

基于 VMD 和 WOA-SVM 的变压器绕组松动 故障诊断 *

薛健桐， 马宏忠

(河海大学 能源与电气学院, 江苏 南京 211100)

摘要：为了更加准确有效地诊断变压器绕组松动故障, 提出了一种基于变分模态分解(VMD)和鲸鱼优化支持向量机(WOA-SVM)的变压器绕组松动故障诊断方法。首先, 对某 10 kV 变压器进行模拟故障试验, 测量其振动信号; 随后, 采用 VMD 将非平稳的振动信号分解成多个本征模态函数(IMF), 并计算各层 IMF 的能量熵, 构成特征向量; 最后, 将特征向量输入鲸鱼算法(WOA)优化的支持向量机(SVM)中训练出分类模型, 实现变压器绕组松动故障诊断。结果表明, 所提方法适用于变压器绕组松动故障诊断, 并且相较于传统的改进 SVM 分类模型, 所提方法的故障识别准确率更高。

关键词：变压器绕组松动；振动信号；变分模态分解；鲸鱼优化支持向量机；故障诊断

中图分类号：TM41 **文献标志码：**A **文章编号：**1673-6540(2023)08-0084-07

doi: 10.12177/emca.2023.021

Fault Diagnosis for Winding Looseness of Transformer Based on VMD and WOA-SVM *

XUE Jiantong, MA Hongzhong

(College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China)

Abstract: In order to diagnose transformer winding looseness fault more accurately and effectively, a fault diagnosis method for transformer winding looseness based on variational mode decomposition (VMD) and support vector machine optimized by whale optimization algorithm (WOA-SVM) is proposed. Firstly, a fault simulation experiment is carried out on a 10 kV transformer to measure its vibration signal. Then, VMD is used to decompose the non-stationary vibration signal into multiple intrinsic mode functions (IMF), and the energy entropy of each IMF is calculated to constitute feature vectors. Finally, the feature vectors are input into the WOA-SVM to train the classification model, and the fault diagnosis of transformer winding looseness is realized. The results show that the proposed method is applicable to the fault diagnosis of transformer winding looseness, and its fault identification accuracy is higher than the traditional improved SVM classification model.

Key words: transformer winding looseness; vibrational signal; variational mode decomposition (VMD); support vector machine optimized by whale optimization algorithm (WOA-SVM); fault diagnosis

0 引言

变压器作为电能传输的枢纽, 是电力系统的核心设备, 因此其安全稳定运行对保证电网的供

电可靠性至关重要^[1-2]。然而, 变压器绕组在运输时可能会产生倾斜、移位等现象, 加之在投入运行后因长期承受不规律短路冲击电流而异常振动, 变压器绕组会产生松动变形^[3-4], 从而大大降低了

收稿日期: 2022-11-13; 收到修改稿日期: 2023-01-30

* 基金项目: 国家自然科学基金项目(51577050); 国网江苏省电力有限公司科技项目(J2021053)

作者简介: 薛健桐(1999—), 男, 硕士研究生, 研究方向为变压器状态监测与故障诊断。

马宏忠(1962—), 男, 教授, 博导, 研究方向为电力设备状态监测与故障诊断。

变压器的抗短路能力,给电力系统的安全运行埋下隐患^[5-6]。

振动作为电力设备固有的物理属性,其发生机理与设备运行状态密切相关^[7-8]。振动分析法通过分析所采集具体设备的振动信号,能够挖掘出其中包含的内部故障信息。并且,振动分析法无需与电力设备有直接的电气联系,能够实现不带电操作,因而在故障诊断领域有着广泛应用^[9-10]。对振动信号最常用的分析方法主要有快速傅立叶变化(FFT)分析、经验模态分解(EMD)等时频分析方法。文献[11]通过对变压器振动信号进行频谱分析,定义了不受电流影响的绕组松动缺陷特征值,实现了绕组缺陷诊断与故障相定位。文献[12]为了对变压器绕组混合故障进行准确识别,利用集合经验模态分解(EEMD)方法提取振动信号本征模函数(IMF)能量和2范数构建特征向量作为故障判据。EEMD方法克服了EMD过程中产生的模态混叠等问题,但计算速度慢并且容易存在多个低频IMF分量^[13]。在各类时频分析方法中,变分模态分解(VMD)方法在计算过程中通过迭代的方式求解变分问题,自适应地确定每个IMF分量的中心频率和带宽,因此可根据具体情况选择分解层数,十分适用于非平稳的时间序列分析。因此,本文采用VMD提取变压器振动信号特征。

支持向量机(SVM)因其在小样本分类中展现的优越性,成为了机器学习的主流技术^[14]。在实际应用中,支持向量机需要引入核函数将低维样本集投入高维空间以解决线性不可分问题,因此线性不可分SVM模型中的惩罚参数c与核函数参数g的选取对分类识别准确率的影响尤为关键。文献[15]采用鲸鱼优化算法(WOA)优化Elman模型的初始权值与阈值,实现锂离子电池健康状态评估。文献[16]将WOA引入最小二乘支持向量机参数寻优中,用于超短期风电预测。上述应用均取得了很好的效果,且与传统模型相比其精度更高。

综上所述,本文提出了一种基于VMD和WOA-SVM的变压器绕组松动故障诊断方法。采用VMD得到试验所采集振动信号的IMF分量,计算其能量熵,构成特征向量。在SVM模型训练时通过WOA优化c、g参数,构建WOA-SVM模型

对变压器绕组松动故障进行识别诊断。

1 基于VMD的变压器振动信号特征提取

1.1 VMD原理

Konstantin等^[17]于2014年提出了VMD算法,与EMD等信号分解方法不同,其是一种迭代而非递归的自适应信号分解算法。VMD在求解过程中将原始时间序列信号分解为k层IMF,自适应更新各IMF的最优中心频率与带宽。具体过程如下:

VMD分解出的IMF可表示为

$$u_k(t) = A_k(t) \cos[\phi_k(t)] \quad (1)$$

式中: $A_k(t)$ 为该IMF信号幅值; $\phi_k(t)$ 为瞬时相位。

VMD约束要求每个IMF中心频率的带宽之和最小,因此构造VMD约束变分问题:

$$\begin{aligned} & \min_{\{u_k\}, \{\omega_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|^2 \right\} \\ & \text{s. t. } \sum_k u_k(t) = f(t) \end{aligned} \quad (2)$$

式中: $\{u_k(t)\}$ 表示各层IMF信号集合; $\{\omega_k(t)\}$ 表示各层IMF的中心频率集合;*为卷积运算; ∂_t 为梯度运算; $d(t)$ 为狄拉克函数。

引入增广拉格朗日函数将式(2)转化为一个无约束问题:

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \\ & \alpha \sum_k \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) * u_k(t) \right] e^{-j\omega_k t} \right\|^2 + \\ & \|f(t) - \sum_k u_k(t)\|^2 + \langle \lambda(t), f(t) - \sum_k u_k(t) \rangle \end{aligned} \quad (3)$$

式中: α 为惩罚因子; l 为拉格朗日算子; $\langle \cdot \rangle$ 为内积运算。

通过交替方向乘子法求解式(3),在频域内 $u_k(\omega)$ 的迭代表达式为

$$u_{k,n+1}(\omega) = \frac{\sum_{i \neq k} u_i(\omega) + \lambda_n(\omega)/2}{1 + 2\alpha(\omega - \omega_{k,n})^2} \quad (4)$$

式中: ω 为频率。

具体迭代过程为

- (1) 初始化 $u_{k,1}, \omega_{k,1}$ 和 l_1 ;
- (2) 根据式(4)计算更新 u_k ;

(3) 根据式(5)计算更新 ω_k :

$$\omega_{k,n+1} = \frac{\int_0^\infty \omega |u_{k,n+1}(\omega)|^2 d\omega}{\int_0^\infty |u_{k,n+1}(\omega)|^2 d\omega} \quad (5)$$

(4) 根据式(6)更新 l_k :

$$\lambda_{n+1}(\omega) = \lambda_n(\omega) + \tau [f(\omega) - \sum_k u_{k,n+1}(\omega)] \quad (6)$$

式中: t 为噪声容限。

(5) 重复迭代过程(2)~(4), 直到满足式(7)的迭代终止条件:

$$\frac{\sum_k \|u_{k,n+1} - u_{k,n}\|^2}{\|u_{k,n}\|^2} < \varepsilon \quad (7)$$

1.2 能量熵

在对绕组处于不同状态的变压器振动信号进行 VMD 得到 k 层 IMF 后, 分别求出各层 IMF 的能量熵^[18]可以挖掘绕组每种状态隐含的差异。因此, 本文将各层 IMF 的能量熵构成一组特征向量代表变压器绕组的一种状态。

能量熵的概念可由信息熵引入。定义事件结果 i 的信息量为

$$I_i = -\log P_i \quad (8)$$

式中: P_i 为事件结果 i 发生的概率。

信息熵被定义为信息量的期望, 其计算式为

$$H = -\sum_{i=1}^n P_i \log P_i \quad (9)$$

由此, 经 VMD 的变压器振动信号能量熵即为

$$H_{VMD} = -\sum_{i=1}^n e_i \log e_i \quad (10)$$

$$e_i = \frac{E_i}{\sum_{i=1}^k E_i} = \frac{\sum_{j=1}^N x_j^2}{\sum_{i=1}^k \sum_{j=1}^N x_j^2} \quad (11)$$

式中: e_i 为第 i 层 IMF 的能量 E_i 占 IMF 总能量的比例; N 为变压器振动信号长度。

若将第 i 层 IMF 分为 m 个部分, 可计算出每部分的能量 E_m , 令 $q_n = E_m/E_i$, 则第 i 层 IMF 的能量熵为

$$H_{IMF}^i = -\sum_{n=1}^m q_n \log q_n \quad (12)$$

2 WOA-SVM 算法

Mirjalili 等^[19]于 2016 年提出了 WOA, 这是一

种新型群智能优化算法, 启发于鲸鱼捕猎时的两种独特行为: 包围猎物和发出气泡网驱赶猎物。通过模拟上述两种行为, WOA 实现了在算法前期进行全局搜索, 后期进行局部搜索, 得到最优解。WOA 的具体过程如下^[19]:

定义鲸鱼个体在 d 维解空间的位置为

$$X = (x_1, x_2, \dots, x_d) \quad (13)$$

鲸鱼个体每次使用包围或发出气泡网的概率是相等的, 即 $P_{\text{包围}} = P_{\text{气泡网}}$ 。而包围猎物又分为向最优个体位置移动和向随机个体移动。

向最优个体移动的位置更新公式为

$$X'_i = X_{\text{best}} - A \cdot |C \cdot X_{\text{best}} - X_i| \quad (14)$$

$$A = 2a \cdot r - a \quad (15)$$

$$C = 2 \cdot r \quad (16)$$

式中: X_{best} 为当前最优个体位置; a 随迭代次数从初始值 2 线性递减至 0; r 为 $(0, 1)$ 的随机 d 维向量。

向随机个体移动的位置更新公式为

$$X'_i = X_{\text{rand}} - A \cdot |C \cdot X_{\text{rand}} - X_i| \quad (17)$$

当 $\|A\| < 1$ 时, 选择向最优个体移动; 当 $\|A\| \geq 1$ 时, 选择向随机个体移动。

发出气泡网时的位置更新公式为

$$X'_i = |X_{\text{best}} - X_i| * e^{bl} * \cos(2\pi l) + X_{\text{best}} \quad (18)$$

式中: b 为常数, 默认取 1; l 为 $[-1, 1]$ 的随机数。

SVM 方法实现了将线性不可分的数据集映射到高维空间从而构建出最优划分超平面达到分类的目的^[20]。构建线性不可分 SVM 模型时, 其中的惩罚参数 c 与核函数参数 g 对整个分类模型的精度影响是不可避免的^[21], 因此本文采用上述 WOA 优化 SVM 中的 c, g 参数, 提高分类精度。参数寻优过程具体如下:

(1) 鲸鱼个体的位置向量设为 $[c, g]$, 设置其寻优的上限 u_b 与下限 l_b , 初始化鲸鱼群体个数 N 、最大迭代次数 T ;

(2) 以预测错误率作为适应度函数;

(3) 计算每个个体的适应度值, 适应度值最小的作为最优个体, 其位置也即当前最优位置;

(4) 对每个个体而言, 若选择包围且 $\|A\| < 1$, 则按式(14)更新位置; 若选择包围且 $\|A\| \geq 1$, 则按式(17)更新位置; 若选择气泡网, 则按式(18)更新位置;

(5) 重复进行步骤(3)、(4), 直到达到最大

迭代次数；

(6) 输出最优个体位置, 得到最佳 c, g 参数。

3 基于 VMD 和 WOA-SVM 的变压器绕组松动故障诊断模型

本文提出一种基于 VMD 和 WOA-SVM 的变压器绕组松动故障诊断方法, 其流程如图 1 所示。



图 1 基于 VMD 和 WOA-SVM 的变压器绕组松动故障诊断流程

具体诊断过程如下：

- (1) 在变压器表面布置振动信号测试点, 采集振动信号;
- (2) 将振动信号分为多组进行 VMD, 并计算每组信号各层 IMF 的能量熵, 构成特征向量;
- (3) 将多组特征向量分为训练集和测试集, 采用 WOA 以训练集数据对 c, g 参数寻优, 获得最佳 c, g 参数;
- (4) 利用最佳 c, g 参数构建 WOA-SVM 模型, 输入测试集样本实现变压器绕组松动状态的诊断。

4 试验结果与分析

本文搭建了 10 kV 变压器模拟故障试验平

台, 在该变压器顶部设置测试点采集振动信号以验证本文所提方法的可行性。

试验所用传感器为 IEPE 压电式加速度传感器, 型号为 1A212E; 采集仪型号为 DH5922, 采样频率为 20 kHz。为模拟变压器负载运行情况, 实验中设置了 30 Mvar 电抗器与 30 Mvar 电容器分别作为感性负载和容性负载, 还设置了电阻防止合闸瞬间产生激振的振动信号。试验现场及振动测试点分布如图 2、图 3 所示。

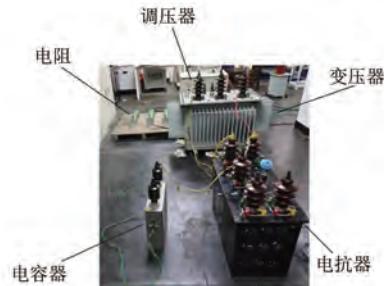


图 2 试验现场

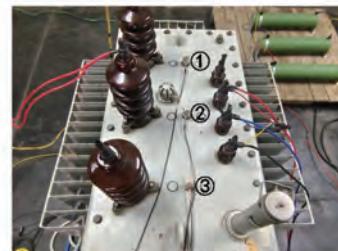


图 3 振动测试点分布

本文试验故障设置方式采用调节变压器内部故障相绕组螺母预紧力的方式, 如图 4 所示。模拟了两种变压器绕组松动故障状态, 分别为绕组预紧力下降 40% 和绕组预紧力下降 80%。



图 4 故障设置

本文以变压器绕组预紧力下降 40% 状态下测试点 1 的振动信号为例, 取信号长度 $N =$

10 000, IMF 分解层数为 4, 对其进行 VMD, 如图 5 所示。同时, 对原始信号及各层 IMF 进行频谱分析, 如图 6 所示。

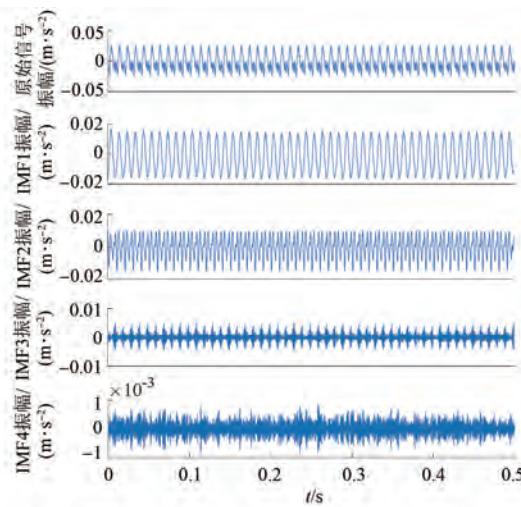


图 5 变压器绕组预紧力下降 40% 状态下测试点 1 的 VMD 结果图

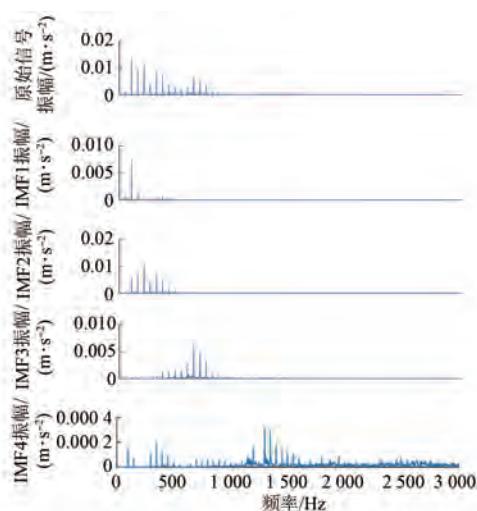


图 6 信号 VMD 对应频谱图

由图 6 可知, 变压器振动信号经 VMD 后的频谱分布基本无模态混叠现象, 且各层 IMF 对应着一种频谱分布, 可以有效识别。因此, 计算各层 IMF 的能量和能量熵以进一步分析故障特征。其结果如表 1 所示。

由表 1 可知, 前 3 层 IMF 的能量值属于主要成分, 第 4 层 IMF 能量值极小, 其数量级较于前 3 层 IMF 可忽略不计, 并且结合图 6 可知, 第 4 层 IMF 有大量高频成分, 说明包含噪声成分需要去除^[22]。因此, 本文将前 3 层 IMF 能量熵作为特征

向量的元素输入 WOA-SVM 进行参数寻优与故障分类诊断。

表 1 各层 IMF 能量和能量熵计算结果

IMF 层数	能量	能量熵
1	1.168 0	0.004 541
2	0.449 1	0.008 735
3	0.020 5	0.006 743
4	0.000 6	0.000 285

在进行 WOA 参数寻优时, 本文设置 c, g 参数范围均为 [0.01, 200], 鲸鱼个体数目为 30, 最大迭代次数为 100。试验样本数据有三种, 分别为绕组正常、绕组预紧力下降 40% 和绕组预紧力下降 80% 状态。其中, 训练集样本每种状态 100 组, 共 300 组; 测试集样本每种状态 60 组, 共 180 组。诊断结果如图 7 和表 2 所示。其中, 图 7 中样本类别 1、2、3 分别对应绕组正常、绕组预紧力下降 40% 和绕组预紧力下降 80% 三种状态。

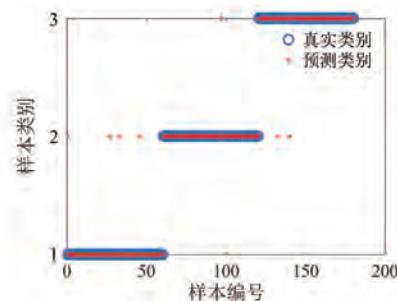


图 7 WOA-SVM 模型诊断效果图

表 2 基于 VMD 和 WOA-SVM 模型的诊断结果

绕组状态	正确个数/组	准确率/%
正常	57	95.00
预紧力下降 40%	59	98.33
预紧力下降 80%	58	96.67
合计	174	96.67

在得到基于 VMD 和 WOA-SVM 模型分类精度的基础上, 将该结果与传统 SVM、基于粒子群优化算法支持向量机 (PSO-SVM) 和基于遗传算法支持向量机 (GA-SVM) 模型分类结果对比分析, 采用相同训练集与测试集输入上述模型中, 其诊断结果如表 3~表 5 所示。

本文所建立变压器绕组松动故障诊断模型与其他 3 种模型的综合对比如图 8 所示。

表 3 基于 VMD 和 SVM 模型的诊断结果

绕组状态	正确个数/组	准确率/%
正常	51	85.00
预紧力下降 40%	52	86.67
预紧力下降 80%	49	81.67
合计	152	84.44

表 4 基于 VMD 和 PSO-SVM 模型的诊断结果

绕组状态	正确个数/组	准确率/%
正常	52	86.67
预紧力下降 40%	53	88.33
预紧力下降 80%	51	85.00
合计	156	86.67

表 5 基于 VMD 和 GA-SVM 模型的诊断结果

绕组状态	正确个数/组	准确率/%
正常	54	90.00
预紧力下降 40%	55	91.67
预紧力下降 80%	53	88.33
合计	162	90.00

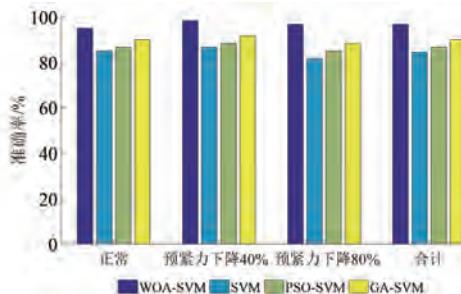


图 8 不同模型的诊断结果对比

由图 8 可知, 在输入样本相同的情况下, WOA-SVM 模型在诊断绕组各种状态时的准确率都达到 95% 以上, 而其他 3 种模型准确率均在 92% 以下, 证明了 WOA 在本文对 SVM 参数寻优时优于传统粒子群优化算法 (PSO)、遗传算法 (GA) 对 SVM 参数的优化。

综上所述, 基于 VMD 和 WOA-SVM 故障诊断模型的诊断精度比传统 VMD-SVM 及传统改进 SVM 模型的诊断精度要高, 更适用于变压器绕组松动故障诊断。

5 结语

本文提出了一种基于 VMD 和 WOA-SVM 的变压器绕组松动故障诊断方法。通过模拟变压器故障试验采集相应变压器振动信号, 然后经 VMD 计算各层 IMF 能量熵构成特征向量, 利用经 WOA 优化 c, g 参数后的 SVM 模型进行故障分类识别。由于 WOA 的调节参数少、结构简单、收敛速度快等特点, 使其能够实现 c, g 参数的快速寻优, 并且不易陷入局部最优解。最终的试验结果表明, 与传统 VMD-SVM 及 PSO-SVM、GA-SVM 模型相比, 本文所提方法在诊断变压器绕组松动故障时存在优越性。

【参考文献】

- [1] 尚海昆, 李宇才, 林伟. 基于 EWT-MQE 的变压器局部放电特征提取 [J]. 电力系统保护与控制, 2022, 50(14): 161.
- [2] 李鹏, 毕建刚, 于浩, 等. 变电设备智能传感与状态感知技术及应用 [J]. 高电压技术, 2020, 46(9): 3097.
- [3] 刘云鹏, 李欢, 高树国, 等. 分布式光纤传感在大型变压器温度和绕组变形监测中的应用研究 [J]. 中国电机工程学报, 2022, 42(16): 6126.
- [4] 邓祥力, 朱慧, 杨梅, 等. 基于多状态模型的变压器绕组早期故障保护方法研究 [J]. 中国电机工程学报, 2022, 42(18): 6704.
- [5] 马鑫, 尚毅梓, 胡昊, 等. 基于数据特征增强和残差收缩网络的变压器故障识别方法 [J]. 电力系统自动化, 2022, 46(3): 175.
- [6] 赵洪山, 李宇昊. 基于比例强度模型的变压器不完全检修策略 [J]. 电力自动化设备, 2021, 41(6): 179.
- [7] 盛健, 银星茜, 邓玮丹, 等. 基于相空间重构技术的断路器振动信号边缘特征提取 [J]. 高压电器, 2022, 58(9): 27.
- [8] 阮江军, 杨秋玉, 黄道春, 等. 高压断路器机械振动信号混沌吸引子形态特性 [J]. 电力自动化设备, 2020, 40(3): 187.
- [9] 赵莉华, 张振东, 张建功, 等. 运行工况波动下基于振动信号的变压器故障诊断方法 [J]. 高电压技术, 2020, 46(11): 3925.
- [10] 张玉良, 马宏忠, 蒋梦瑶, 等. 基于 SSI-MSVM 的调相机轴承故障诊断方法 [J]. 电机与控制应用, 2021, 48(3): 87.

- [11] 周宇, 马宏忠, 黄凤文, 等. 基于振动的变压器绕组松动缺陷诊断方法[J]. 中国电力, 2018, 51(6): 83.
- [12] 李莉, 朱永利, 宋亚奇. 变压器绕组多故障条件下的振动信号特征提取[J]. 电力自动化设备, 2014, 34(8): 140.
- [13] 李楠, 马宏忠, 张玉良, 等. 基于特征筛选和改进深度森林的变压器内部机械状态声纹识别[J]. 电机与控制应用, 2022, 49(9): 57.
- [14] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016.
- [15] 李旭东, 张向文. 基于主成分分析与 WOA-Elman 的锂离子电池 SOH 估计方法[J]. 储能科学与技术, 2022, 11(12): 4010.
- [16] 谢丽蓉, 王斌, 包洪印, 等. 基于 EEMD-WOA-LSSVM 的超短期风电功率预测[J]. 太阳能学报, 2021, 42(7): 290.
- [17] 张九思, 马宏忠, 李勇, 等. 基于 VMD 的变压器绕组松动故障分析与诊断[J]. 高压电器, 2021, 57(8): 198.
- [18] 高淑萍, 宋晓辰, 宋国兵. 基于 VMD 能量熵的混合双端直流输电线路纵联保护方案[J]. 电力系统保护与控制, 2022, 50(14): 123.
- [19] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51.
- [20] 叶远波, 李端超, 谢民, 等. 基于 SSA-SVM 的继电保护装置状态评估方法研究[J]. 电力系统保护与控制, 2022, 50(8): 171.
- [21] 安国庆, 史哲文, 马世峰, 等. 基于 RF 特征优选的 WOA-SVM 变压器故障诊断[J]. 高压电器, 2022, 58(2): 171.
- [22] 张玉良, 马宏忠, 蒋梦瑶. 基于 VMD-MSVM 的同步调相机载荷分配故障诊断方法[J]. 电力工程技术, 2022, 41(1): 185.