

# 基于多维特征与优化 SVM 在高压断路器故障分类中的应用\*

杨 帅<sup>1</sup> 张 岩<sup>1</sup> 梁永春<sup>1</sup> 王昭雷<sup>2</sup> 符鑫哲<sup>1</sup> 王子昕<sup>1</sup> 任泽瑄<sup>1</sup>

(1. 河北科技大学电气工程学院 石家庄 050091; 2. 国网河北省电力有限公司超高压分公司 石家庄 050070)

**摘 要:**针对利用电流信号进行高压断路器故障分类过程中,采集电流信号原始特征提取种类单一,故障识别率低和分类性能退化的问题,提出一种基于多维特征与支持向量机(support vector machine,SVM)相结合的故障分类方法。首先,提取分闸电流信号关键时间、电流幅值作为局部特征,提取电流信号的全局特征组成多维特征向量,构建断路器操作过程的电流联合原始特征集;其次,为消除冗余特征信息,使用主成分分析法(principal component analysis,PCA)降维后构建最终特征向量集合;最后,使用粒子群算法(particle swarm algorithm,PSO)优化支持向量机参数设置问题,对断路器进行故障分类。试验结果表明,采用本文提出的方法识别准确率较高,具有实际工程应用价值。

**关键词:**高压断路器;特征向量;粒子群算法;支持向量机

**中图分类号:** TN06 **文献标识码:** A **国家标准学科分类代码:** 470.40

## Application of multidimensional feature-based and optimized SVM in high-voltage circuit breaker fault classification

Yang Shuai<sup>1</sup> Zhang Yan<sup>1</sup> Liang Yongchun<sup>1</sup> Wang Zhaolei<sup>2</sup> Fu Xinzhe<sup>1</sup> Wang Zixin<sup>1</sup> Ren Zexuan<sup>1</sup>

(1. School of Electrical Engineering, Hebei University of Science and Technology, Shijiazhuang 050091, China;

2. State Grid Hebei Extra High Voltage Company, Shijiazhuang 050070, China)

**Abstract:** Aiming at the use of current signals for high-voltage circuit breaker fault classification process, the acquisition of current signals raw feature extraction of a single type, low fault recognition rate and degradation of classification performance, this paper proposes a fault classification method based on the combination of multidimensional features and support vector machine (SVM). Firstly, the critical time of the tripping current signal and the current amplitude are extracted as local features, and the global features of the current signal are extracted to form a multi-dimensional feature vector, which constructs a joint original feature set of the current of the circuit breaker operation process. Secondly, in order to eliminate redundant feature information, the final set of feature vectors is constructed after dimensionality reduction using principal component analysis (PCA). Finally, particle swarm algorithm (PSO) is used to optimize the support vector machine parameter setting problem for fault classification of circuit breakers. The experimental results show that the recognition accuracy is high using the method proposed in this paper, which has practical engineering application value.

**Keywords:** high-voltage circuit breaker; feature vector; particle swarm algorithm; support vector machine

### 0 引 言

高压断路器是电力设备十分重要的安全控制器件,因

其发生故障会造成难以预料的后果<sup>[1-3]</sup>。断路器运行动作与二次电气回路控制和机械部件之间相互能量传动的过程紧密相连,其相对复杂的结构和不同的运行环境易导致

收稿日期:2024-03-31

\* 基金项目:国家自然科学基金(51877070,61876059)、河北省自然科学基金(E2019208443)、河北省高等学校科学技术研究项目(ZD2021202)、国家级大学生创新创业训练计划项目(202310082004)资助

断路器损坏,产生故障<sup>[4-5]</sup>。分闸脱扣器线圈电流是判断断路器动作状态是否异常十分有效的特征量。因此基于分闸脱扣器线圈电流信号的断路器故障诊断方法受到了学者们的关注<sup>[6-8]</sup>。线圈电流信号可有效反映控制电路中的故障信息,如电压过高或者电阻减小,控制线圈电流信号蕴藏完整的二次回路和电磁铁控制信息<sup>[9]</sup>。文献[10]使用正常线圈电流波形作为基准向量与实际分合闸线圈电流特征相对比,对断路器运行情况进行评估。文献[11]采用集合经验模态分解(ensemble empirical mode decomposition, EEMD)样本熵值的方法进行特征提取,将提取后的重要特征通过支持向量机(support vector machine, SVM)进行故障诊断并取得了较好的结果。文献[12]提取断路器分合闸线圈电流信号的特征量,并使用随机森林算法(random forest, RF),对断路器运行情况进行故障分类,但是提取特征较为单一,没有考虑到电流信号的时域特征信息。文献[13]采用断路器负荷开关电机电流信号进行断路器的故障诊断,建立诊断模型,但是没有考虑在特征提取时可能产生的冗余现象。

通过对机器学习和深度学习不断的了解,智能算法与断路器故障分类识别的组合成为研究的重点<sup>[14-16]</sup>。目前常用的算法有 SVM<sup>[17]</sup>、极限学习机<sup>[18]</sup>(extreme learning machine, ELM)和卷积神经网络(convolutional neural network, CNN)<sup>[19]</sup>等。在故障分类模型构建中, SVM 作为机器学习主流算法之一,在解决小样本、非线性及高维问题以及故障运行分类上表现优异。然而, SVM 的分类性能很大程度上取决于模型的参数选择,惩罚因子、核函数参数对 SVM 分类性能效果影响显著。采用粒子群算法(particle swarm algorithm, PSO)较强的全局搜索能力和 SVM 良好的分类效果,以提升故障类型识别准确率。

鉴于此,本文提出提取局部特征和全局特征样本的方法对断路器进行故障识别分类。首先对原始采集波形进行降噪处理并提取关键时间、电流幅值作为局部特征,其次计算电流信号全局参数作为全局特征值,构成断路器多特征原始向量集合。在此基础上,对构造的原始特征集合进行数据归一化处理,使用主成分分析法(principal component analysis, PCA)进行降维处理,确定出最优的特征集合,选择 SVM 对特征集合进行故障分类,并进一步采用 PSO 优化了 SVM 参数选取的问题。通过实验验证了本文方法对于断路器不同故障类型可以准确识别,提高了目标分类的识别准确率,具有一定的实际应用价值。

### 1 高压断路器分闸电磁铁等效电路分析

ZN63(VS1)型高压断路器是三相交流 50 Hz,额定电压为 7.2~12 kV 高压设备。根据 ZN63(VS1)型高压真空断路器分闸电磁铁脉动直流电的供电方式,可得到分闸电磁铁工作时等效电路,如图 1 所示。

图 1 中 AC 为交流电源, K 为开关, VD<sub>1</sub>~VD<sub>4</sub> 为整

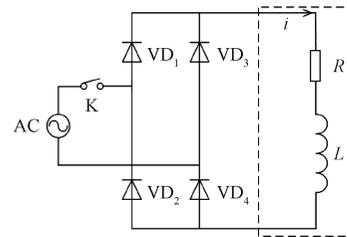


图 1 分闸电磁铁等效电路

Fig. 1 Equivalent circuit of slamming solenoid

流二极管,  $L$ 、 $R$  分别为分闸电磁铁线圈的电感和电阻。在分闸过程中交流电经过整流桥得到的是整流后的脉动直流电压,表达式为:

$$u = u_m |\sin(\omega t + \varphi)| \quad (1)$$

式中:  $u$  为脉动直流电压;  $u_m$  为电源电压幅值;  $\omega$  为电源角频率;  $\varphi$  为电源电压分闸相位角。根据等效电路可得分闸电磁铁电压方程为:

$$u = Ri(t) + \frac{d\psi}{dt} = Ri(t) + L(x) \frac{di}{dt} + iv \frac{dL(x)}{dt} \quad (2)$$

式中:  $i$  为线圈励磁电流;  $\psi$  为线圈磁链;  $x$  为动铁芯位移;  $L(x)$  为随动铁芯位移  $x$  变化的非线性线圈电感;  $v$  为动铁芯运动速度。动态电磁铁吸力公式为:

$$F_s = \frac{1}{2} i^2 \frac{dL(x)}{dx} \quad (3)$$

动铁芯运动阻力公式为:

$$f = f_0 + mg + k(x + l_0) \quad (4)$$

式中:  $f$  为动铁芯运动阻力;  $f_0$  为动铁芯和导向管之间的摩擦力;  $k$  为复位弹簧弹性系数;  $l_0$  为复位弹簧压缩长度。由于本文针对的断路器型号中分闸电磁铁为竖直摆放,所以动铁芯额外受到自身重力  $mg$ , 其中  $m$  为动铁芯质量,  $g$  为重力加速度。

根据式(2)~(4)可推导出分闸电磁铁运动方程为:

$$\begin{cases} F_s - f = m \frac{d^2x}{dt^2} \\ i = \frac{1}{L(x)} \int_0^t \left[ u - iR - vi \frac{dL(x)}{dx} \right] dt \\ v = \frac{1}{m} \int_0^t (F_s - f) dt \\ x = \int_0^t v dt \end{cases} \quad (5)$$

由式(5)可得到电磁吸力  $F_s$  是线圈电流  $i$  和位移  $x$  的函数也是时间  $t$  的函数。同时也可得到分闸电磁铁分闸时的电流特性  $i$ 、速度特性  $v$  和位移特性  $x$ 。因此,分闸电磁铁的运动特性与电磁铁自身的参数和机械结构密切相关。电磁铁的运动特性可以通过线圈电流的变化来确定,因此,通过分析分闸线圈电流信号的特征信息,可以深入研究断路器分闸电磁铁的故障运行特性。为了进一步探究分闸电磁铁的动作状态与线圈电流之间的关系,对分

闸电磁铁线圈电压和电流进行了测量,测量波形结果如图2和3所示。

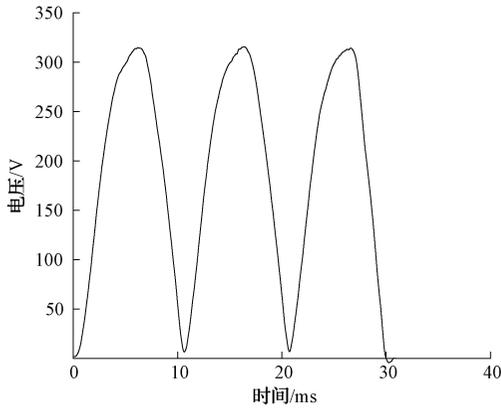


图2 直流电压波形  
Fig.2 DC voltage waveform

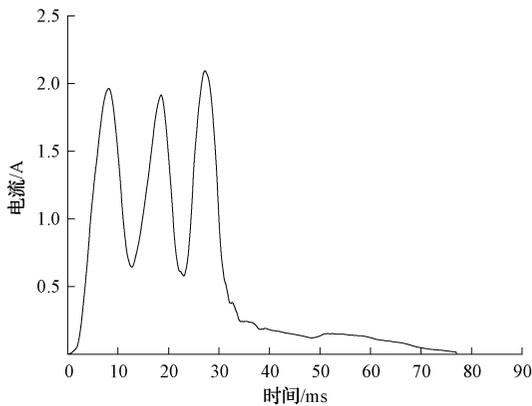


图3 分闸线圈电流波形  
Fig.3 Waveforms of tripping coil current

## 2 多特征提取

分闸电磁铁是高压断路器操作机构的重要组成部分。因为不同类型的故障会影响各动作时间和电流峰谷幅值的变化,同时也包含故障特征信息,为了更加全面地分析断路器不同机械特性的电流信号,分别从局部、全局提取了电流信号的多维特征,有效定义了断路器不同工况下的电流信号。

### 2.1 电路信号局部特征提取

高压断路器处在不同的运行状况时,如动铁芯运动时间、线圈通电时间,采集相对应的线圈电流波形,通过对波形的处理分析,可以计算出电磁铁分闸运动的关键时间点、线圈运动时的电流幅值等信息。

特征向量是指能准确反映信号特征或设备某时刻运行状态的数值参量,通常选取线圈电流波形中不同区域的极值及对应的时间(图4)。利用相邻两点的斜率来近似代替该点的导数,根据导数结果的正负确定极值点。极值

点的计算公式为:

$$f'(x) = \lim_{\Delta x \rightarrow 0} \frac{\Delta y}{\Delta x} = \lim_{\Delta x \rightarrow 0} \frac{f(x_0 + \Delta x) - f(x_0)}{\Delta x} \quad (6)$$

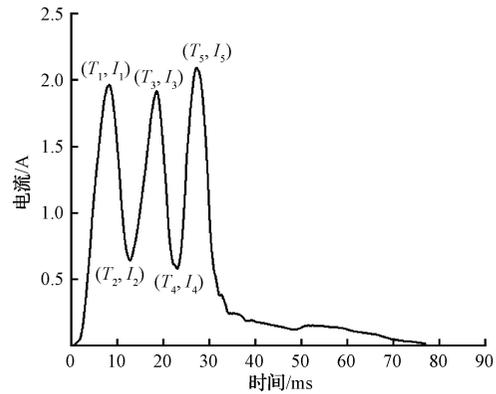


图4 分闸电磁铁线圈电流的局部特征  
Fig.4 Localized characteristics of the current in the coil of the tripping solenoid

通过综合分析并结合电流波形特性,提取分闸线圈电流波形的关键时间参数,电流幅值参数,将分闸线圈电流波形的关键时间参数和电流幅值参数组合作为局部特征分量  $F_1$ 。

### 2.2 电流信号全局特征提取

高压断路器电流信号为一组时间序列的数据,对高压断路器采集的电流运行情况进行时域分析,分别提取了标准差、峭度值、偏度、均方根、波形因子、峰值因子。6种电流信号的时域特征作为全局特征分量  $F_2$ ,充分体现了高压断路器不同运行情况时电流信号的时域特性。6种时域特征量的公式如表1所示。 $\rho_1, \rho_2, \dots, \rho_6$  分别对应标准差、峭度值、偏度、均方根、波形因子、峰值因子6种时域特征值。

表1 时域特征计算公式

Table 1 Calculation formulae for time-domain features

时域特征	
$\rho_1 = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \frac{1}{N} \sum_{i=1}^N x_i)^2}$	$\rho_2 = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \rho_1)^4}{\rho_1^4}$
$\rho_3 = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - \rho_1)^3}{\rho_1^3}$	$\rho_4 = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
$\rho_5 = \frac{\rho_4}{\frac{1}{N} \sum_{i=1}^N  x_i }$	$\rho_6 = \frac{\max  x_i }{\rho_4}$

构建电流局部、全局联合原始特征集,对于电流信号的局部特征分量,取电流信号的关键时间、电流幅值,5个时间特征,5个电流幅值特征,共有10个特征分量;对于

电流信号的全局特征分量,包含6个电流时域特征。因此,电流信号局部、全局联合原始特征集共包含16个特征量  $F$ :

$$F = [F_1, F_2] \quad (7)$$

### 2.3 基于主成分分析的特征向量提取

电流联合原始特征集包含断路器运动过程的动作信息。但对于不同的故障类型,一部分特征是与故障信息相关,一部分特征则是冗余的。冗余的特征可能会影响断路器的故障识别,高维数原始特征集会带来较长计算时间,增加运算时长,同时会造成分类性能退化或者识别准确率降低。为提高分类模型的识别率和泛化能力,构建完成电流信号局部一联合原始特征集合后,本文使用PCA降低原始特征的维度,对数据结构进行简化和保留数据主要特征信息成分的同时,最大程度的减少冗余信息<sup>[20]</sup>。

假设输入样本集  $\mathbf{X} = (x_1, x_2, \dots, x_m)$  为  $n$  维向量,则首先对样本进行中心化处理,那么中心化后样本之间的协方差和协方差矩阵分别为:

$$\text{Cov}(x_i, x_j) = \frac{1}{m-1} \sum_{i,j=1}^n (x_i - \bar{x}_i)(x_j - \bar{x}_j) \quad (8)$$

$$\mathbf{C} = \frac{1}{m} \mathbf{X}\mathbf{X}^T =$$

$$\begin{bmatrix} \text{Cov}(x_1, x_1) & \text{Cov}(x_1, x_2) & \text{Cov}(x_1, x_m) \\ \text{Cov}(x_2, x_1) & \text{Cov}(x_2, x_2) & \text{Cov}(x_2, x_m) \\ \vdots & \vdots & \vdots \\ \text{Cov}(x_m, x_1) & \text{Cov}(x_m, x_2) & \text{Cov}(x_m, x_m) \end{bmatrix} \quad (9)$$

在此基础上求协方差矩阵  $\mathbf{C}$  的特征值  $\lambda$  和特征向量  $\mathbf{u}$ , 并满足:

$$\mathbf{C}\mathbf{u} = \lambda\mathbf{u} \quad (10)$$

将特征值按照从大到小排序并根据需求选择累计方差贡献率前  $k$  个  $\lambda(\lambda_1, \lambda_2, \dots, \lambda_k)$ , 把相对应的特征向量  $\mathbf{u}(u_1, u_2, \dots, u_k)$  作为行向量组成特征向量矩阵  $\mathbf{P}$ , 则可得:

$$\mathbf{Y} = \mathbf{P}\mathbf{X} \quad (11)$$

式中:  $\mathbf{Y}$  为降维到  $k$  维后得特征向量。

## 3 PSO 优化 SVM 原理

### 3.1 SVM

SVM 是一种人工智能算法,在解决过度拟合、样本量小和非线性问题时表现出色<sup>[21]</sup>。在进行分类模式识别时,将原始特征空间的数据样本通过核函数映射到重构的高维特征空间,并构造分类超平面,从而对样本进行有效分类。

假设有一组  $m$  维样本  $(x_i, y_i)$ ,  $x_i$  和  $y_i$  分别为样本和输出类型。即希望找到一个由  $(\omega, b)$  确定的超平面使得所有的正样本都位于该平面上方,所有负样本都位于该平面下方,其中  $\omega$  是超平面的法向量,  $b$  是偏置项。

超平面的目标函数和约束条件为:

$$\min \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n \xi_i \quad (12)$$

$$\text{s. t. } y_i(\omega^T x_i + b) \geq 1 - \xi_i, \xi_i \geq 0 \quad (13)$$

式中:  $\omega$  为权值向量;  $C$  为惩罚因子;  $\xi_i$  为分类允许的误差;  $x_i$  为训练集的样本;  $y_i$  为分类标记。

为约束最优化问题的解,引入拉格朗日函数和核函数,使超平面的目标函数转化为对偶问题,表达式如下:

$$\max \left\{ \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_i a_j y_i y_j k(x_i, x_j) \right\} \quad (14)$$

$$\text{s. t. } \sum_{i=1}^n a_i y_i = 0; 0 \leq a_i \leq c; i = 1, 2, \dots, n$$

式中:  $a$  为拉格朗日乘子,  $k(x_i, x_j)$  为核函数。使用核函数将原始数据映射到特征空间,使线性不可分的数据在高维空间变的可分。常见选取的核函数有线性核函数、RBF 核函数、sigmoid 函数。RBF 核函数拥有性能优异并且应用广泛的特点,所以本文使用 RBF 核函数:

$$k(x, x_i) = \exp(-g \|x_i - x_j\|^2) \quad (15)$$

式中:  $g$  核函数系数;  $k$  代表核函数。SVM 分类模型精度受惩罚因子  $C$  和核参数  $g$  的影响较大,选取合适的参数可以达到最理想的效果,使 SVM 分类器有更好的分类性能。

### 3.2 PSO

本文选用 PSO 来优化 SVM 参数,PSO 是一种全局优化算法,最早基于模拟鸟群的觅食行为而设计,相较于其他优化算法,PSO 算法具有原理简单、高效搜索以及快速收敛的优点<sup>[22-23]</sup>。在 PSO 算法中,算法在初始时刻会产生一定数量的初始解。迭代寻优过程中每个粒子会在空间中进行运动,算法会保留所有粒子找到的最优位置和最佳解向量。PSO 的速度、位置更新公式为:

$$V_{ij}(t+1) = \omega V_{ij}(t) + a_1 r_1 (P_{bestij}(t) - X_{ij}(t)) + a_2 r_2 (G_{bestij}(t) - X_{ij}(t)) \quad (16)$$

$$X_{ij}(t+1) = X_{ij}(t) + V_{ij}(t+1) \quad (17)$$

式中:  $V_{ij}$  为粒子速度;  $X_{ij}$  为粒子位置;  $t$  为迭代次数;  $\omega$  为惯性权重因子,一般取  $0 \sim 1$  之间;  $P_{bestij}(t)$  为第  $i$  个粒子群第  $j$  次迭代的局部最优解;  $G_{bestij}(t)$  为第  $j$  次迭代的全局最优解;  $a_1, a_2$  为加速因子,取值范围为  $0 \sim 2$ ;  $r_1, r_2$  为在  $0 \sim 1$  之间产生的随机数。

### 3.3 PSO 优化 SVM 模型参数

在 SVM 模型中,惩罚参数  $C$  和核函数参数  $g$  非常重要。 $C$  表示支持向量到超平面的距离,其值越大,表示距离越小。对样本分类误差的容忍度越低,准确率越高,其缺点是容易造成过拟合,降低模型的泛化能力。反之,模型的泛化能力强,容易出现欠拟合。核函数参数  $g$  越大,映射维度越高,分类效果越准确。但是,模型会变得更加复杂,容易出现过拟合。反之,则容易出现欠拟合<sup>[24]</sup>。为解决 SVM 模型参数设置的问题,使用 PSO 对参数寻优,能够克服 SVM 人工选取困难等问题,显著提升模型的识别分类效果,整体流程如图 5 所示。

PSO-SVM 算法的具体训练步骤如下。

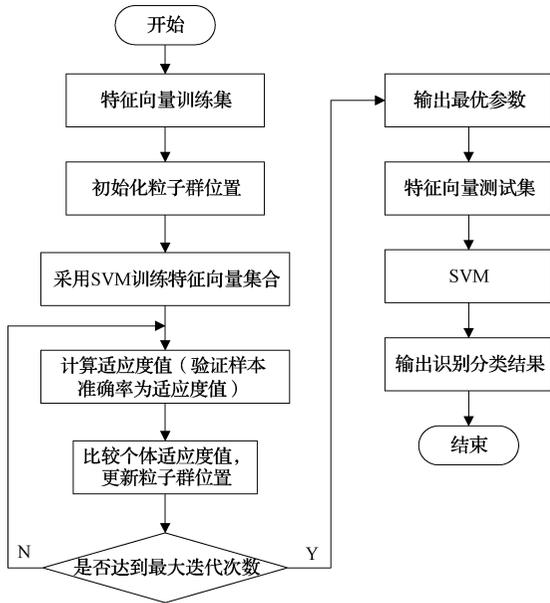


图5 PSO优化SVM参数流程

Fig. 5 Flowchart of PSO optimized SVM parameters

1) 选择高压断路器的实验模拟数据作为模型输入并划分训练集和测试集。

2) 初始化粒子群, 设置粒子数、搜索范围和迭代次数, 根据每个粒子位置并使用 SVM 对训练集训练, 为防止过拟合, 增加寻优的精度, 采用 K 折交叉验证法, 将训练集分为训练样本和验证样本。

3) 设置训练集验证样本集识别准确率作为适应度函数, 评估并记录最优的个体位置。

4) 对 SVM 参数进行迭代更新, 直至满足最终的输出条件, 保留最优参数组合, 使用最优参数对测试集进行识别分类, 输出识别结果。

#### 4 高压断路器故障分类流程

基于高压断路器分闸线圈电流局部、全局特征和 PSO-SVM 的故障分类方法如下。

1) 搭建实验平台, 采集正常运行和模拟故障运行的分闸线圈电流信号, 使用小波阈值法对电流信号进行降噪处理。

2) 对采集的电流信号进行局部、全局特征分量的提取。将断路器运行电流信号的峰谷值时间参数和电流幅值参数组成局部特征分量, 然后计算电流信号的全局特征分量, 共同组成电流信号局部、全局特征向量集合, 对特征向量集合进行数据归一化处理, 使用 PCA 对特征向量集合进行降维处理。

3) 将处理后的特征向量集合使用 PSO-SVM 模型进行故障识别分类。整体高压断路器故障分类流程如图 6 所示。

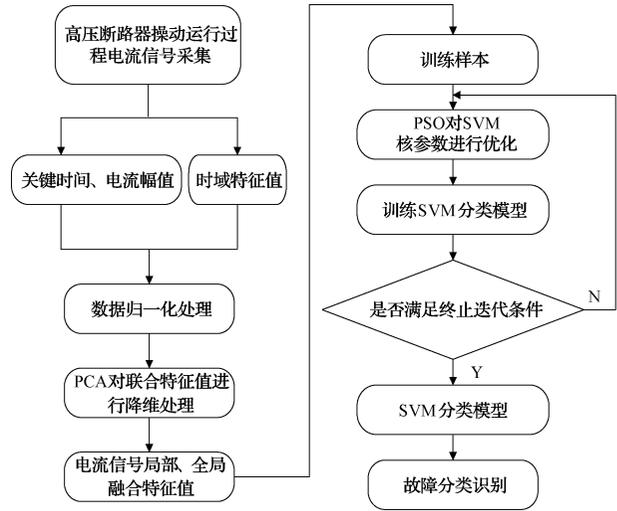


图6 基于电流信号局部-全局特征的高压断路器分类流程  
Fig. 6 Classification process of high voltage circuit breaker based on local-global features of current signal

### 5 实验分析

#### 5.1 实验平台搭建及故障模拟

采用 ZN63(VS1)型高压断路器为实验研究对象搭建故障模拟实验平台, 电流传感器为霍尔闭环直流电流传感器, 数据采集装置为 Hantek6000BE 型号数据采集卡, 在实验模拟中, 为测量分闸电磁铁线圈回路电流, 将电流传感器与分闸电磁铁线圈相连, 使用数据采集卡采集电流传感器中的线圈电流信号, 通过 USB 总线上传到电脑, 使用 LabVIEW 搭建采集程序框图模拟上位机显示并记录断路器的电流信号, 采集的数据以 Excel 形式储存到电脑磁盘。实验模拟平台如图 7 所示。

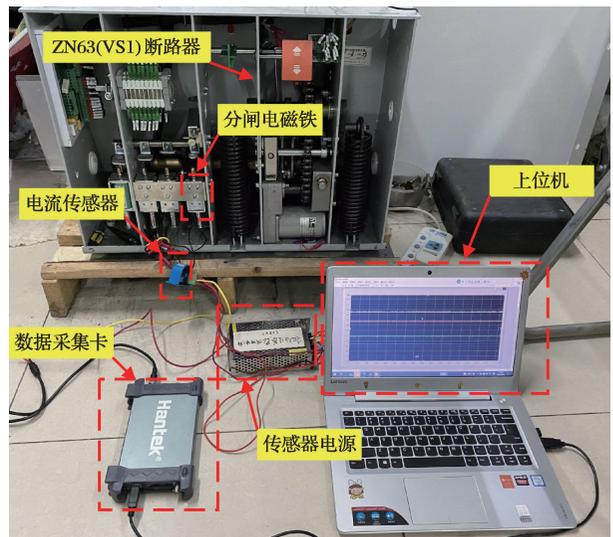


图7 实验模拟平台

Fig. 7 Experimental simulation platform

实验平台模拟断路器5种运行状态,在数据样本集合中,5种断路器运行状态各包含30组样本,根据电流信号局部特征与全局特征提取,每个样本包含16种特征值。共同构成5种状态下的 $150 \times 16$ 维特征向量矩阵。实验中断路器的5种状态及故障模拟方式如表2所示。

表2 5种高压断路器运行状态模拟  
Table 2 Simulation of 5 kinds of high-voltage circuit breaker operation state

故障状态类型	故障模拟方式
正常分闸	断路器正常运行
匝间短路	替换匝数不同的线圈
接触不良	线圈回路串接电阻
操作电压偏高	调整控制电压至240 V
操作电压偏低	调整控制电压至200 V

其中,将正常线圈替换为线径相同而匝数不同的线圈

来模拟线圈匝间短路故障;通过在分闸电磁铁线圈回路串接电阻值,在电路中增加电阻的方式来模拟接触不良故障;分闸线圈的供电电压为220 V,通过调压器调整供电于分闸线圈的电压来模拟控制回路电压偏高或者偏低的故障。为保证故障模拟的准确性,遵循单一变量原则,保证每次实验断路器仅有一种故障。

## 5.2 分闸线圈电流特征提取及结果分析

对采集的电流信号采用小波阈值降噪进行预处理,利用局部斜率求导法提取关键时间、电流幅值。计算上述5种断路器运行状态下的电流信号局部特征参数( $T_1, T_2, T_3, T_4, T_5$ ), ( $I_1, I_2, I_3, I_4, I_5$ ), 以此构成电流信号局部特征分量,部分特征值如表3所示。从表3可以看出,断路器不同运行状态下电流的运行时间、波峰谷值各不相同,处在匝间短路时峰值时刻相比较于正常状态会变长,处在接触不良运行时,电流有变小的趋势,断路器处在不同运行状态各阶段维持时间和电流大小都有较大差别。

表3 分闸电流时间和电流参数  
Table 3 Shunt current time and current parameters

类型	时间/ms					电流/A				
	$T_1$	$T_2$	$T_3$	$T_4$	$T_5$	$I_1$	$I_2$	$I_3$	$I_4$	$I_5$
正常分闸	5.20	9.60	15.20	19.60	24.64	2.06	0.80	1.90	0.70	2.20
匝间短路	7.12	11.84	17.68	21.84	27.12	2.25	0.70	2.02	0.66	2.22
接触不良	6.72	11.36	16.72	21.12	26.96	1.70	0.63	1.50	0.63	1.71
操作电压偏高	4.08	8.08	13.28	17.92	23.36	2.04	0.82	2.03	0.75	2.38
操作电压偏低	7.12	11.6	16.88	21.36	26.64	1.70	0.73	1.48	0.68	1.68

对采集的电流信号进行全局特征值计算,每个电流信号计算6种全局特征值,构成全局特征分量,部分时域特征值如表4所示。由表4可以看出,当处在接触不良时,

电流信号 $\rho_4$ 的值较小,电压偏高时 $\rho_6$ 的值最大,不同运行状态下的时域特征值都有所不同,反应了不同运行状态下分闸电流信号的时域特性。

表4 不同运行状态下分闸电流信号时域特征值  
Table 4 Time-domain eigenvalues of tripping current signals under different operating conditions

类型	$\rho_1$	$\rho_2$	$\rho_3$	$\rho_4$	$\rho_5$	$\rho_6$
正常分闸	0.609 2	4.557 7	1.701 0	0.718 6	1.867 4	3.194 8
匝间短路	0.635 3	4.534 6	1.723 5	0.741 8	1.934 7	3.063 4
接触不良	0.495 7	4.004 7	1.555 0	0.593 3	1.818 0	2.915 7
操作电压偏高	0.627 4	4.614 8	1.719 7	0.740 1	1.880 3	3.228 5
操作电压偏低	0.491 4	3.565 8	1.379 0	0.617 7	1.649 7	2.753 0

根据实验结果计算,对实验数据特征向量矩阵进行PCA降维处理。贡献率柱状图如图8所示,由图8看出,前5个主分量贡献率为68.810 6%、15.861 4%、9.013 2%、3.368 7%、2.063 9%,累计贡献率达到99.117 8%,排后的主分量贡献率近似为0,表明贡献率较少。因此,选择前5个主成分共同构成新的特征向量来代表原始数据。部分降维后的样本特征如表5所示。

利用上述分析计算对原始数据进行降维处理,由原始

数据 $150 \times 16$ 维降维到 $150 \times 5$ 维构建样本特征向量矩阵,选择PSO对SVM分类器模型的惩罚因子 $C$ 和核函数参数 $g$ 进行参数寻优,设定PSO算法初始参数值:粒子种群大小为30,迭代次数为100次, $C$ 的寻优范围 $[0.01, 100]$ , $g$ 的寻优范围 $[0.01, 100]$ ,将样本数据的60%设置为训练数据输入SVM分类器模型训练,样本数据的40%设置为测试数据进行故障分类。将样本数据的训练集用 $K$ 折交叉验证的方式,设置 $K=5$ ,即将数据样

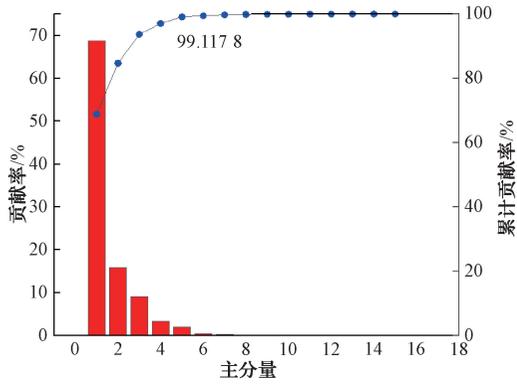


图8 单个主分量贡献率

Fig. 8 Individual principal component contribution

本随机分成5份,其中4份为训练样本,1份为验证样本,以验证样本的识别准确率为适应度函数,通过 PSO 算法对 SVM 参数进行寻优,得到最优参数值  $C = 16.49, g = 0.01$ , PSO 优化 SVM 参数的适应度曲线如图 9 所示,算法进化到第 6 代时验证样本达到了最大识别准确率 100%。

训练集样本的准确率如图 10 所示,故障分类的识别率为 100%,测试样本的分类结果如图 11 所示,分类的识别率达到 98.3%,有一个测试样本识别错误,虽然没有达到准确率 100%,但该准确率仍然可以说明本文提出的方法具有较好的分类效果,能够准确的对断路器进行故障分类。

表 5 经 PCA 降维后的部分特征参数

Table 5 Some feature parameters after PCA dimensionality reduction

序号	运行状态	第 1 主分量	第 2 主分量	第 3 主分量	第 4 主分量	第 5 主分量
1	正常分闸	0.717 6	-0.246 0	0.298 4	0.286 8	-0.151 0
2	匝间短路	0.840 4	0.192 3	-0.064 7	0.210 2	0.213 5
3	接触不良	-0.960 0	-0.608 8	-0.244 0	-0.279 7	0.047 4
4	电压偏高	0.938 5	-1.151 1	0.381 6	0.045 1	-0.006 2
5	电压偏低	-1.286 0	1.202 0	-0.066 9	0.279 1	-0.044 2

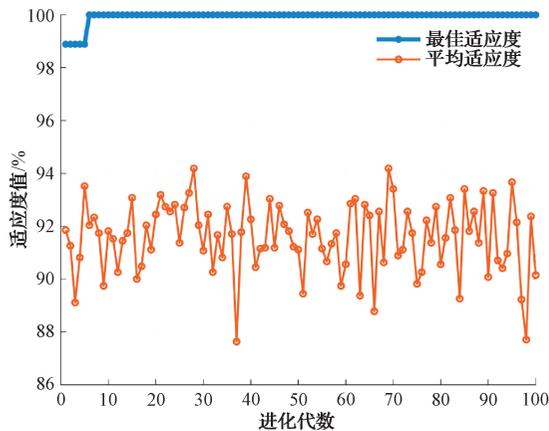


图9 算法适应度曲线

Fig. 9 Algorithm adaptation graph

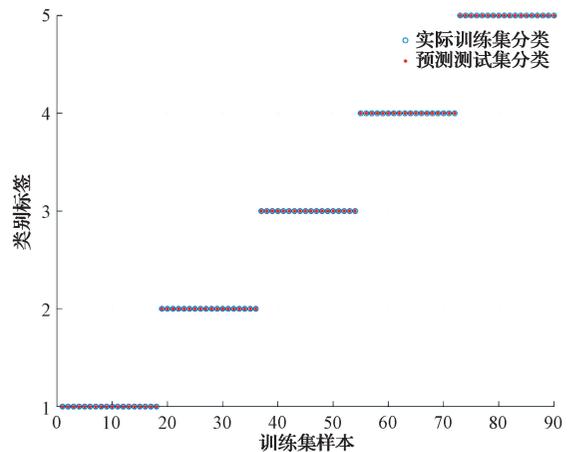


图10 PCA-PSO-SVM 的高压断路器训练集故障分类结果

Fig. 10 PCA-PSO-SVM fault classification results for high voltage circuit breaker training set

### 5.3 不同优化算法对比分析

为了验证 PSO 寻优算法的性能,本文将 PSO 算法与目前的常见麻雀搜索算法 (SSA)、灰狼算法 (GWO) 进行性能比较,同样设置算法的种群数量为 30,迭代寻优次数为 100,并采用 5 折交叉验证法,将验证样本的识别准确率设置为适应度函数。比较各优化算法的适应度函数收敛情况,做各适应度值函数对比,如图 12 所示。

由图 12 可知,PSO 算法在进化代数为 6 次时适应度值达到了 100%,SSA 算法在进化代数为 15 次时,适应度值为 98.89%,GWO 算法最低,经过 19 次迭代,适应度值为 97.78%,相比较其他两种算法搜索能力较弱。综上所述

述,PSO 算法迭代收敛速度最快,适应度值更高,可以较快地找到全局最优解,有着更强的全局搜索能力。由此可得,在对 SVM 模型参数优化性能方面,PSO 算法更具优势。

### 5.4 故障分类结果比较分析

为测试不同方法对断路器故障识别分类效果,将样本数据 60% 作为训练集,40% 作为测试集,依次输入 SVM、PCA-SVM、PCA-SSA-SVM、PCA-GWO-SVM、PCA-PSO-SVM 分类模型中进行故障分类,5 种算法分类准确率结果如表 6 所示。

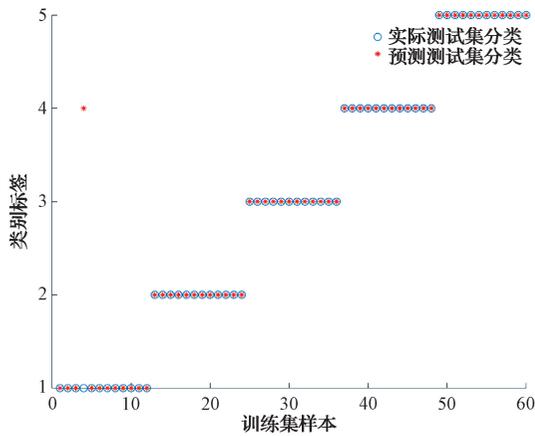


图 11 PCA-PSO-SVM 的高压断路器测试集故障分类结果  
Fig. 11 PCA-PSO-SVM fault classification results for HV circuit breaker test set

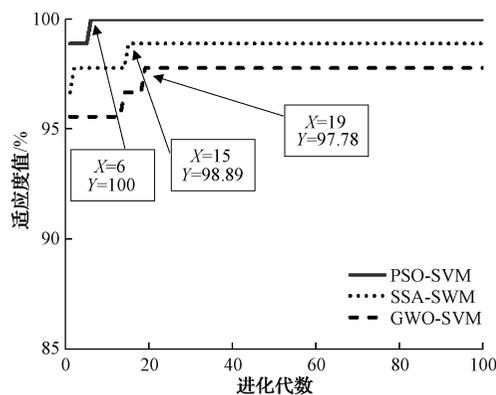


图 12 3 种优化算法适应度曲线  
Fig. 12 Fitness profiles of the 3 optimization algorithms

表 6 不同算法分类准确率对比  
Table 6 Comparison of classification accuracy of different algorithms

故障分类方法	分类准确率/%	C	g	时间/s
SVM	75.0	10.00	10.00	3.13
PCA-SVM	83.3	10.00	10.00	4.28
PCA-SSA-SVM	95.0	1.34	13.32	11.35
PCA-GWO-SVM	93.3	40.85	2.15	13.77
PCA-PSO-SVM	98.3	16.49	0.01	10.36

由不同方法故障分类结果可以观察到,对比初始 SVM 分类模型,数据原始特征集合经过 PCA 降维后的故障分类准确率提高 8.3%,经过 3 种寻优算法优化 C、g 参数的 SVM,SSA 算法寻优 SVM 参数值为(1.34,13.32),GWO 算法寻优 SVM 参数值为(40.85,2.15),PSO 算法寻优 SVM 参数值为(16.49,0.01),优化参数后的模型的

拟合效果更好,故障分类准确率都达到了 90% 以上,都具有良好的识别效果,对比优化 SVM 模型参数的 SSA、GWO、PSO 3 种算法,PCA-PSO-SVM 方法识别准确率最高,达到 98.3%,寻优速度最快,时间为 10.36 s。同时,采用优化算法对 SVM 参数进行寻优故障识别分类平均运行时间相比较于前两种方法略长,因为需要算法迭代寻找最优参数进行故障识别分类,但整体准确率识别精度更高,更加适用于高压断路器的故障分类。

## 6 结论

高压断路器操作过程伴随着控制线圈电流的变化,分闸线圈电流包含断路器丰富的状态信息,本文通过模拟高压断路器正常分闸、匝间短路、接触不良、操作电压偏高、操作电压偏低 5 种故障运行状态,对于断路器不同运行状态下电流特征向量的提取问题,使用局部特征和全局特征相结合的方式,并使用 PCA 算法对局部、全局联合特征进行降维,使用 PSO-SVM 分类器模型进行故障分类,得到如下结论。

1)相较于传统方式提取特征值的单一选择,提出将高压断路器分闸电流信号局部特征和全局特征相结合的方式,使得采集的电流组成联合特征向量集合,充分表征原始电流曲线特性,能够全面反映高压断路器的机械故障信息。

2)为最大程度减少冗余信息,筛选出相关特征,剔除不相关特征,首先对联合特征向量进行数据归一化处理,然后采用 PCA 对数据进行降维处理,形成最优特征向量集合,可以进一步提高识别准确率。

3)为解决 SVM 关键参数选择问题,通过 PSO 对参数进行寻优,从而提升了准确率。试验表明基于本文方法能准确、可靠的对高压断路器故障类型进行分类。

4)接下来的研究工作可以把机器学习和在线监测相结合,对于高压断路器设备的故障处理的效率和准确性会更加优异,同时对于高压断路器的运维管理和安全生产工作有重要的实际意义。

## 参考文献

[1] 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.  
GUAN Y G, YANG Y W, ZHONG J Y, et al. Review on mechanical fault diagnosis methods for high-voltage circuit breakers [J]. Automation of Electric Power System, 2018, 54(7): 10-19.

[2] 娄杲,田行军,闫辉,等. 基于知识与数据联合驱动的断路器状态评估系统研究[J]. 国外电子测量技术, 2023,42(6):63-69.  
LOU G, TIAN X J, YAN H, et al. Research on circuit breaker state evaluation system driven by knowledge and data [J]. Overseas Electronic Measurement

- Technology, 2023, 42(6): 63-69.
- [3] 杨秋玉,王栋,阮江军,等.基于振动信号的断路器机械零部件故障程度识别[J].电工技术学报,2021,36(13):2880-2892.  
YANG Q Y, WANG D, RUAN J J, et al. Fault severity estimation method for mechanical parts in circuit breakers based on vibration analysis [J]. Transactions of China Electrotechnical Society, 2021, 36(13): 2880-2892.
- [4] 游颖敏,王景芹,舒亮,等.断路器保护特性测试电流的自适应控制策略[J].电工技术学报,2020,35(15):3203-3213.  
YOU Y M, WANG J Q, SHU L, et al. Research on adaptive current control method in circuit breaker protection characteristic test [J]. Transactions of China Electrotechnical Society, 2020, 35(15): 3203-3213.
- [5] GAO W, QIAO S P, WAI R J, et al. A newly designed diagnostic method for mechanical faults of high-voltage circuit breakers via SSAE and IELM [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70: 1-13.
- [6] YANG Q, RUAN J, ZHUANG Z, et al. Condition evaluation for opening damper of spring operated high voltage circuit breaker using vibration time-frequency image [J]. IEEE Sensors Journal, 2019, 19(18): 8116-8126.
- [7] ZHANG Y Y, WEI H, LIAO R J, et al. A new support vector machine model based on improved imperialist competitive algorithm for fault diagnosis of oil-immersed transformers [J]. Journal of Electrical Engineering and Technology, 2017, 12(2): 830-839.
- [8] 刘会兰,许文杰,赵书涛,等.面向高压断路器故障分类的电流-振动信号类聚几何敏感特征优选方法[J].电工技术学报,2023,38(1):26-36.  
LIU H L, XU W J, ZHAO SH T, et al. Optimization method of clustering geometric sensitive features of current vibration signals for fault classification of high voltage circuit breakers [J]. Transactions of China Electrotechnical Society, 2023, 38(1): 26-36.
- [9] 邵阳,武建文,马速良,等.用于高压断路器机械故障诊断的AM-Relief特征选择下集成SVM方法[J].中国电机工程学报,2021,41(8):2890-2901.  
SHAO Y, WU J W, MA S L, et al. Integrated SVM method with AM-Relief feature selection for mechanical fault diagnosis of high voltage circuit breakers [J]. Proceedings of the CSEE, 2021, 41(8): 2890-2901.
- [10] 钟声,李晓洋,梁胜乐,等.基于线圈电流信号及动态时间规整的高压断路器状态评估方法[J].高压电器, 2023, 59(4): 24-31.  
ZHONG SH, LI X Y, LIANG SH L, et al. Condition assessment method on high voltage circuit breaker based on coil current signal and dynamic time warping [J]. High Voltage Apparatus, 2023, 59(4): 24-31.
- [11] 刘荣海,豆龙江,万书亭,等.基于EEMD样本熵和支持向量机的高压断路器故障诊断[J].华北电力大学学报,2018,45(2):82-88.  
LIU R H, DOU L J, WAN SH T, et al. Fault diagnosis of high voltage circuit breaker based on EEMD sample entropy and support vector machine [J]. Journal of North Electric Power University, 2018, 45(2): 82-88.
- [12] 刘芹,彭在兴,王颂,等.基于随机森林算法的断路器分合闸线圈故障电流曲线识别[J].高压电器, 2019, 55(7): 93-100.  
LIU Q, PENG Z X, WANG S, et al. Fault current curve identification of circuit breaker opening and closing coil based on stochastic forest algorithm [J]. High Voltage Apparatus, 2019, 55(7): 93-100.
- [13] 王佳灿,何志鹏,冀一玮,等.一种基于电机电流的高压断路器与负荷开关弹簧操作机构故障诊断算法[J].高压电器, 2024, 60(5): 39-45.  
WANG J C, HE ZH P, JI Y W, et al. Fault diagnosis algorithm for spring operating mechanism of high voltage circuit breaker and load switch based on motor current [J]. High Voltage Apparatus, 2024, 60(5): 39-45.
- [14] 王艳新,闫静,王建华,等.基于特征融合度量学习的高压断路器机械故障诊断[J].仪器仪表学报, 2022, 43(9): 98-105.  
WANG Y X, YAN J, WANG J H, et al. Mechanical fault diagnosis for high voltage circuit breaker via a novel feature fusion metric learning [J]. Chinese Journal of Scientific Instrument, 2022, 43(9): 98-105.
- [15] 石颖,杜国庆.改进麻雀搜索算法优化SVM的方法及应用[J].计算机工程与设计, 2023, 44(3): 954-961.  
SHI J, DU G Q. Method and application of SVM optimized by improved sparrow search algorithm [J]. Computer Engineering and Design, 2023, 44(3): 954-961.
- [16] 尹衍楚,邹永久,杜太利,等.基于SSA-SVM算法的船舶LFCS故障诊断[J].计算机仿真, 2024, 41(1): 548-553.  
YIN Y CH, ZOU Y J, DU T L, et al. Fault diagnosis of ship low freshwater cooling system LFCS based on SSA-SVM algorithm [J]. Computer Simulation,

- 2024, 41(1): 548-553.
- [17] 孙林,王东山,秦伦明,等. 基于灰狼算法的局部放电信号快速自动降噪算法[J]. 电子测量技术, 2023, 46(17):131-138.  
SUN L, WANG D SH, QIN L M, et al. Fast automatic noise reduction algorithm for PD signals based on GWO [J]. Electronic Measurement Technology, 2023, 46(17): 131-138.
- [18] 张佳,陈志英,陈丽安,等. 基于粒子群优化极限学习机的断路器故障诊断方法研究[J]. 高压电器, 2020, 56(6):181-188.  
ZHANG J, CHEN ZH Y, CHEN L AN, et al. Research on fault diagnosis of circuit breaker based on particle swarm optimization extreme learning machine [J]. High Voltage Apparatus, 2020, 56(6): 181-188.
- [19] YAN R, LIAO J Q, YANG J, et al. Multi-hour and multi site air quality index forecasting in Beijing using CNN, LSTM, CNN-LSTM, and spatiotemporal clustering [J]. Expert Systems with Applications, 2021, 169: 114513.
- [20] JIA X D, JIN C, BUZZA M, et al. Wind turbine performance degradation assessment based on a novel similarity metric for machine performance curves [J]. Renewable Energy, 2016, 99: 1191-1201.
- [21] 盖曜麟,葛丽娟,郭懿中,等. 基于改进 SVM 算法的高压断路器故障诊断[J]. 高压电器, 2022, 58(12):14-20.  
GE Y L, GE L J, GUO Y ZH, et al. Fault diagnosis of high voltage circuit breaker based on improved SVM algorithm [J]. High Voltage Apparatus, 2022, 58(12): 14-20.
- [22] 刘秀丽,王鸽,吴国新,等. VMD 及 PSO 优化 SVM 的行星齿轮箱故障诊断[J]. 电子测量与仪器学报, 2022,36(1):54-61.  
LIU X L, WANG G, WU G X, et al. Fault diagnosis method of planetary gear box based on variational modal decomposition and particle swarm optimization support vector machine [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(1): 54-61.
- [23] 杨静宜,白向伟. 基于 PSO-BP 神经网络的分拣机器人视觉反馈跟踪[J]. 国外电子测量技术, 2024, 43(1):166-172.  
YANG J Y, BAI X W. Visual feedback tracking of sorting robot based on PSO-BP neural network [J]. Overseas Electronic Measurement Technology, 2024, 43(1): 166-172.
- [24] 宋玲玲,王琳,钟丽,等. 融合多特征信息与 GWO-SVM 的机械关键设备故障诊断[J/OL]. 机械设计与制造,1-8[2024-07-11]. <https://doi.org/10.19356/j.cnki.1001-3997.20240517.024>.  
SONG L L, WANG L, ZHONG L, et al. Fault diagnosis of key equipment machinery based on multi-feature information and GWO-SVM [J/OL]. Mechanical Design and Manufacturing, 1-8 [2024-07-11]. <https://doi.org/10.19356/j.cnki.1001-3997.20240517.024>.

#### 作者简介

杨帅,硕士研究生,主要研究方向为电力设备故障诊断与在线监测。

E-mail:809758585@qq.com

张岩(通信作者),副教授,硕士生导师,主要研究方向为电力设备故障诊断、智能电器监测技术和工程电磁场数值计算。

E-mail:yanyanfly163@163.com

梁永春,教授,硕士生导师,主要研究方向为电力电缆温度场和载流量分析、电力设备在线监测与故障诊断。

E-mail:lycocean@163.com

王昭雷,硕士,高级工程师,主要研究方向为电力系统设备智能检测与智能运维。

E-mail:wzlab@163.com

符鑫哲,硕士研究生,主要研究方向为电力设备故障诊断、智能电器监测。

E-mail:726855495@qq.com

王子昕,本科生,主要研究方向为电力设备故障诊断、智能电器监测。

E-mail:1521344960@qq.com

任泽瑄,本科生,主要研究方向为电力设备故障诊断、智能电器监测。

E-mail:1605064806@qq.com