

Mechanical Fault Detection Method in High Voltage Circuit Breakers by Using Hybrid Features and Integrated Extreme Learning Machine *

TIAN Yuan *, HUANG Zuyuan, ZHANG Hang, SU Wenwei,
GENG Zhenwei, GAO Yudou
(Information center of Yunnan Power Grid Co., Ltd., Kunming Yunnan 650011, China)

Abstract: A mechanical fault detection method for high voltage circuit breaker based on hybrid feature extraction and integrated extreme learning machine (IELM) is proposed. Firstly, the vibration signal is decomposed by using fully integrated adaptive noise empirical mode decomposition (CEEMDAN) to obtain the intrinsic mode function (IMF). Then, the time-frequency matrix is obtained through sub-band reconstruction of each order IMF component combined with Hilbert transform and band-pass filter. The time-frequency matrix is transformed into energy matrix, the frequency band is normalized by using normal cumulative distribution function (NCDF), and the time-frequency entropy and singular entropy are extracted to form the mechanical fault feature vector. In addition, a fault classification system is established. The advantage of CEEMDAN scheme combined with band-pass filtering is that it can eliminate modal aliasing, reduce the addition of auxiliary noise and improve the decomposition efficiency. In addition, the normalized singular entropy of NCDF has more stable performance. IELM composed of multiple weak classes can solve the shortcomings of traditional extreme learning machines. Experimental results based on measured data show that mechanical faults can be effectively detected by using this method through small samples.

Key words: high-voltage circuit breakers; vibration signals; empirical mode decomposition; time-frequency entropy; singular entropy; extreme learning machine

EEACC: 1210; 7220

doi: 10.3969/j.issn.1005-9490.2023.01.034

基于混合特征和集成极限学习机的高压断路器机械故障检测 *

田 园 *, 黄祖源, 张 航, 苏文伟, 耿贞伟, 高宇豆
(云南电网有限责任公司信息中心, 云南 昆明 650011)

摘 要: 提出了一种基于混合特征提取和集成极限学习机 (IELM) 的高压断路器机械故障检测方法。首先, 采用全集成自适应噪声经验模态分解 (CEEMDAN) 对振动信号进行分解, 得到固有模态函数 (IMF)。然后结合 Hilbert 变换和带通滤波器对各阶 IMF 分量进行子带重构, 得到时频矩阵。将时频矩阵转化为能量矩阵, 利用正态累积分布函数 (NCDF) 对频带进行归一化, 提取出时频熵和奇异熵, 形成机械故障特征向量。此外, 还建立了故障分类系统。结合带通滤波的 CEEMDAN 方案优点是可以消除模态混叠, 减少辅助噪声的加入, 并提高分解效率。此外, NCDF 归一化的奇异熵具有更稳定的性能。由多个弱类组成的 IELM 可以解决传统极限学习机的不足。基于实测数据的实验结果表明, 该方法能有效地通过小样本进行机械故障检测。

关键词: 高压断路器; 振动信号; 经验模态分解; 时频熵; 奇异熵; 集成极限学习机

中图分类号: TP206+.3

文献标识码: A

文章编号: 1005-9490(2023)01-0203-07

高压断路器作为电力系统中的重要电气设备, 具有优化电网结构和保护电网安全的双重作用。高压断路器一旦损坏, 可能会导致极大的经济损失, 甚至危及系统安全。因此, 准确识别高压断路器的缺陷和故障显得尤为重要。

随着人工智能的发展, 机械故障诊断方法逐渐与人工智能技术相结合^[1-3]。在许多新兴的诊断方法中, 振动信号、接触行程位移和电磁线圈电流等逐渐

成为典型诊断方法^[4-6]。基于振动信号的非侵入式故障诊断方法由于在数据采集方面十分便捷, 逐渐受到重点关注^[7-8]。其中, 常用的时频分析方法主要有小波变换、小波包变换、傅里叶变换等^[9-10]。文献[11]提出一种基于 Relief-F 算法和灰色关联分析的故障诊断方法, 可以降低模型复杂度并提高识别精度。文献[12]提出一种自适应白噪声完整集合经验模态分解 (Complete Ensemble Empirical Mode Decom-

position with Adaptive Noise, CEEMDAN) 与样本熵相结合的故障特征提取方法。文献[13]提出了一种基于核主成分分析(Kernel Principal Component Analysis, KPCA)的 SoftMax 故障诊断模型。采用基于 SoftMax 的分类算法对故障进行定位再识别。文献[14]提取信号的多层 IMF 特征,输入支持向量机来训练分类模型。然而现有很多算法的识别精度都不高。

为了解决这个问题,本文提出了一种新的高压断路器机械故障诊断方法。首先,采用 CEEMDAN 算法进行振动信号的时频分析,结合 Hilbert 变换和带通滤波器对各阶内涵模态分量(Intrinsic Mode Functions, IMF)分量进行重构,然后提取能量矩阵的时频熵和正态累积分布函数(Normal Cumulative Distribution Function, NCDF)归一化后的奇异熵,利用混合特征训练集成极限学习机(Integrated Extreme Learning Machine, IELM),并将其用于高压断路器小故障样本的分类。实验结果证实了本文提出的高压断路器机械故障检测方法的优越性。

1 信号的特征提取

1.1 基于 CEEMDAN 的波形分解方法

已知要处理的信号 $x(t)$, 则 CEEMDAN 算法可以表示为以下步骤:

通过 EMD 分解 $x(t)$ 和 $\varepsilon_0 w_i(t)$, 得到第一层的 IMF 分量:

$$c_1(t) = \frac{1}{I} \sum_{i=1}^I E_1(x(t) + \varepsilon_0 w_i(t)) \quad (1)$$

式中: $i=1, 2, \dots, I$, I 为辅助噪声的相加次数。于是可以得到第一边距为:

$$r_1(t) = x(t) - c_1(t) \quad (2)$$

通过 EMD 分解 $r_1(t)$ 和 $\varepsilon_1 E_1(w_i(t))$, 得到第二层的 IMF 分量:

$$c_2(t) = \frac{1}{I} \sum_{i=1}^I E_1(r_1(t) + \varepsilon_1 E_1(w_i(t))) \quad (3)$$

与式(2)和(3)相似, $(k+1)$ 阶 IMF 分量可以表示为:

$$c_{k+1}(t) = \frac{1}{I} \sum_{i=1}^I E_1(r_k(t) + \varepsilon_k E_k(w_i(t))) \quad (4)$$

在边距满足残差分量的终止条件之前, 可以将原始信号 $x(t)$ 分解为:

$$x(t) = \sum_{k=1}^K c_k(t) + r(t) \quad (5)$$

式中: K 是 IMF 分量的总阶数, $r(t)$ 是残差分量。

1.2 基于希尔伯特变换和带通滤波的波形重构

本文采用基于希尔伯特变换和带通滤波器的波

形重构方法, 将分解后的波形重构到各个频带, 提取同一类别信号的一般特征, 并研究不同类型信号之间的差异。波形重构和带通滤波过程表示为:

首先各阶的 IMF 分量 $c_k(t)$ 通过希尔伯特变换可以表示为:

$$H[c_k(t)] = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{c_k(\tau)}{t-\tau} d\tau \quad (6)$$

然后解析信号可以构造为:

$$z_k(t) = c_k(t) + jH[c_k(t)] = \alpha_k(t) e^{j\phi_k(t)} \quad (7)$$

因此, 对应的相函数可以表示为:

$$\phi_k(t) = \arctan \frac{H[c_k(t)]}{c_k(t)} \quad (8)$$

此外, 相位函数的瞬时频率表示为:

$$f_k(t) = \frac{1}{2\pi} \times \frac{d\phi_k(t)}{dt} \quad (9)$$

假设预先划分的频带数为 M 。 $(F_{m-1}, F_m) |_{m=1, 2, \dots, M}$ 频带的重构信号可以通过遍历每个 IMF 分量 $c_k(t)$ 得到。当 $c_k(t)$ 中各数据点的瞬时频率在该频带内时, 保持该数据点; 否则, 它将被清除。最后可以形成一个新的序列。通过计算新的序列

$D(t) = \sum_{k=1}^K \hat{c}_k(t)$ 可以获得位于 $(F_{m-1}, F_m) |_{m=1, 2, \dots, M}$ 频带的波形。原始波形可以分解为每个指定的频带。通过分析振动信号在同一尺度上的变化, 方便了 IMF 分量在不同频段的划分。

1.3 基于熵的混合特征提取

本文采用两个熵特征来表征高压断路器的机械状态。时频熵以能量矩阵为分析对象, 分别统计计算各时间段和各频带的能量分布。时频熵在时频域揭示了振动信号在不同力学状态下的能量分布特征; 奇异熵主要描述了时频矩阵奇异值的分布统计量。奇异值分解可以提取信号在干扰和噪声发生时的稳定性特征, 以及振幅由大到小的顺序分布。由于奇异值分布在不同时间段的下降程度不同, 因此奇异值的概率分布也不同。

①时频熵

在频域上, 将重构波形分成 M 个不同频段的子波形, 形成 $M \times N$ 大小的时频矩阵。在时域中, 将时频矩阵等分为 L 个时间段, 形成 $M \times L$ 个分块时频矩阵, 其中每个分块矩阵的长度为 N/L 。令 $D_l^m(t)$ ($l=1, 2, \dots, L; m=1, 2, \dots, M$) 为第 M 个频带内第 l 个周期所对应的时间序列。其能量值 $E_{l,m}$ 的计算公式表示为:

$$E_{l,m} = \sqrt{\sum_{t=1}^{N/L} D_l^m(t)^2} \quad (10)$$

由式(10)可将分块时频矩阵转换为分块能量矩阵。然后,将能量矩阵按下式归一化:

$$P_{l,m} = E_{l,m} / E \quad (11)$$

式中: E 为矩阵的总能量; $P_{l,m}$ 为 $E_{l,m}$ 在 E 中的比例。作为评价时间序列复杂性的指标, 香农熵常用来表征信号的不确定性。不确定性越大, 熵就越大。熵 Θ 可以表示为:

$$\Theta = - \sum_{i=1}^R \zeta_i \ln \zeta_i \quad (12)$$

本文采用香农熵其作为特征属性。在能量矩阵中提取时频域方向的时频熵特征。计算公式可表示为:

$$\begin{cases} W_l^t = - \sum_{k=1}^M (P_{l,k} \times \ln(P_{l,k})) \\ W_m^f = - \sum_{k=1}^L (P_{k,m} \times \ln(P_{k,m})) \end{cases} \quad (13)$$

上式中, W_l^t 是时域第 l 个时间段的特征值, 反映了这一时间段内不同频带的能量分布, 简称为时域熵 (Time-domain Entropy, TE)。 W_m^f 是频域内第 m 个频带的特征值, 反映了该频带内不同时段能量分布, 简称为频域熵 (Frequency-domain Entropy, FE)。 $W = [W_1^t, W_2^t, \dots, W_L^t, W_1^f, W_2^f, \dots, W_M^f]$ 为总特征集, 即本文描述的时频熵 (Time Frequency Entropy, TFE)。从特征向量的形式可以看出, TFE 是由 TE 和 FE 组成的。

②NCDF 奇异熵

高压断路器运行产生的振动信号具有一定数量的非周期冲击最大值, 如图 1 所示。这些数值是由机械部件之间的强烈碰撞和干扰因素的影响造成的。因此, 振动信号的幅值并不与振动能量的衰减同步降低。NCDF 是服从正态分布的概率密度函数的积分, 可以描述随机变量 x 的概率分布, 表示为:

$$F(x; \mu, \sigma) = \frac{1}{\sigma \sqrt{2\pi}} \int_{-\infty}^x \exp\left(-\frac{(t-\mu)^2}{2\sigma^2}\right) dt \quad (14)$$

式中: μ , σ 和 σ^2 分别为随机变量 X 的均值、标准差和方差。图 2 显示了均值为零时不同方差下的 NCDF 分布, 横坐标为 x 的数值, 纵坐标为 NCDF 数




图 1 振动信号冲击最大值

值, 可见, 不同 σ^2 量级的 NCDF 曲线中间陡, 两端平缓, 陡峭程度与 σ^2 的大小有关。合理的参数选择可以有效地将冲击最大值分布到曲线的两极。从本质上突出振动信号的整体分布, 从而降低冲击最大值的影响。在 NCDF 完成每个频带的归一化处理后, 奇异熵提取步骤如下所示。




图 2 不同方差下的 NCDF 分布

假设 D 是一个 $a \times b$ 大小矩阵。根据奇异值分解, 对于任何 $a \times b$ 矩阵, 总有一个 $a \times c$ 矩阵 U , 一个 $c \times b$ 矩阵 V , 一个 $c \times c$ 对角矩阵 Λ_c 。这样矩阵 D 可以表示为:

$$D = U \Lambda V^T \quad (15)$$

式中: 对角元素 $\lambda_k (k=1, 2, \dots, c)$ 称为矩阵 D 的奇异值。奇异值是非负的, 并按递减方式排列。然后, 对奇异值进行归一化:

$$p_k = \lambda_k / \sum_{k=1}^c \lambda_k \quad (16)$$

式中: p_k 为 λ_k 占总奇异值的比例。另外, 奇异熵 (Singular Entropy, SE) 可以定义为:

$$S_E = - \sum_{k=1}^c p_k \ln p_k \quad (17)$$

1.4 集成极限学习机 (IELM)

根据 ELM 的原理, 其输出可以表示为:

$$H\beta = Y \quad (20)$$

式中: H 为隐含层的输出矩阵。通过计算式(20)的最小二乘解, 可以得到 β 的解:

$$\min_{\beta} \| H\beta - Y \| \quad (21)$$

由式(21), 可以得到解为:

$$\hat{\beta} = H^+ Y \quad (22)$$

式中: H^+ 是 H 的 Moore-Penrose 广义逆矩阵。使用极限学习机 (Extreme Learning Machine, ELM) 作为高压断路器机械故障诊断模型的分类器有两个缺点: 因为权重和偏差是随机产生的, 每个训练过程生成的网络不一致, 其性能也有显著差异。而且, 对于每个生成的模型, 评价最优准则都是不足的。针对单一极限学习机存在的不足, 本文提出了一种集成极限学习机 (IELM)。IELM 由一组 ELM 生成的许多弱分类器组成。决策分类的实现过程可以表

述为:

对于具有多个输出节点的 ELM,通常以输出值最高的类别作为最终的输出标签。例如,给定一个测试数据 $x, f(x) = [f_1(x), f_2(x), \dots, f_w(x)]$ 为 ELM 各输出节点的值,其中 w 为输出节点的个数, $f_i(\cdot)$ 为 ELM 函数模型。为了便于描述, $f(x)$ 的值是 1 到 w 范围内的整数。具有多个输出节点的 ELM 的决策函数可以表示为:

$$\text{label}(x) = \underset{i}{\operatorname{argmax}} f_i(x), i \in [1, 2, \dots, w] \quad (23)$$

式中: $\operatorname{arg}(\cdot)$ 是求得自变量的值函数。式(23)右侧表示最大情况下的类别标签。IELM 由一组 ELM 生成, ELM 的决策函数可表示为

$$\text{label}(x) = \underset{i}{\operatorname{argmax}} \sum(i), i \in [1, 2, \dots, w] \quad (24)$$

式中: $\sum(i)$ 表示预测结果为 i 的子分类器数量。本文提出了一种基于混合特征提取和 IELM 的高压断路器机械故障诊断方法。

2 实验分析

本实验采用室内真空断路器 ZN63A-12。实验装置采集数据的照片如图 3 所示。该传感器采用压电式加速度传感器 (LC0102T 型), 灵敏度为 10.06 mV/g_n , 可测范围为 $(0 \sim 500 \text{ g}_n)$, 频率响应范围为 $2 \text{ Hz} \sim 13\,000 \text{ Hz}$ 。数据采集单元采用 NI 公司生产的多功能设备 (USB-6211), 其更新速率为 250 kS/s 。在该平台上模拟了四种实际力学状态, 并进行了相应的数据采集。在该数据集中, 正常状态、基部松动状态、c 相超前-关闭状态和 c 相滞后-关闭状态的数据分别记录为第 1 类至第 4 类。第 3 和第 4 类属于异步关闭失败。此外, 为了验证提出的方法在实际现场是否有效, 可以获得背景干扰下的实验数据, 如断路器开合、行人或车辆通过等。

本文以 20 kHz 的采样频率采集各机械状态的振动信号, 总采样时间为 0.5 s 。为了减轻传感器零点漂移的影响, 在特征提取前需要对振动信号进行截取。



图 3 数据采集实验装置照片

启动前 10 ms 、启动后 190 ms 的波形 (共 $4\,000$ 个点) 被认为最有价值的信息。对信号进行 CEEMDAN 分解。加入高斯白噪声是原信号标准差幅值的 0.2 倍。加入时间为 20 s 。图 4 为基部松动状态振动信号分解后提取的 IMF 分量和残差分量, 其中横轴为 $4\,000$ 个数点的时间序列, 纵轴为振动信号幅值, 单位是 mV 。很明显, 六阶后 IMF 分量的振幅较小。




图 4 在基部松动状态下对每阶分量的 CEEMDAN 分解

依次对各阶分量信号进行逐级重构, 并计算与原信号的相关性, 得到表 1 结果。从图 4 可以看出, 第 7 IMF 波形的幅值明显减小。由表 1 可知, 一阶 IMF 分量重构信号与原信号的相关性达到 0.997 。在频带划分方面, 共分配 10 个频带, 带宽为 $1\,000 \text{ Hz}$, 即频带分别从 0 Hz 到 $1\,000 \text{ Hz}$, $1\,000 \text{ Hz}$ 到 $2\,000 \text{ Hz}$, ..., $9\,000 \text{ Hz}$ 至 $10\,000 \text{ Hz}$ 。为了提取时频熵, 将每个频带的平均分成 20 个集合, 形成 10 组 20 个分块时频矩阵, 每个分块矩阵的大小为 1×200 。如果分块数量过小, 容易掩盖重要信息, 提取的特征不具有代表性。

表 1 异阶重构信号与原信号的相关性

顺序	1st	2nd	3rd	4th	5th	6th	7th
第 1 类	0.819	0.921	0.976	0.990	0.994	0.997	0.998
第 2 类	0.769	0.901	0.960	0.989	0.995	0.997	0.999
第 3 类	0.797	0.911	0.975	0.997	0.999	0.999	0.999
第 4 类	0.794	0.921	0.979	0.991	0.996	0.998	0.999

通过多次实验, 本文选择的块数是最优的结果。每种力学状态随机选取 3 个样本, 提取 TFE。因此, 绘制了二维特征图, 如图 5 所示。

结果表明, c 相超前合闸和滞后合闸两种状态在时域特性上与其他两种状态有明显的区别。尤其是

c相滞后关闭状态与其他三种状态的差异。而c相导合闸态与正常状态或基部松动状态的差异则体现在第7和第11个特征上。由于正常状态和基部松动状态的差别很小,时域的特征不足以区分它们。同样,第21~25个特征的4种力学状态之间虽然存在细

微的差异,但在频域上差异不明显。可以看出用于区分每个机械的时频熵特性状态只取决于几个特性。振动能量在噪声和扰动背景下可能随机变化,导致基于能量矩阵提取的特征不稳定。因此,利用多种混合特征来增强信号的表征能力具有十分重要的意义。




图5 四种不同力学状态的时频熵

方差(σ^2)的值决定了标准化的程度。如果 σ^2 的值太小,NCDF曲线太陡,大部分信息会被映射到曲线的两端。信号的细节会被淹没,即使是很小的噪声信号也会被放大。如果 σ^2 的值太大,NCDF曲线就太平坦。大部分信息将分布在渐变区域的中间而近似线性,无法达到减弱冲击信号的效果。如图6(a)、图6(d)所示,NCDF归一化前后在第一类存在信号比较。在图6(a)中,对信号的前2000个数据点进行标准化处理,在不同的 σ^2 范围内分别映射到0~1的范围(如图6(b)、图7(c)、图7(d)所示)。在图6(b)中,大部分数据被映射到0和1,信号的细节几乎完全被淹没。在图6(c)和图6(d)中,随着 σ^2 的增大,标准化后的信号趋于原信号的线性映射。对于 $\sigma^2=2$,其他三种状态(第二类、第三类、第四类)的归一化信号分别如图6(e)、图6(f)、图6(g)所示。

显然,NCDF标准化后的信号冲击最大值可以明显减小,这有利于奇异值分解。为了达到弱化冲击值的效果,对比了多次实验的结果,最终将 σ^2 的取值设定为2。在时域中,将100个数据点划分为40个部分,形成40个时频矩阵,其中每个分块矩阵的大小为 10×100 ,即可得到每个分块矩阵的SE。图7给出了三组具有NCDF标准化和不具有NCDF标准化的c相超前闭合状态振动信号样本的奇异熵特征。在未归一化的情况下,同一类型振动信号的

奇异熵都趋于相同的值,不同时间段的奇异熵没有显著差异。NCDF标准化后,不仅同一周期的奇异熵趋近于同一值,而且不同周期的特征差异尤为突出。为了使奇异熵特征可视化,局部奇异熵从振动信号中提取三维坐标的四个不同的机械状态描绘在图8中。图8(a)、图8(b)、图8(c)和图8(d)描述奇异熵的特征分布间隔分别在10th~12th, 23th~25th, 26th~28th和30th~32th不同的情况下,每个案例随机抽取10个样本。对于图8(b)所示的区间,虽然第1类与其他三类之间存在一定的差异,但这种差异太小,很难准确分类。如果将其与图8(a)和图8(c)所表示的区间相结合形成完整信息,则第1类、第3类和第4类之间的特征差异显著增大。这些多区间特征的集合是振动信号中故障特征表达的有效方法。

为了分析本文方法与以往研究中其他方法分类精度的差异,将本文方法与文献[15~17]中方法进行比较。表2总结了四种方法的检测结果。虽然文献[15]和[16]中都使用了时频熵作为特征,但结果却有很大的不同,这主要是由于SVM和BPNN之间的差异。文献[15,17]使用SVM作为分类器,其识别率高于文献[16]。但也有一定程度的误判。本文方法的分类准确率高于其他三种方法,主要体现在双重特征弥补单类特征表达能力不足的问题。此外,利用IELM作为分类器,弥补了单一分类器泛化能力的不足。




图 6 不同振动信号的 NCDF 归一化信号




图 7 NCDF 归一化与非归一化奇异熵的比较

表 2 不同算法的性能比较

方法	第 1 类	第 2 类	第 3 类	第 4 类	正确率/%
本文方法	12	12	12	12	100
文献[15]	10	9	10	12	89.5
文献[16]	9	10	8	11	79.1
文献[17]	11	9	12	12	91.6




图 8 不同力学状态下的部分奇异熵

3 结论

本文提出了一种基于混合特征提取和 IELM 的高压断路器机械故障诊断方法,最后通过实验分析证明了所提方案的优越性,主要结论如下:

①利用 CEEMDAN 对振动信号进行分解,构造了两个不同的特征(时频熵和奇异熵),并用 NCDF 对波形进行归一化处理,提高了奇异熵表征信号的稳定性。实验表明,混合特征的分类正确率可以达到 100%,高于单一类型特征的分类正确率。

②根据本文方法与文献[15]、[16]、[17]中的方法相比,在时频信号分析、特征提取和模式识别等方面都有较大的改进。所提方法具有更高的故障识别率。

参考文献:

- [1] 林琳,陈志英. 基于粗糙集神经网络和振动信号的高压断路器机械故障诊断[J]. 电工技术学报,2020,35(S1):277-283.
- [2] 余锋,许开熙,黄俊,等. 基于 BP 神经网络的高压断路器故障诊断[J]. 真空科学与技术学报,2019,39(3):249-253.
- [3] 王晓明,周柯,周卫,等. 基于恒等映射 CNN 的高压断路器机械故障诊断方法[J]. 高电压技术,2021,47(10):3657-3663.
- [4] 陈欣昌,冯玓,林圣. 基于深度自编码网络的高压断路器操作机构机械故障诊断方法[J]. 高电压技术,2020,46(9):3080-3088.
- [5] 韩宇,董波. 一种基于线圈电流的高压断路器机械故障诊断方法[J]. 高压电器,2019,55(9):241-246.
- [6] 杨元威,关永刚,陈士刚,等. 基于声音信号的高压断路器机械故障诊断方法[J]. 中国电机工程学报,2018,38(22):6730-6737.
- [7] 关永刚,杨元威,钟建英,等. 高压断路器机械故障诊断方法综述[J]. 高压电器,2018,54(7):10-19.
- [8] 李云,傅成华,吴浩. 高压断路器机械故障研究综述[J]. 科技风,2015(18):31-32.
- [9] 李宾宾,柯艳国,田宇,等. 基于小波包理论的高压断路器机械状态检测[J]. 合肥工业大学学报(自然科学版),2019,42(7):924-929.
- [10] 金鑫晨,崔鹤松,武建文,等. 基于小波包能量谱和延时时间的断路器故障诊断[J]. 高压电器,2019,55(6):38-44.
- [11] 李邦彦,齐伟强,桂媛,等. 基于 Relief F 和灰色关联分析的高压断路器机械故障诊断[J]. 高压电器,2020,56(6):197-203,210.
- [12] 赵书涛,马莉,朱继鹏,等. 基于 CEEMDAN 样本熵与 FWA-SVM 的高压断路器机械故障诊断[J]. 电力自动化设备,2020,40(3):181-186.
- [13] 王昱皓,武建文,马速良,等. 基于核主成分分析-SoftMax 的高压断路器机械故障诊断技术研究[J]. 电工技术学报,2020,35(S1):267-276.
- [14] 陈尚,郑翔. 基于 VMD 能量熵与支持向量机的断路器机械故障诊断方法研究[J]. 黑龙江电力,2019,41(1):60-63.
- [15] Huang N T, Chen H J, Zhang S X, et al. Mechanical Fault Diagnosis of High Voltage Circuit Breakers Based on Wavelet Time-Frequency Entropy and One-Class Support Vector Machine[J]. Entropy, 2016, 18(1):7.
- [16] Liu S, Tan J, Meng F G, et al. Study of PSO-BP Neural Networks Application in High Voltage Circuit Breakers Mechanical Fault Diagnosis [C]//2016 China International Conference on Electricity Distribution (CI-CED), Xi'an, China, 2016:1-5.
- [17] Huang N T, Chen H J, Cai G W, et al. Mechanical Fault Diagnosis of High Voltage Circuit Breakers Based on Variational Mode Decomposition and Multi-Layer Classifier[J]. Sensors, 2016, 16(11):1887.



田园(1989—),男,汉族,云南昆明人,硕士,工程师,主要从事电网数字化工作 228478554@qq.com。