1,按照上述步骤计算出:

$$A^{(m)}(r) = \frac{1}{N-m} \sum_{i=1}^{N-m} A_i^m(r)$$
 (24)

由上述步骤可以求得  $B^{(m)}(r)$  和  $A^{(m)}(r)$  分别是 2 个序列在相似容限 r 下匹配 m 以及 m+1 个点的概率,由此可得序列的样本熵(SampEn):

$$Sam pEn(m, r) = -\ln[A^{(m)}(r)/B^{(m)}(r)]$$
 (25)

#### 1.4 支持向量机 SVM 算法原理

基于 OLTC 样本熵特征量样本数较小且均为非线性的特点,因此本文选用 SVM 对 OLTC 进行状态模式识别. 对于给定数据集 $\{(x_1, y_1), \dots, (x_i, y_i)\}, i=1,2,\dots,l,$  其中x 为数据样本特征,y 为样本标签. 对于多维特征,SVM 构造超曲面  $f(x) = \boldsymbol{\omega}^{\mathrm{T}} \varphi(X) + b$  对输入样本进行划分, $\boldsymbol{\omega}$  定义为平面权向量,b 为偏差,其原理示意图如图 2 所示.

为了提高样本分类的准确性,需要对超曲面 进行最优求解,依据原理示意图构造约束条件.

$$\begin{cases} \min_{\boldsymbol{\omega}} \frac{\|\boldsymbol{\omega}\|^{2}}{2} \\ \text{s. t. } y_{i}(\boldsymbol{\omega}^{T} x_{i} + b) \geqslant 1 \end{cases}$$
 (26)

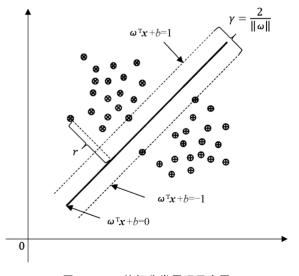


图 2 SVM 特征分类原理示意图

但常见样本特征多为线性不可分的情况,因此需引入松弛变量  $\boldsymbol{\xi} = (\boldsymbol{\xi}_1, \dots, \boldsymbol{\xi}_i)^{\mathrm{T}}(\boldsymbol{\xi}_i > 0)$  来提高模型 对噪声和异常点的容忍度,并提高泛化能力. 加入松弛变量后其约束条件如下式所示:

$$\begin{cases}
\min_{\boldsymbol{\omega}} \frac{\|\boldsymbol{\omega}\|^{2}}{2} + C \sum_{i=1}^{i} i = \boldsymbol{\xi}_{i} \\
\text{s. t. } y_{i}(\boldsymbol{\omega}^{T} x_{i} + b) \geqslant 1 - \boldsymbol{\xi}_{i}
\end{cases}$$
(27)

式中: C 为惩罚因子,即给分类误差加入代价函数. 引入 Largrange 函数以及参数  $a_i$  和  $a_i^*$  求解凸规划问题:

$$L = \| \boldsymbol{\omega} \|^{2} + C \sum_{i=1}^{l} \left[ (\xi_{i} + \xi_{i}^{*}) - \sum_{i}^{l} (a_{i}^{*} + a_{i}) - \sum_{i}^{l} (a_{i}^{*} - a_{i}) \right]$$
 (28)

式中:  $a_i > 0$ ,  $a_i^* \ge 0$ . 根据 KT 条件, 求解最优超平面的充分必要条件为:

$$\sum_{i=1}^{l} y_i (a_i^* - a_i) = 0 (29)$$

由上式可将优化问题转换为对偶问题求解出最优超平面:

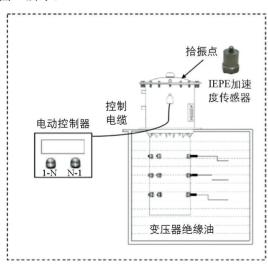
$$f(x) = \sum_{i=1}^{l} (a_i^* - a_i)(x \cdot y) + b$$
 (30)

常利用核函数  $K(x \cdot y) = \phi(x) \cdot \phi(y)$  代替线性、多项式核函数 $(x \cdot y)$ .

但是 SVM 模型中包含了 2 个关键参数 C 和 g,参数 C 用于表示模型对输入样本误差的包容度,g 为 SVM 的核参数,决定新的特征空间中数据位置的分布情况. 2 种参数的选择均会影响 SVM 的训练结果,因此也需要对 SVM 的参数进行参数寻优,从而提高 OLTC 故障识别的准确率.

## 2 OLTC 典型故障模拟实验

本文搭建了 OLTC 故障模拟实验平台以及振动信号检测系统(IEPE 加速度传感器、恒流源、信号采集器以及信号分析软件 Matlab 2020),开展了基于振动信号的 OLTC 故障诊断研究,其信号检测平台设计如图 3 所示.





OLTC示意图

OLTC振动信号采集系统

图 3 OLTC 振动信号检测平台

选取双城国开公司的 SYJZZ-10 kV 型复合式 OLTC 作为实验对象,该分接开关采用三相直接切换、中部跨接式进行调压,额定电流为 100 A,开关各触点接触电阻小于等于 500  $\mu\Omega$ ,整个开关电动操作切换一次时间为 12 s,其中过渡电阻切换时间为 15~35 ms,可通过自动或电动控制器实现精准快速调压.当 OLTC 进行分解绕组切换时,内部电动机从电动控制器获得调压指令后开始转动,经两级蜗轮蜗杆减速机

构减速后推动铆在涡轮上的圆柱销转动;圆柱销推动拐臂转动,使拉伸弹簧逐步拉伸储能直至弹簧机构过死点释放,带动拨槽件转动,使槽轮转过一个等分,便完成了变压器挡位的切换.振动传感器选用 YK-YD55 型压电式加速度传感器,其相关参数如表 1 所示.恒流源选用凌航公司生产的单通道 IEPE 恒流源,频率带宽为 0.3 Hz~100 kHz,采用 24 V 直流供电,其输出电流为 4 mA,增益挡位有"×1"和"×10"2 个挡位选择,性能稳定,抗噪能力强,可有效输出传感器采集到的加速度电压信号.泰克 MDO4104C 示波器拥有 20 Mpointe 记录长度,在获取长时间段的信号后仍保持较高的分辨率;拥有 4 个模拟通道、1 GHz 带宽以及高达 5 GS/s 的采样率,能够准确采集 OLTC 的振动信息.

tt ste	YK-YD55 型 IEPE 压电式		YK-YD55 型 IEPE 压电式		
名称 	加速度传感器	名称	加速度传感器		
测量范围	$0\sim50 \text{ m} \cdot \text{s}^{-2}$	输入阻抗	<100 Ω		
频率响应(3 dB)	0.5 Hz~10 kHz	谐振频率	25  kHz		
工作温度范围	$-40~{^{\circ}\!\!\!\!C} \sim +120~{^{\circ}\!\!\!\!C}$				

表 1 IEPE 加速度传感器参数指标

本文设计 OLTC 正常工况以及 3 种典型缺陷的模拟实验,如图 4 所示.其中:1) 去掉一根主弹簧用于模拟弹簧断裂故障;2) 选用劲度系数较小的弹簧并将其弯曲处理用于模拟弹簧疲软故障;3) 松动固定触头螺母用于模拟触头松动故障.设置示波器采样频率为 40 kHz,OLTC 正常、弹簧疲软、弹簧断裂以及触头松动下的 4 种振动信号如图 5 所示.

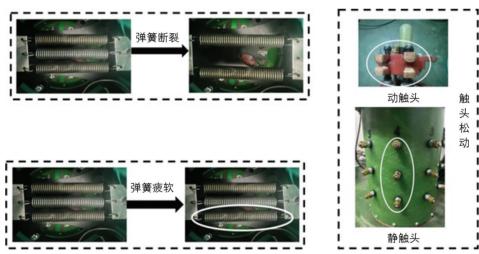


图 4 OLTC 典型缺陷模拟设置

基于 OLTC 振动波形以及内部机械结构先后动作时序可以将其分为 3 个阶段,如图 6 所示. 第 1 阶段为弹簧经由电动机拉伸储能,这期间主要由弹簧、电机以及蜗轮蜗杆减速机构产生微弱振动信号,在此阶段中无明显振动波形产生;第 2 阶段为弹簧经过死点释放至动静触头碰撞之间的振动信号,此阶段的振源主要来自弹簧的突然动作以及储能弹簧带动拨槽件转动与槽轮产生的碰撞,可以看出弹簧以及槽轮突然动作产生了较为明显的冲击性波形;第 3 阶段为拨槽件带动下方动触头与静触头猛烈碰撞产生振动能量,此阶段的振源来自动静触头碰撞以及内部齿轮机构的突然停止,随后振动信号能量随时间逐渐变小直至趋于0.可以看出,当 OLTC 内部机械零部件改变其原始运动状态时,便会产生较为剧烈的振动波形,并且由于零部件运动状态的改变时间极短,振动波形多具有冲击性,并且随着时间的推移波形逐渐减弱.通过图 5 中 OLTC 不同工况下的振动信号分析可以看出,与正常工况相比,弹簧断裂故障下由于弹簧储存的弹性势能变小导致动静触头碰撞产生的振动能量有所减弱;弹簧疲软故障下,由于弹簧进行拉伸弯曲处理导致弹

簧释放产生的振动较小,并且弹簧释放完之后仍会产生振动现象;触头松动故障下,动静触头发生碰撞后由于触头松动导致撞击后产生少量的余振现象.综合分析可以看出 OLTC 内部主要的机械结构部件性能可以间接由振动信号波形呈现出来.

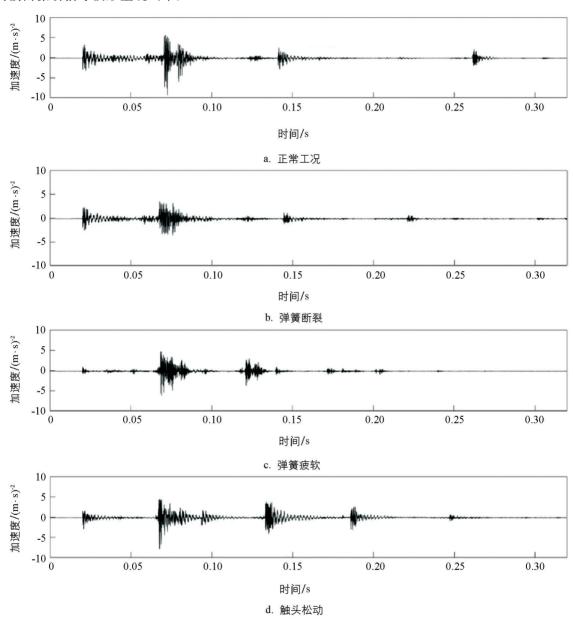


图 5 OLTC 不同工况的振动信号

## 3 基于 WSO-VMD 样本熵的 OLTC 特征向量构建

针对传统模态分解法对 OLTC 故障振动信号特征提取不完整导致诊断识别准确率低的问题,本文选用 WSO-VMD 算法获得不同工况下振动信号最优分解参数组合[K, $\alpha$ ],再利用寻优后得到的 VMD 模型对振动信号进行分解处理获得对应 K 个 IMF 分量,之后求取其对应样本熵值并构建 OLTC 不同工况下的特征向量,作为 SVM 的输入进行 OLTC 故障诊断. 在利用 WSO 优化时设置搜索空间维度为 2,种群数量为 10,迭代次数为 20 以及惩罚因子  $\alpha$  和 K 的上下限分别为 ub = [2 300,15]和 lb = [100,3],WSO 的参数设置如表 2 所示. 在寻优过程中将最小包络熵作为目标函数[ $^{20}$ ].

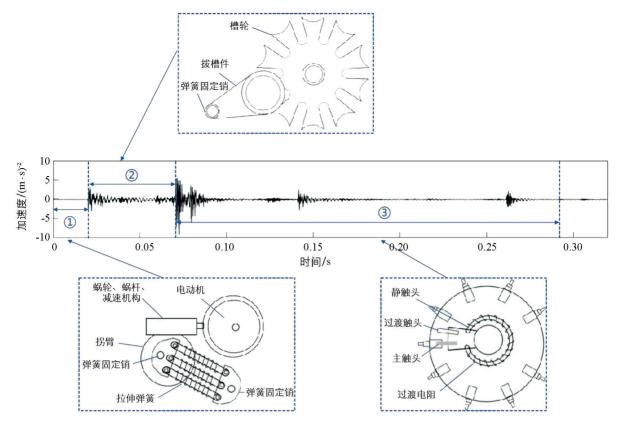


图 6 OLTC 振动信号时序分析

表 2 WSO 算法的参数设置

d	$f_{ m max}$	$f_{ m min}$	$P_{ m max}$	$P_{ m min}$	$a_0$	$a_1$	$a_2$
2	0.75	0.07	1.5	0.5	6.25	100	0.005

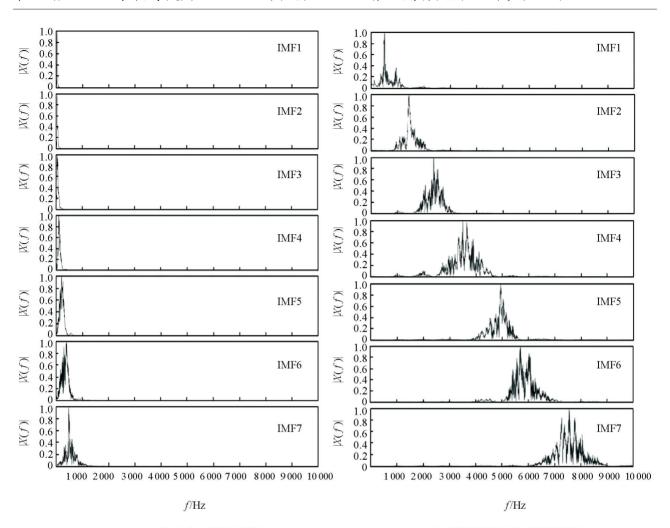
为了更好地对比分解结果,分别利用参数优化后的 VMD 模型以及 EMD 对 OLTC 正常工况振动信号进行模态分解并计算各模态分量归一化频谱图. EMD 模态分解以及 WSO-VMD 模态分解获取的 IMF 数量分别为 14 和 10,本文选取前 7 个模态分量作为比较对象,其对应模态分量的频谱图如图 7 所示.

对比传统 EMD 以及 WSO-VMD 方法对 OLTC 振动信号进行模态分解的模态分量频谱图可以看出,EMD 分解获得的模态分量在低频段内发生了严重的中心频率混叠,即 EMD 无法对 OLTC 振动信号进行有效分解,这也证明了由于 OLTC 内部机械结构复杂,导致提取到的振动信号中存在异常事件影响了 OLTC 极值点的选取,使极值点分布不均匀造成模态分量中产生了异常分量。对比 EMD 与 WSO-VMD 对 OLTC 振动信号分解的 IMF 频谱图可以看出,相较于 EMD 分解,本文选用的 WSO-VMD 方法得到的 OLTC 振动信号模态分量并未产生混叠现象,能够有效获取其振动信号不同频率段的故障特征。针对 OLTC 4 种不同工况下的振动信号,本文利用 WSO 算法分别对不同工况下 10 组振动信号的 VMD 分解参数进行寻优并求取平均值,其最优参数组合[K,  $\alpha$ ]如表 3 所示。

表 3 最佳 VMD 参数组合

OLTC 工况	[Κ, α]	OLTC 工况	[K, α]
正常状态	[1 710, 10]	弹簧断裂	[2 120, 11]
弹簧疲软	[1 977, 10]	触头松动	[1 940, 10]

利用 WSO 优化 VMD 模型对 OLTC 不同工况振动信号进行模态分解获取对应 IMFs,每种 OLTC 工况选取其中 10 组振动数据进行模态分解获取对应模态分量,对模态分量进行样本熵计算并求取均值,结果



a. 基于EMD分解的IMF频谱图

b. 基于WSO-VMD分解的IMF频谱图

图 7 不同模态分解的 IMF 频谱图

如图 8 所示. 从图 8 可以看出不同工况下的样本熵特征存在差异,这是因为 OLTC 不同工况下,其内部机械零部件性能具有明显差异,这种差异可以反映至检测到的振动波形中,最后导致 VMD 模态分解计算的不同模态分量以及对应样本熵值存在着差异.

## 4 基于 SSA-SVM 算法的 OLTC 故障 诊断研究

根据最优 VMD 参数模型对 OLTC 不同工况下进行模态分解,选取前 10 个模态分量的样本熵构建样本特征向量.为了证明该方法的鲁棒性与可靠性,本文选用同种型号的不同

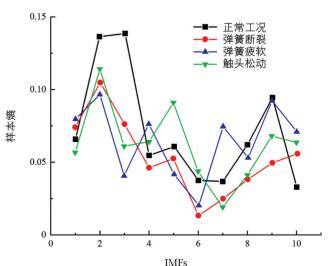


图 8 OLTC 4 种工况样本熵特征向量

OLTC 故障模拟实验并进行振动信号采集,选取 4 种工况各 60 组样本(每个 OLTC 采集 12 个振动信号样本)作为数据集,共计 240 组实验数据. 依据数据样本以 7:1:2 的比例构建样本训练集、验证集以及测试集进行 SVM 分类训练,训练过程中采用监督式训练,以标签 1、2、3、4 分别对应 OLTC 正常工况、弹簧

断裂、弹簧疲软以及触头松动 4 种不同的状态结果. 利用 SVM 对 OLTC 运行状态进行特征分类,其训练时间为 0. 421 s,训练集、验证集以及测试集结果如图 9 所示.

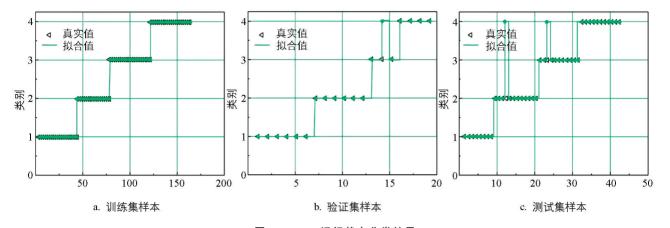


图 9 OLTC 运行状态分类结果

基于 WSO-VMD 以及样本熵构建的 OLTC 工况特征向量,利用 SVM 对 OLTC 不同工况进行分类,从训练结果可以看出:训练集样本的分类识别准确率为 100%,而验证集以及测试集的识别准确率均为 95.83%,平均识别准确率为 98.75%,表现出了对 OLTC 故障工况优异的识别准确率. 为验证优化后的 VMD 分解模型对 OLTC 振动信号模态分解的有效性和准确性,利用给定参数 VMD(K=10, a=2000)、EMD 和 EEMD 分解对 OLTC 振动信号进行模态分解,并用样本熵对 OLTC 不同工况进行特征向量构建,选用 SVM 进行模式识别,其不同模态分解方法的测试集识别准确率如表 4 所示.

处理方法	正常工况/%	弹簧断裂/%	弹簧疲软/%	触头松动/%	平均识别准确率/%
EMD+SampEn	91.67	100.00	91.67	75.00	89.59
EEMD+SampEn	100.00	91.67	75.00	100.00	91.67
VMD + SampEn	100.00	100.00	100.00	75.00	93.75

表 4 不同模态分解的分类识别准确率

由图 9 和表 4 可以看出,相较于其他特征提取方法,SVM 对本文提出的 WSO-VMD 模态分解法构建的特征向量拥有更高的识别准确率。此外,SVM 对正常工况以及弹簧断裂 2 种工况的识别准确率高于弹簧疲软以及触头松动故障,这是由于 OLTC 弹簧疲软以及触头松动 2 种工况相对于正常工况,故障设置改变并不是很大,因此其原本机械结构并未发生较大的变化,同时也体现在检测得到的振动信号波形与正常波形之间的差异性较小。而弹簧断裂对 OLTC 内部机械结构改变程度相较于弹簧疲软以及触头松动 2 种工况较大,因此弹簧断裂对应振动波形与正常工况之间的差异性也较大,对 OLTC 故障诊断识别准确率最高。通过不同 OLTC 特征向量构建方法的结果对比可以看出,其测试集准确率比 EMD、EEMD 以及给定参数 VMD 分别提高了 9.52%、4.54%以及 2.22%,这也表明本文提出的 WSO 参数优化 VMD 法能够提取更为丰富的 OLTC 内部机械特征。为进一步提高 SVM 对 OLTC 故障识别的准确率,选用粒子群(PSO)、麻雀搜索(SSA)以及灰狼优化(GWO)算法对 SVM 进行参数寻优[20-22],并对 OLTC 不同工况的特征分类进行研究,其测试集分类识别准确率结果如表 5 所示。

通过几种优化算法展开 SVM 参数寻优,不同参数优化 SVM 模型对 OLTC 测试集的平均识别准确率均高于 95%,特别是对 OLTC 弹簧疲软以及触头松动 2 种故障识别的准确率有了明显的提高,均在 90%以上. 此外,从表 5 中可以看出 SSA-SVM 算法对 OLTC 4 种工况测试集样本识别的准确率均为 100%,表现出对 OLTC 优异的故障识别准确率. 通过不同智能优化算法对 SVM 进行参数优化,其结果表明了本文提出的特征提取法能够提取 OLTC 丰富的机械状态特征信息,以及训练的 SSA-SVM 算法能够有效对OLTC 进行故障诊断.

识别结果		算	法	
以别结来 —	SVM	PSO-SVM	SSA-SVM	GWO-SVM
OLTC 正常工况/%	100.00	100.00	100.00	100.00
OLTC 弹簧断裂/%	100.00	100.00	100.00	100.00
OLTC 弹簧疲软/%	91.67	92.30	100.00	100.00
OLTC 触头松动/%	91.67	100.00	100.00	91.67
平均识别准确率/%	95.83	98.08	100.00	97.92

表 5 不同参数优化 SVM 的测试集分类识别准确率

## 5 结论

针对目前基于振动信号分析的 OLTC 故障诊断中存在着特征提取不完善以及故障识别准确率低的问题,本文系统性提出了基于 WSO 优化 VMD 和样本熵的 OLTC 机械振动信号特征提取方法以及基于 SSA-SVM 的 OLTC 故障诊断方法. 首先以包络熵作为目标函数用 WSO 对 VMD 进行参数寻优,经参数优化的 VMD 模型对 OLTC 振动信号进行模态分解获得模态分量,再利用样本熵构建不同工况的特征向量,并作为 SVM 的输入开展了 OLTC 的故障诊断识别研究,其结果表明:

- 1) 相较于传统 EMD 以及 EEMD 模态分解法,本文提出的 WSO-VMD 分解法对 OLTC 振动信号分解获得的模态分量不存在中心频率混叠现象,对 OLTC 振动信号分解效果更好,能够提取 OLTC 更为丰富的状态特征.
- 2) 基于 WSO-VMD 对 OLTC 不同工况的振动信号进行模态分解获得模态分量,计算模态分量对应的 样本熵值并构建特征向量. 利用 SVM 对样本进行分类识别,其测试集样本分类准确率为 95.83%,并且在 训练集中的识别准确率为 100%,表明本文搭建的 SVM 分类模型对 OLTC 表现出了良好的故障识别准确 率以及基于 WSO-VMD 的 OLTC 振动信号特征提取的有效性.
- 3)利用不同模态分解方法开展 OLTC 振动信号模态分解与样本熵特征向量构建,其 SVM 分类结果表明:相比于 EMD、EEMD 与给定参数 VMD 方法,本文提出的 WSO-SVM 分解法获得的特征更为丰富,对OLTC 故障诊断识别的准确率最高,其测试集准确率比 EMD、EEMD 以及给定参数 VMD 分别提高了9.52%、4.54%以及 2.22%。由于 OLTC 弹簧疲软以及触头松动 2 种常见故障设置与正常工况差异较小,因此对于这 2 种工况的识别准确率较其他 2 种工况低。此外不同模态分解法对 OLTC 故障诊断表现出了优异的识别准确率,表明本文利用样本熵作为 OLTC 不同工况特征向量的可行性以及有效性。
- 4) 为了进一步提高对 OLTC 故障识别的准确率,分别选用 SSA、PSO 以及 GWO 算法对 SVM 进行参数优化,结果表明: SVM 参数优化之后,对 OLTC 触头松动以及弹簧疲软 2 种工况的识别准确率均有明显的提升,并且基于 SSA-SVM 算法对 OLTC 3 种故障样本测试集识别的准确率均为 100%,表现出了优异的识别准确率.

综合来看,本文提出的基于 WSO-VMD 模态分解法能够实现对 OLTC 振动信号的准确有效分解,样本熵也能够提取 OLTC 丰富的状态特征,并且设计的 SSA-SVM 算法模型实现了对 OLTC 故障的准确分类,本文的研究对于 OLTC 故障诊断具有一定的工程实践意义与参考价值.

#### 参考文献:

- [1] 司马文霞, 王大森, 杨鸣, 等. 适配变压器全档位切换暂态分析的有载分接开关电路模型构建 [J]. 高电压技术, 2024, 50(2): 478-488.
- [2] 徐晨博,王丰华,傅坚,等.变压器有载分接开关振动测试系统设计与开发 [J]. 仪器仪表学报,2013,34(5):987-993.

- [3] 杨壮,周渠,赵耀洪,等.基于人工神经网络和多频超声波检测技术的变压器油界面张力预测 [J].高电压技术,2019,45(10):3343-3349.
- [4] 赵书涛,王紫薇,陈志华,等. 有载分接开关 GLCM 纹理特征及改进随机森林算法的故障诊断方法 [J]. 高电压技术, 2022, 48(9): 3593-3601.
- [5] 高树国,王丽丽,田源,等. 基于振动时频信号灰度共生矩阵的有载分接开关触头状态检测方法研究 [J]. 电工电能新技术,2022,41(1):69-77.
- [6] 蔡宇琦,方瑞明,彭长青,等. 基于 ANHGA-VMD 和耦合隐马尔可夫模型的有载分接开关机械故障诊断 [J]. 高电压 技术,2021,47(11):3949-3959.
- [7] 赵书涛,王紫薇,胡经伟,等.基于振动信号分析的有载分接开关故障诊断研究综述[J].华北电力大学学报(自然科学版),2021,48(5):61-71.
- [8] 阳瑞霖,何葵东,胡蝶,等. 基于振动信号 EMD 分解与支持向量机的有载分接开关机械故障诊断 [J]. 变压器,2022,59(7):29-33.
- [9] 温馨. 改进经验模态分解法衰减地震随机噪声研究及应用 [D]. 长春: 吉林大学, 2022.
- [10] 杨波, 黄倩, 付强, 等. 基于 CEEMD 和优化 KNN 的离心泵故障诊断方法 [J]. 机电工程, 2022, 39(11): 1502-1509.
- [11] 梁黎明,王茂芝,徐文皙,等. 综合斜率和三次样条的 EMD 端点效应抑制方法 [J]. 振动与冲击,2022,41(14):70-76.
- [12] 张淑清, 苑世钰, 姚玉永, 等. 基于 ICEEMD 及 AWOA 优化 ELM 的机械故障诊断方法 [J]. 仪器仪表学报, 2019, 40(11): 172-180.
- [13] DRAGOMIRETSKIY K, ZOSSO D. Variational Mode Decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [14] 杨森,陈莎莎,李光茂,等. 基于变分模态分解的变压器有载分接开关振动信号去噪分析 [J]. 电测与仪表,2019,56(13):104-112.
- [15] 周翔, 王丰华, 傅坚, 等. 基于混沌理论和 K-means 聚类的有载分接开关机械状态监测 [J]. 中国电机工程学报, 2015, 35(6): 1541-1548.
- [16] 曾全昊, 王丰华, 郑一鸣, 等. 基于卷积神经网络的变压器有载分接开关故障识别 [J]. 电力系统自动化, 2020, 44(11): 144-151.
- [17] 赵彤. 有载分接开关机械状态的在线监测与故障诊断技术研究 [D], 济南: 山东大学, 2008.
- [18] 唐贵基, 王晓龙. 参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用 [J]. 西安交通大学学报, 2015, 49(5): 73-81.
- [19] BRAIK M, HAMMOURI A, ATWAN J, et al. White Shark Optimizer: A Novel Bio-Inspired Meta-Heuristic Algorithm for Global Optimization Problems [J]. Knowledge-Based Systems, 2022, 243: 108457.
- [20] 赵志刚, 马习纹, 姬俊安. 基于 AFSA 与 PSO 混合算法的 J-A 动态磁滞模型参数辨识及验证 [J]. 仪器仪表学报, 2020, 41(1): 26-34.
- [21] 姚远,贾路芬,刘立,等. 基于 KPCA-SSA-ENN 的变压器油界面张力预测 [J]. 重庆理工大学学报(自然科学), 2023, 37(7): 297-305.
- [22] 唐圣学, 马晨阳, 勾泽. 基于时频特征融合与 GWO-ELM 的棒控电源早期故障状态辨识方法 [J]. 仪器仪表学报, 2023, 44(1): 121-130.

责任编辑 柳剑 崔玉洁