

DOI: 10.19783/j.cnki.pspc.241245

## 多策略改进 DBO 算法与 KELM 的变压器故障辨识

谭贵生<sup>1</sup>, 赵波<sup>2</sup>, 张桂莲<sup>1</sup>, 刘丹丹<sup>3</sup>, 石宜金<sup>4</sup>

(1. 丽江文化旅游学院, 云南 丽江 674199; 2. 东北电力大学自动化工程学院, 吉林 吉林 132012;  
3. 云南电网有限责任公司丽江供电局, 云南 丽江 674199; 4. 新疆政法学院, 新疆 图木舒克 843900)

**摘要:** 针对油浸式变压器故障诊断中因样本存在冗余特征, 导致故障诊断精度低的问题, 提出一种新的多策略改进蜣螂算法(multi-strategy improved dung beetle optimizer, MSIDBO)优化核极限学习机(kernel extreme learning machine, KELM)的变压器故障判别模型。首先, 利用随机森林(random forest, RF)与核主成分分析法(kernel principal component analysis, KPCA)对变压器原始数据进行特征提取, 合理降低特征量的维度。其次, 引入改进的 Circle 混沌映射、变螺旋搜索机制、非线性控制因子、融合正余弦算法和融合多种群差分进化算法的变异策略对蜣螂算法(dung beetle optimizer, DBO)进行改进, 提高全局搜索能力和收敛精度。最后, 利用 MSIDBO 对 KELM 中的核参数和正则化参数进行优化, 构建 KPCA-MSIDBO-KELM 的变压器故障诊断模型。实验表明, 其诊断准确率为 94.07%。与 DBO-KELM、WOA-KELM、HHO-KELM、GWO-KELM 和 PSO-KELM 故障模型进行对比分析, 准确率分别提高了 2.54%、3.39%、5.93%、7.63%和 13.56%。相比其他模型, 所提方法能够有效提高变压器故障诊断的准确率。

**关键词:** 变压器; 故障诊断; 多策略改进蜣螂算法; 核极限学习机; 核主成分分析

### Transformer fault identification based on multi-strategy improved DBO algorithm and KELM

TAN Guisheng<sup>1</sup>, ZHAO Bo<sup>2</sup>, ZHANG Guilian<sup>1</sup>, LIU Dandan<sup>3</sup>, SHI Yijin<sup>4</sup>

(1. Lijiang Culture and Tourism College, Lijiang 674199, China;

2. School of Automation Engineering, Northeast Electric Power University, Jilin 132012, China;

3. Lijiang Power Supply Bureau, Yunnan Power Grid Co., Ltd., Lijiang 674199, China;

4. Xinjiang University of Political Science and Law, Tumushuke 843900, China)

**Abstract:** Aiming at the low accuracy of fault diagnosis in oil-immersed transformers caused by redundant features in the sample data, this paper proposes a new transformer fault identification model based on a multi-strategy improved dung beetle optimizer (MSIDBO) and kernel extreme learning machine (KELM) is proposed. First, random forest (RF) and kernel principal component analysis (KPCA) are used to extract the features from the raw transformer data, effectively reducing dimensionality. Next, the dung beetle optimizer (DBO) is comprehensively improved through multiple strategies, including improved Circle chaotic mapping, variable spiral search mechanism, nonlinear control factor, fusion with the sine-cosine algorithm, and a hybrid multi-population differential evolution mutation strategy. These enhancements significantly improve the algorithm's global search ability and convergence accuracy. Finally, the MSIDBO algorithm is applied to optimize the kernel and regularization parameters of KELM, constructing the KPCA-MSIDBO-KELM transformer fault diagnosis model. Experiments show that the constructed transformer fault diagnosis model achieves an accuracy of 94.07%, which is 2.54%, 3.39%, 5.93%, 7.63% and 13.56% higher than DBO-KELM, WOA-KELM, HHO-KELM, GWO-KELM, and PSO-KELM. Overall, the proposed method significantly improves the accuracy of transformer fault diagnosis.

This work is supported by the National Natural Science Foundation of China (No. 61901101).

**Key words:** transformer; fault diagnosis; multi-strategy improved dung beetle optimizer; kernel extreme learning machine; kernel principal component analysis

**基金项目:** 国家自然科学基金项目资助(61901101); 丽江市科技局项目资助(2022LJSHFZ013); 丽江文化旅游学院项目资助(2023xshb04); 新疆政法学院项目资助(XZZK2024002)

## 0 引言

随着电网快速发展和对电力设备可靠性的严格要求, 变压器作为电力系统中的重要组成部分, 其可靠性显得尤为重要<sup>[1]</sup>。一旦变压器出现故障处理不及时, 将产生严重的经济损失, 甚至引发重大安全事故, 因此, 准确诊断变压器故障对于电网安全运行具有重要意义<sup>[2-3]</sup>。目前, 电网中运行的变压器主要是油浸式变压器, 当变压器发生故障时, 变压器的绝缘油会分解大量气体, 主要包括  $H_2$ 、 $CH_4$ 、 $C_2H_6$ 、 $C_2H_4$ 、 $C_2H_2$  等, 因此油中溶解气体分析法(dissolve gas analysis, DGA)成为进行变压器故障识别的重要手段<sup>[4-5]</sup>, 采用传统的三比值法、罗杰斯比法等基于 DGA 的故障诊断方法时, 存在操作复杂、编码缺失等问题, 导致故障诊断结果准确性偏低, 实际运用中存在一定的局限性。

随着人工智能技术的发展, 将人工智能技术与 DGA 相结合应用到变压器故障诊断中已成为电力设备状态监测领域的研究热点, 例如, 人工神经网络<sup>[6-7]</sup>、支持向量机<sup>[8]</sup>、极限学习机<sup>[9]</sup>等。文献[10]提出一种在改进的布谷鸟算法中结合局部搜索策略的文化基因算法, 利用反向传播神经网络有效提高了故障分类的效果, 但神经网络需要大量数据集, 模型的复杂度高, 诊断精度有待提高。文献[11]采用改进秃鹰搜索算法优化支持向量机的核函数参数, 相比传统支持向量机算法, 其准确率大幅度提高。然而, 当故障数据集较大时, 该方法会导致学习时间长, 计算开销高, 使得变压器故障诊断的准确率偏低。然而, 当变压器故障数据存在严重不均衡时, 基于小样本数据集的多类型故障诊断方法往往面临样本不足的问题, 极端情况下甚至导致故障诊断失效。文献[12]采用多策略改进蜣螂算法的变压器故障诊断方法, 考虑到蜣螂算法的全局搜索能力较强, 但在工程应用中收敛精度偏低, 易陷入局部最优解。以上方法在变压器故障诊断中有很大的应用价值, 与其他模型相比, 核极限学习机是基于极限学习机并结合核函数所提出的改进算法<sup>[13]</sup>。该方法不仅保留了极限学习机训练速度快、泛化能力强的优点, 还提高了处理非线性问题的能力, 更适合用于故障分类。在变压器故障诊断中, 核极限学习机(kernel extreme learning machine, KELM)的诊断精度主要受限于正则化系数  $C$ 、核参数、混合权重以及故障特征子集的最优解。因此, 构建“特征选择和参数优化”协同优化框架成为突破瓶颈的关键。智能优化算法因其在寻优搜索方面的突出表现, 已成为求解最优问题的有效方法。文献[14]为解决故障数据

不平衡问题, 构建了改进的鲸鱼算法与核极限学习机的模型, 该模型对 KELM 的正则化系数、核参数等关键超参数进行优化, 并经过实验表明, 该模型不仅提高变压器故障诊断准确率, 还在小样本故障类型上表现出良好的泛化性能优势。虽然智能算法能够提高故障诊断精度, 但智能算法的单一性易出现局部最优解和搜索范围受限等问题, 从而影响学习机参数的优化过程, 并最终对变压器故障辨识的准确性产生负面影响。

综上所述, 本文提出了一种基于多策略改进蜣螂算法(dung beetle optimizer, DBO)与 KELM 的变压器故障辨识方法。首先采用随机森林属性约简与核主成分分析方法对构建的 20 个特征量的变压器故障数据进行特征提取, 降低特征量的数量; 其次引入改进的 Circle 混沌映射、变螺旋搜索机制、非线性控制因子、正余弦算法和融合多种群差分进化算法的变异策略对蜣螂算法进行改进, 提高了全局搜索能力和收敛精度。最后利用多策略改进蜣螂算法(multi-strategy improved dung beetle optimizer, MSIDBO)对 KELM 中的核参数和正则化参数进行优化, 构建 RF-KPCA-MSIDBO-KELM 的变压器故障诊断模型, 实验结果表明, 本文所提方法能够实现较高精度的故障诊断, 验证了该方法的有效性。

## 1 数据预处理

### 1.1 变压器故障特征提取

当变压器正常运行时, 油箱的气体浓度相对稳定; 一旦发生故障, 变压器的绝缘油会分解大量气体, 主要包括  $H_2$ 、 $CH_4$ 、 $C_2H_6$ 、 $C_2H_4$ 、 $C_2H_2$  等。传统的故障识别方法主要依赖 5 种气体浓度进行识别, 由于 5 种气体含量分布较为分散, 并且故障发生时气体与气体之间存在联系, 会导致信息不够完善, 影响变压器故障识别的准确率<sup>[15]</sup>。为了提高变压器故障识别的准确率, 本文采用无编码比值方法构建 20 个特征量, 如表 1 所示, 其中 TH 为烃类气体( $CH_4$ 、 $C_2H_6$ 、 $C_2H_4$ 、 $C_2H_2$ )浓度和; TE 为总气体( $H_2$ 、 $CH_4$ 、 $C_2H_6$ 、 $C_2H_4$ 、 $C_2H_2$ )浓度和。

### 1.2 随机森林属性约简

变压器故障特征量为高维度数据, 其存在冗余数据, 会导致模型运行时间长, 故障诊断精度下降<sup>[16]</sup>。本文基于随机森林的数据属性约简方法对变压器故障数据进行属性约简。

随机森林的数据属性约简是利用随机森林算法进行特征选择的重要手段之一, 引入袋外数据误差对各指标进行重要性评价。重要性评价指标计算如式(1)所示。

$$M_j = \frac{1}{E} \sum_{i=1}^n (E_{n,j}^{\text{OOB}} - E_n^{\text{OOB}}) \quad (1)$$

式中:  $M_j$  为第  $j$  个指标的重要性;  $E$  为随机树的个数;  $n$  为特征指标的数量;  $E_{n,j}^{\text{OOB}}$  为加入噪声的袋外误差;  $E_n^{\text{OOB}}$  为原袋外的误差。

表 1 气体故障特征量

Table 1 Fault characteristic of DGA

编号	特征量	编号	特征量
1	H <sub>2</sub>	11	C <sub>2</sub> H <sub>6</sub> /TE
2	CH <sub>4</sub>	12	CH <sub>4</sub> /H <sub>2</sub>
3	C <sub>2</sub> H <sub>6</sub>	13	C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub>
4	C <sub>2</sub> H <sub>4</sub>	14	C <sub>2</sub> H <sub>4</sub> /C <sub>2</sub> H <sub>6</sub>
5	C <sub>2</sub> H <sub>2</sub>	15	CH <sub>4</sub> /TH
6	TH	16	C <sub>2</sub> H <sub>2</sub> /TH
7	H <sub>2</sub> /TE	17	C <sub>2</sub> H <sub>4</sub> /TH
8	CH <sub>4</sub> /TE	18	C <sub>2</sub> H <sub>6</sub> /TH
9	C <sub>2</sub> H <sub>2</sub> /TE	19	(CH <sub>4</sub> + C <sub>2</sub> H <sub>4</sub> )/TH
10	C <sub>2</sub> H <sub>4</sub> /TE	20	TH/TE

另外, 设置重要性评价指标的约简阈值  $\lambda$ , 剔除不重要的指标, 选取大于阈值的指标, 通过计算袋外误差, 选取平均属性重要性最高的集合作为约简后的数据集。

### 1.3 KPCA 数据处理

对随机森林属性约简的数据, 利用核主成分分析对变压器的故障特征量进行降维约简, 提高了模型的泛化能力和故障诊断的准确率。KPCA 算法引入非线性核函数  $\Phi$  对变压器原始数据  $x = \{x_i | i=1, 2, \dots, n; x_i \in \mathbf{R}\}$  进行非线性变换, 将  $x$  映射到高维特征空间  $F$  进行线性分析,  $F$  的协方差矩阵为

$$C = \frac{1}{n} \sum_{i=1}^n \Phi(x_i) \Phi(x_i)^T \quad (2)$$

变压器故障特征信息体现为特征方程的特征向量和特征值。

$$\lambda V = CV \quad (3)$$

式中:  $\lambda$  为特征值;  $V$  为特征向量。

为了避免高维运算, 引入核矩阵  $K_{ij}$ 。

$$K_{ij} = \Phi(x_i) \Phi(x_j) \quad (4)$$

高斯核函数  $K(x_i, x_j)$  为

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma^2}\right) \quad (5)$$

式中:  $\sigma$  为核函数参数。

对核矩阵  $K_{ij}$  进行简化, 得到  $K^*$  为

$$K^* = K - IK - KI + IKI \quad (6)$$

式中:  $I$  为单位矩阵。

将式(3)—式(6)进一步简化, 得到

$$\lambda \alpha = \frac{1}{n} K^* \alpha \quad (7)$$

式中:  $\alpha$  为列向量。

为了确定变压器各故障特征的影响因子, 由式(8)计算出贡献率大于 90% 的  $m$  个故障特征量。

$$c = \frac{\sum_{j=1}^m \lambda_j}{\sum_{i=1}^n \lambda_i} \geq 90\% \quad (8)$$

式中:  $\lambda_i$ 、 $\lambda_j$  为对应的特征值。

由式(9)计算出线性样本  $F_i$  为

$$F_i = \left[ \sum_{i=1}^n \alpha_i \Phi(x_i) \right]^T = \alpha^T [\Phi(x_i, x)]^T \quad (9)$$

## 2 改进 DBO 算法

### 2.1 DBO 算法简介

蜚螂算法是在 2022 年提出的一种新型智能优化算法, 该算法主由滚球、繁殖、觅食和偷窃 4 个部分组成<sup>[17]</sup>, 各部分内容如下。

#### 1) 滚球

在无障碍条件下, 蜚螂滚球前行时, 依靠太阳来导航, 使得粪球进行直线滚动, 按这种方式, 蜚螂个体的滚球位置更新方式可由式(10)所示的数学模型进行描述。

$$\begin{cases} x_i^{t+1} = x_i^t + akx_i^{t-1} + b\Delta x \\ \Delta x = |x_i^t - x^w| \end{cases} \quad (10)$$

式中:  $t$  为迭代次数;  $x_i^t$  为第  $i$  个蜚螂在第  $t$  次更新的位置;  $k$  为偏转系数,  $k \in (0, 0.2]$ ;  $b$  为定值,  $b \in [0, 1]$ ;  $a$  为偏离系数, 当  $a=1$  时为无偏离, 当  $a=-1$  时为偏离方向;  $x^w$  为全局最差值;  $\Delta x$  为关照强度的变化值, 其值越小光源越强。

当蜚螂遇到障碍物时, 需要通过跳舞的形式重新获取新的路线, 则蜚螂的位置更新方式如式(11)所示。

$$x_i^{t+1} = x_i^t + \tan \theta |x_i^t - x_i^{t-1}| \quad (11)$$

式中:  $\theta$  为干扰角,  $\theta \in [0, \pi]$ , 当  $\theta=0$  rad、 $\pi/2$  或者  $\pi$  时, 蜚螂位置不需要更新。

#### 2) 繁殖

在自然界中, 蜚螂为了繁殖后代, 需要提供安全的产卵环境。因此, 雌性蜚螂的产卵边界选择策略可采用式(12)所示的数学模型进行定量描述。

$$\begin{cases} L^* = \max(X^*(1-R), L) \\ U^* = \min(X^*(1+R), U) \end{cases} \quad (12)$$

式中： $L^*$ 和 $U^*$ 分别为产卵区域的下界和上界； $L$ 和 $U$ 分别为优化问题的下界和上界； $X^*$ 为局部最优位置； $R=1-t/T$ ， $T$ 为最大迭代次数。

由于蜣螂产卵区域边界值是动态变化的，因此，产卵球的位置也是动态变化的，如式(13)所示。

$$B_i^{t+1} = X^* + b_1(B_i^t - L^*) + b_2(B_i^t - U^*) \quad (13)$$

式中： $B_i^t$ 为第 $i$ 个卵球在第 $t$ 次迭代的位置； $b_1$ 和 $b_2$ 为大小为 $1 \times D$ 两个独立的随机向量， $D$ 为优化的维度。

### 3) 觅食

一些长大或者成熟的小蜣螂出来觅食时，需要建立小蜣螂觅食区域，该觅食区域是动态调整的，如式(14)所示。

$$\begin{cases} L^b = \max(X^b(1-R), L) \\ U^b = \min(X^b(1+R), U) \end{cases} \quad (14)$$

式中： $L^b$ 和 $U^b$ 分别为小蜣螂觅食区域的下界和上界； $X^b$ 为局部最优位置。小蜣螂的位置更新公式为

$$x_i^{t+1} = x_i^t + C_1(x_i^t - L^b) + C_2(x_i^t - U^b) \quad (15)$$

式中： $C_1$ 为服从正态分布的随机数，即 $C_1 \sim N(0,1)$ ； $C_2$ 为 $(0,1)$ 的随机向量。

### 4) 偷窃

部分蜣螂会去其他的蜣螂那里偷窃食物，偷窃蜣螂个体的位置更新行为可由式(16)所示的数学模型表征。

$$x_i^{t+1} = X^b + S \times \mathbf{g} \times (|x_i^t - X^*| + |x_i^t - X^b|) \quad (16)$$

式中： $S$ 为恒定常数； $\mathbf{g}$ 为一个大小为 $1 \times D$ 维的随机向量，其服从于正态分布。

## 2.2 改进蜣螂算法

针对 DBO 算法存在的收敛精度低，易陷入局部最优解的问题，本文通过 5 个策略进行优化改进，首先在初始阶段采用改进的 Circle 混沌映射；其次采用变螺旋搜索行为、非线性控制因子、正余弦算法和融合多种差分进化方式的多种群变异策略，避免陷入局部最优解。

### 2.2.1 改进的 Circle 混沌映射初始化种群

在蜣螂算法中，初始种群为随机的，导致种群不均匀，严重影响寻找最优解，而混沌映射能够有效改善上述问题，保证种群均匀分布。目前常见的混沌映射有 Logistic 映射<sup>[18]</sup>、Tent 映射<sup>[19]</sup>和 Circle<sup>[20]</sup>混沌映射等，而 Circle 映射较为稳定且其混沌值覆盖率高<sup>[21]</sup>。但考虑到 Circle 映射在 $[0.2, 0.6]$ 之间取值较

为密集，其分布并不均匀，因此对 Circle 混沌映射公式进行改进，使其更加均匀。

原 Circle 混沌映射表达式为

$$x_i^{t+1} = \text{mod}(x_i^t + 0.2 - \frac{0.5}{2\pi} \sin(2\pi x_i^t), 1) \quad (17)$$

改进 Circle 混沌映射表达式为

$$x_i^{t+1} = \text{mod}(3.85x_i^t + 0.4 - \frac{0.7}{3.85\pi} \sin(3.85\pi x_i^t), 1) \quad (18)$$

### 2.2.2 变螺旋搜索机制

在 DBO 算法中，蜣螂在进行滚球过程中，没有明确的目标，且个体之间信息交流少，存在随机性，使得算法后期的收敛性不佳，容易陷入局部最优解。因此，引用变螺旋搜索机制进行位置更新，该算法通过自适应搜索机制实现全局空间遍历，有效协调全局探索与局部开发能力，从而显著提升算法的全局寻优性能<sup>[22]</sup>。

在改进的蜣螂优化算法中，引入变螺旋搜索机制后，蜣螂滚球行为的动力学模型可表示为

$$\begin{cases} x_i^{t+1} = x_i^t + a \cdot k \cdot x_{i-1}^{t-1} + b |x_i^t - x^w| & \delta < 0.5 \\ x_i^{t+1} = X_b + E \cdot e^{\beta l} \cos(2\pi l) & \delta \geq 0.5 \\ \beta = e^{5 \cos(\pi(1-t/T))} \end{cases} \quad (19)$$

式中： $X_b$ 为最优个体； $E$ 为最优个体与当前个体之间的距离； $\beta$ 表示螺旋形状，为常数； $l$ 为随机数， $l \in [-1, 1]$ 。

### 2.2.3 非线性控制因子

在 DBO 算法中，需要协调全局搜索能力与局部搜索能力之间的平衡关系，本文基于改进 sigmoid 函数的非线性控制因子  $R$ ，来提高算法的收敛精度和收敛速度。

在育雏球和小蜣螂阶段，通过采用改进 sigmoid 函数的非线性控制因子策略，来更新产卵区和觅食区位置参数。基于改进 sigmoid 的控制因子表示为

$$R = R_1 \cdot \frac{1}{1 + e^{\frac{10r-5T}{T}}} \quad (20)$$

式中： $R_1$ 为控制因子的初始值。

### 2.2.4 融合正余弦算法

在 DBO 算法中，蜣螂个体主要围绕当前最优食物源位置开展定向搜索活动，但运动搜索方式单一，不能对相邻区域进行全面的搜索，容易导致种群多样性降低，很难跳出局部最优解。鉴于上述分析，本文引入正余弦算法(sine-cosine algorithm, SCA)的振荡搜索机制，根据正余弦的迭代特性，实现对全局最优解的渐进式逼近<sup>[23]</sup>。

SCA 算法个体位置更新如式(21)所示。

$$x_i^{t+1} = \begin{cases} x_i^t + r_1 \cdot \cos(r_2) \cdot |r_3 X^b - x_i^t| & r_4 \geq 0.5 \\ x_i^t + r_1 \cdot \sin(r_2) \cdot |r_3 X^b - x_i^t| & r_4 < 0.5 \\ r_1 = v - t \frac{v}{T} \end{cases} \quad (21)$$

式中:  $r_1$  为随机数;  $v$  为常数;  $r_2$  为一个随机变量,  $r_2 \in [0, 2\pi]$ ;  $r_3$  为一个随机权重,  $r_3 \in [0, 2]$ ;  $r_4$  为随机参数,  $r_4 \in [0, 1]$ 。

正弦算法的振荡特性如图 1 所示, 当  $1 < r_1 |\sin(r_2)| \leq 2$  或  $1 < r_1 |\cos(r_2)| \leq 2$  时, SCA 算法在黄色的搜索空间; 当  $r_1 |\sin(r_2)| \leq 1$  或  $r_1 |\cos(r_2)| \leq 1$  时, SCA 算法在红色的搜索空间, 该算法通过调整  $r_1$  和  $r_2$  参数, 从而平衡 SCA 的勘探与开发。因此, 对式(19)引入 SCA 算法, 则小蛭螂位置更新如式(21)所示。

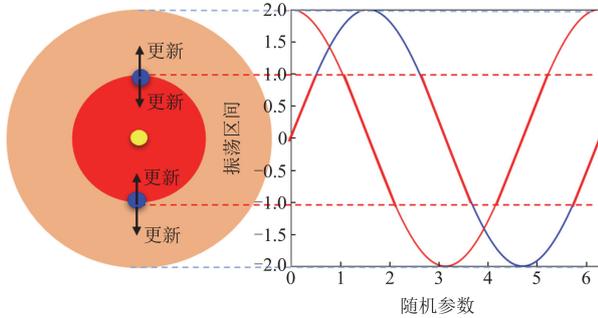


图 1 SCA 算法示意图

Fig. 1 SCA algorithm diagram

### 2.2.5 融合多种群差分进化算法的变异策略

在 DBO 算法中, 根据蛭螂滚球、繁殖、觅食和偷窃行为的更新策略虽然能有效提高搜索效率, 但其固有的局部开发导向性难以帮助算法摆脱局部最优解。因此, 本文采用基于多种差分进化机制的并行多种群变异策略对 DBO 算法进行变异操作, 使得算法摆脱局部最优解。根据适应度将种群分为 3 类, 包括优势种群、劣等种群和中等种群, 每个种群按不同差分进化算法进行变异操作<sup>[24]</sup>, 具体变异操作如下。

#### 1) 引入 DE/current-to-best/1 变异策略

选择种群适应度前 1/3 的个体作为优势群体, 该群体具有较好的适用度, 更能靠近全局最优解。优势群体主要进行开发搜索, 在局部范围有小的扰动探索。引入 DE/current-to-best/1 变异策略进行开发搜索, 该策略能够有效满足优势群体的需求, DE/current-to-best/1 变异策略的表达式为

$$D_i^t = D_i^t + F_n^t \cdot (D_b - D_i^t) + F_n^t \cdot (x_{\omega_1}^t - x_{\omega_2}^t) \quad (22)$$

式中:  $D_i^t$  为变异个体;  $D_i^t$  为变异前的个体;  $F_n^t$  为缩放因子;  $D_b$  为当前群体的最优个体;  $x_{\omega_1}^t$  和  $x_{\omega_2}^t$  为

变异前个体的随机位置。

变异后, 根据贪婪策略进行更新, 表达式为

$$D_i^{t+1} = \begin{cases} D_i^t, & \text{if } f(D_i^t) < f(D_i^t) \\ D_i^t, & \text{else} \end{cases} \quad (23)$$

#### 2) 引入 DE/mean-current/2 变异策略

选择种群适应度前 1/3~2/3 的个体作为中等群体, 该群体既能对优势群体进行局部学习, 又能朝着远处探索全局空间, 因此可以增强种群的多样性。而 DE/mean-current/2 保留了勘探与开发能力, 因此引入 DE/mean-current/2 变异策略, 其表达式为

$$\begin{cases} D_{c1} = \frac{D_{\omega_1}^t + D_{\omega_2}^t}{2} \\ D_{c2} = \frac{D_{\omega_1}^t + D_b}{2} \\ D_i^t = D_i^t + F_n^t \cdot (D_b - D_i^t) + F_n^t \cdot (D_{\omega_1}^t - D_{\omega_2}^t) \end{cases} \quad (24)$$

式中:  $D_{\omega_1}^t$  和  $D_{\omega_2}^t$  为变异前随机个体。

变异后, 根据差分进化中的交叉策略进行更新, 表达式为

$$D_i^{t+1} = \begin{cases} D_i^t, & \text{if } \text{rand}(0,1)_t \leq \psi \text{ or } t = t_{\text{rand}} \\ D_i^t, & \text{else} \end{cases} \quad (25)$$

式中:  $\psi$  为交叉概率,  $\psi \in [0, 1]$ ;  $\text{rand}(0,1)_t$  为  $(0, 1)$  内的随机数;  $t_{\text{rand}}$  为  $[1, N_p]$  之间的随机整数。

#### 3) 引入 DE/rand/1 变异策略

选择种群适应度后 1/3 的个体作为劣等群体, 该群体的适应度较差, 不能依赖其他个体的位置。为了使其具有良好的全局搜索性能, 引入 DE/rand/1 变异策略来提高种群的多样性, 进而摆脱算法局部最优解, DE/rand/1 变异策略的表达式为

$$D_i^t = D_{\omega_1}^t + F_n^t \cdot (D_{\omega_2}^t - D_{\omega_3}^t) \quad (26)$$

式中:  $D_{\omega_1}^t$ 、 $D_{\omega_2}^t$  和  $D_{\omega_3}^t$  为变异前随机个体。

变异后, 根据贪婪策略进行更新, 表达式如式(23)。

## 2.3 算法测试

为了验证 MSIBOA 算法的有效性和优越性, 分别采用 DBO 优化算法、灰狼优化算法(grey wolf optimizer, GWO)<sup>[25]</sup>、鲸鱼优化算(whale optimization algorithm, WOA)<sup>[26]</sup>、粒子群优化算法(particle swarm optimization, PSO)算法<sup>[27]</sup>和 Harris 鹰优化算法(harris hawks optimizer, HHO)<sup>[28]</sup>对典型的测试函数进行仿真实验。选取  $f_1$  和  $f_2$  两组单峰函数、 $f_3$  和  $f_4$  两组多峰函数进行对比分析, 测试函数如表 2 所示。

为了评估 MSIDBO 函数的有效性和准确性, 通过 Matlab 软件采用 4 种智能算法分别对 4 个基准测试函数进行仿真实验, 测试函数参数设置: 种群数设置为 500, 最大迭代次数为 1000, 维度为 30,

每个模型执行 30 次。各算法的对比数据如表 3 所示，不同算法对测试函数的寻优曲线如图 2 所示。

表 2 测试函数

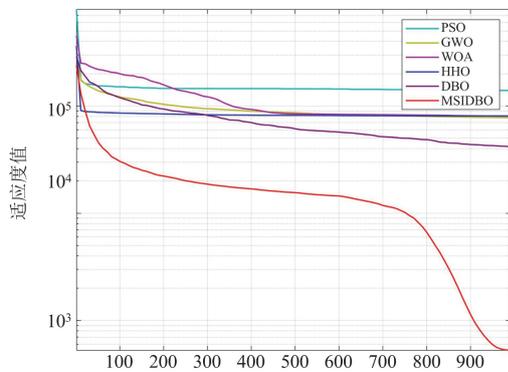
Table 2 Test functions

测试函数	维度	取值范围	最优值
$f_1(x) = \sum_{i=1}^n \sum_{j=1}^i x_j^2$	30	[-100,100]	0
$f_2(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	30	[-5.12,5.12]	0
$f_3(x) = \frac{1}{4000} \left[ \sum_{i=1}^D (x_i - 100)^2 \right] - \left[ \prod_{i=1}^D \cos\left(\frac{x_i - 100}{\sqrt{i}}\right) \right] + 1$	30	[-600,600]	0
$f_4(x) = \frac{\pi}{n} \left\{ 10 \sin^2(\pi y_i) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_n - 1)^2 \right\} + \sum_{i=1}^n u(x_i, 10, 100, 4),$ $y_i = 1 + \frac{1}{4}(x_i + 1)$ $u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m, & x_i > a \\ 0, & -a \leq x_i \leq a \\ k(-x_i - a)^m, & x_i < -a \end{cases}$	30	[-50,50]	0

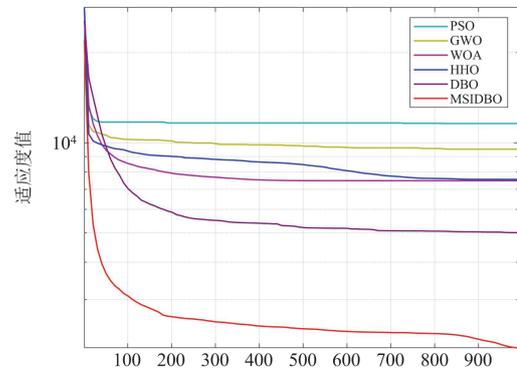
表 3 不同优化算法寻优结果对比

Table 3 Comparison of optimization results of different optimization algorithms

函数	指标	PSO	GWO	WOA	HHO	DBO	MSIDBO
$f_1$	最优值	$1.98 \times 10^5$	$1.37 \times 10^5$	$3.00 \times 10^5$	$9.27 \times 10^4$	$1.38 \times 10^5$	$7.36 \times 10^3$
	平均值	$1.77 \times 10^5$	$1.17 \times 10^5$	$2.03 \times 10^5$	$8.95 \times 10^4$	$1.10 \times 10^5$	$3.67 \times 10^3$
	标准差	$1.62 \times 10^4$	$1.51 \times 10^4$	$8.65 \times 10^4$	$2.19 \times 10^3$	$1.97 \times 10^4$	$2.50 \times 10^3$
$f_2$	最优值	$1.79 \times 10^4$	$1.34 \times 10^4$	$1.12 \times 10^4$	$8.59 \times 10^3$	$8.88 \times 10^3$	$3.87 \times 10^3$
	平均值	$1.42 \times 10^4$	$1.20 \times 10^4$	$7.90 \times 10^3$	$7.79 \times 10^3$	$5.82 \times 10^3$	$2.37 \times 10^3$
	标准差	$2.88 \times 10^3$	$1.56 \times 10^3$	$2.42 \times 10^3$	$6.24 \times 10^2$	$2.28 \times 10^3$	$1.05 \times 10^3$
$f_3$	最优值	$6.69 \times 10^3$	$7.07 \times 10^3$	$2.27 \times 10^3$	$9.88 \times 10^3$	$4.54 \times 10^3$	$1.38 \times 10^3$
	平均值	$5.38 \times 10^3$	$4.74 \times 10^3$	$1.91 \times 10^3$	$6.35 \times 10^3$	$2.32 \times 10^3$	$1.28 \times 10^3$
	标准差	$1.11 \times 10^3$	$1.70 \times 10^3$	$3.89 \times 10^2$	$2.50 \times 10^3$	$1.50 \times 10^3$	$7.24 \times 10^1$
$f_4$	最优值	$3.06 \times 10^9$	$2.60 \times 10^8$	$6.68 \times 10^7$	$5.45 \times 10^9$	$4.74 \times 10^8$	$1.05 \times 10^7$
	平均值	$2.24 \times 10^9$	$2.41 \times 10^8$	$4.80 \times 10^7$	$4.10 \times 10^9$	$1.52 \times 10^8$	$5.07 \times 10^6$
	标准差	$6.59 \times 10^8$	$3.19 \times 10^7$	$2.43 \times 10^7$	$1.58 \times 10^9$	$2.22 \times 10^8$	$4.13 \times 10^6$



(a)  $f_1$  测试函数



(b)  $f_2$  测试函数

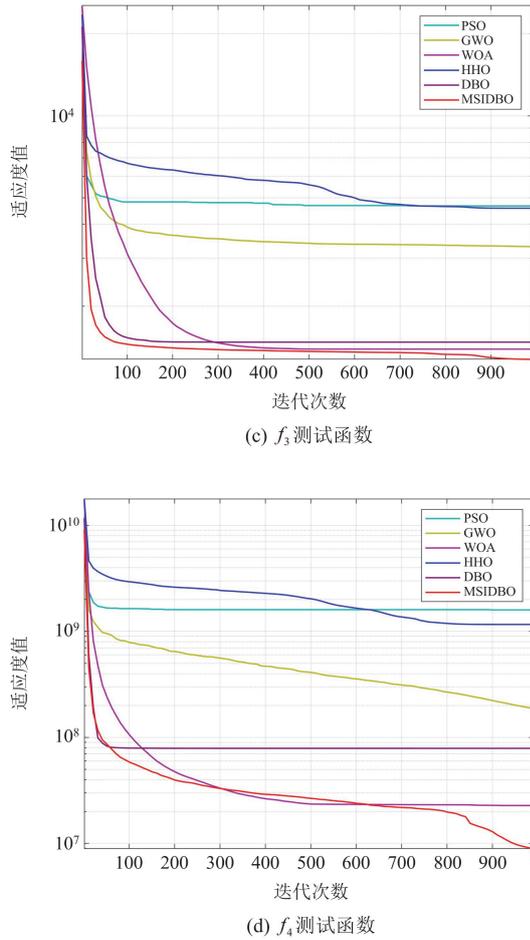


图 2 不同测试函数寻优迭代过程

Fig. 2 Iterative process for optimization of different test functions

从图 2 可知, 对单峰测试函数  $f_1$ 、 $f_2$  进行寻优过程中, PSO、GWO、WOA 和 HHO 算法表现出各自的优劣, 但 MSIDBO 算法的收敛速度最快。从表 3 可知, MSIDBO 算法在最优值、平均值及标准差指标上均显著优于对比算法; 对于多峰测试函数  $f_3$ 、 $f_4$ , MSIDBO 算法的最优值、平均值以及标准差与其他算法对比, 提升效果不明显, 但也稍有提升。综上所述, 改进多策略蜣螂算法的全局搜索能力得到了提升。

### 3 MSIDBO-KELM 变压器故障诊断模型

#### 3.1 核极限学习机

为了提高变压器故障诊断的准确率, 本文通过引入核函数思想与正则化理论对极限学习机隐含层进行优化, 构建的核极限学习机方法在降低模型复杂度的同时显著提升了泛化性能<sup>[29]</sup>。对于  $n$  组变压器故障样本  $x_i$ ,  $i=1,2,\dots,n$ , 其数学表达式为

$$\begin{cases} f(\mathbf{x}) = h(\mathbf{x})\boldsymbol{\beta} = \mathbf{H}\boldsymbol{\beta} \\ \boldsymbol{\beta} = \mathbf{H}^T \left( \frac{\mathbf{Q}}{Z} + \mathbf{H}\mathbf{H}^T \right)^{-1} \mathbf{T} \end{cases} \quad (27)$$

式中:  $f(\mathbf{x})$  为期望输出;  $\boldsymbol{\beta}$  为隐含层与输出层之间的权重;  $\mathbf{H}$  为隐含层节点输出;  $h(\mathbf{x})$  为故障样本矩阵;  $\mathbf{Q}$  为对角矩阵;  $Z$  为正则化系数;  $\mathbf{T}$  为期望的输出向量。

通过引入高斯核函数来提高模型的稳定性, 用核函数矩阵  $\boldsymbol{\Omega}$  代替  $\mathbf{H}\mathbf{H}^T$ , 表示为

$$\begin{cases} \boldsymbol{\Omega} = \mathbf{H}\mathbf{H}^T \\ \boldsymbol{\Omega}_{ij} = h(\mathbf{x}_i)h(\mathbf{x}_j) = G(\mathbf{x}_i, \mathbf{x}_j) \end{cases} \quad (28)$$

$G(\mathbf{x}_i, \mathbf{x}_j)$  为高斯核函数, 表示为

$$G(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|}{\gamma^2}\right) \quad (29)$$

式中:  $\gamma$  为变压器故障诊断的核函数参数。

KELM 算法的输出  $y(\mathbf{x})$  表示为

$$y(\mathbf{x}) = h(\mathbf{x})\mathbf{H}^T \left( \frac{\mathbf{Q}}{Z} + \mathbf{H}\mathbf{H}^T \right)^{-1} = \begin{bmatrix} G(\mathbf{x}, \mathbf{x}_1) \\ \vdots \\ G(\mathbf{x}, \mathbf{x}_n) \end{bmatrix} \left( \boldsymbol{\Omega} + \frac{\mathbf{Q}}{Z} \right)^{-1} \mathbf{T} \quad (30)$$

#### 3.2 MSIDBO-KELM 的诊断模型

MSIDBO-KELM 的变压器故障诊断流程图如图 3 所示, 包括 DBO 的滚球、繁殖、觅食和偷窃的多策略改进, 融合多种群差分进化的变异策略, MSIDBO 优化 KELM 超参数, 分类故障诊断 4 个阶段, 具体步骤如下。

**Step1:** 首先利用随机森林对变压器原始数据进行属性约简, 再采用核主成分分析算法, 按特征贡献率累计大于 90% 的标准选取特征指标, 最终将处理后的数据按照 4:1 的比例划分数据集和训练集。

**Step2:** 设置种群规模、维度、迭代最大次数, 以及 KELM 超参数的取值范围, 初始化种群。

**Step3:** 计算当前 KELM 超参数下蜣螂的最优和最劣适应度值, 记录其位置。

**Step4:** 采用式(18)改进的 Circle 混沌映射对种群进行初始化, 基于式(19)的变螺旋搜索机制对蜣螂滚球位置进行动态更新; 依据式(20)采用改进 sigmoid 函数的非线性控制因子策略更新位置, 利用函数的非线性特性提升局部搜索精度; 针对蜣螂偷窃阶段, 按照式(21)融合正余弦算法(SCA)的振荡搜索机制更新个体位置; 最后, 根据式(22)一式(27), 采用融合多种群差分进化算法的变异策略划分种群数, 通过多种群协同进化机制提升种群多样

性与搜索效率。

Step5: 判断是否满足最大迭代次数, 若满足, 则结束寻优, 将最优超参数值赋予KELM, 否则返回 Step4。

Step6: 基于 MSIDBO 得到的最优参数, 构建 MISDBO-KELM 的变压器故障诊断模型进行故障辨识。

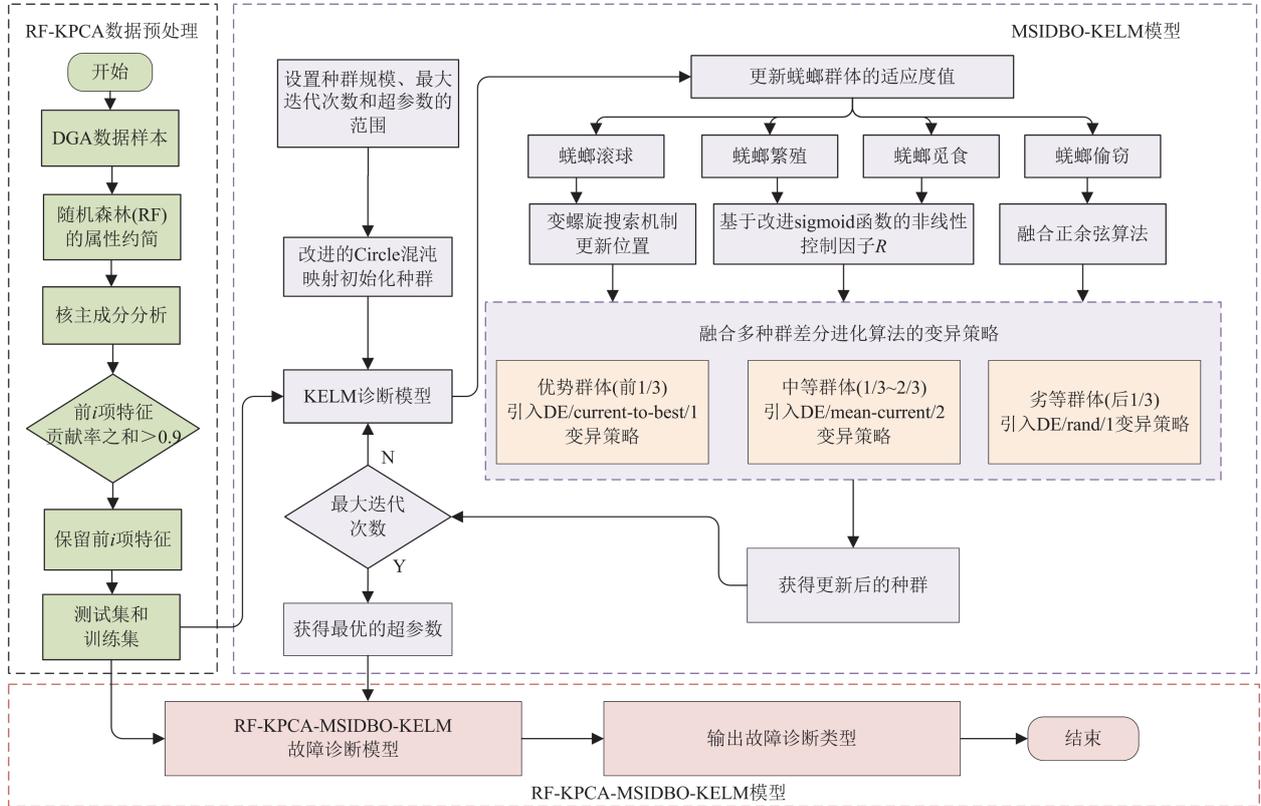


图3 MIDBO-KELM 故障诊断流程图

Fig. 3 Flow chart of MIDBO-KELM fault diagnosis

## 4 实例分析

### 4.1 实验数据处理

根据文献[30-31]的实验数据和某供电局的历史数据和监测数据, 选取 600 组数据按照 4:1 的比例划分为训练集和测试集, 如表 4 所示, 故障类型分别为中低温过热、高温过热、局部放电、低能放电、高能放电和正常 6 种类型, 编号为 1—6, 表 5 为变压器部分故障数据。

表 4 数据集样本分布

Table 4 Sample distribution of the dataset

编号	故障类型	训练集	测试集
1	中低温过热	72	18
2	高温过热	80	20
3	局部放电	64	16
4	低能放电	80	20
5	高能放电	96	24
6	正常	80	20

表 5 变压器部分故障数据

Table 5 Partial fault data of transformer

DGA 气体成分及含量/( $\mu\text{L/L}$ )					故障类型
$\text{H}_2$	$\text{CH}_4$	$\text{C}_2\text{H}_6$	$\text{C}_2\text{H}_4$	$\text{C}_2\text{H}_2$	
120	120	33	84	0.55	中低温过热
130	270	67	500	130	高温过热
77.9	6.3	5.5	13.1	0	局部放电
28.8	4.3	0.6	3.45	29.3	低能放电
136	140	59	582	140	高能放电
42	33.6	14.8	9	0.6	正常

当变压器数据集特征量扩增至 20 个特征量时, 会导致数据集的信息冗余大, 同时会增加算法的复杂度。为了解决上述问题, 采用随机森林算法优选重要性分数较高的特征量, 构成故障辨识的关键特征集。对变压器的 20 个特征量进行重要排序, 确定变压器故障诊断中贡献最大的特征, 特征属性约简如表 6 所示。设置特征量的重要性约简阈值为

0.5, 将变压器数据集从 20 个特征量降到 12 个特征量, 减少了特征指标之间信息冗余。

表 6 特征属性约简

Table 6 Feature attribute reduction

特征量	属性重要性	特征量	属性重要性
C <sub>2</sub> H <sub>2</sub> /TH	0.082 311	C <sub>2</sub> H <sub>4</sub> /TH	0.060 074
C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub>	0.072 318	CH <sub>4</sub> /H <sub>2</sub>	0.058 241
C <sub>2</sub> H <sub>2</sub> /TE	0.068 444	C <sub>2</sub> H <sub>4</sub>	0.056 309
C <sub>2</sub> H <sub>4</sub> /C <sub>2</sub> H <sub>6</sub>	0.065 267	TH	0.056 309
H <sub>2</sub> /TE	0.063 342	H <sub>2</sub>	0.053 600
TH/TE	0.060 483	(CH <sub>4</sub> + C <sub>2</sub> H <sub>4</sub> )/TH	0.052 806

为了进一步消除数据集中的冗余信息, 通过随机森林属性约简和 KPCA 方法对 12 个评价指标进行适当剔除, 提取关键特征信息, 并将其作为变压器故障辨识模型的输入数据集。

将经过随机森林属性约简的故障数据通过 KPCA 进行降维处理, 降维后的主要成分占比如图 4 所示。其中 6 个主要成分的数据累计贡献率为 91.82%, 满足式(8)中累计贡献率大于 90%的条件, 选取 6 个主要成分作为故障的输入量。

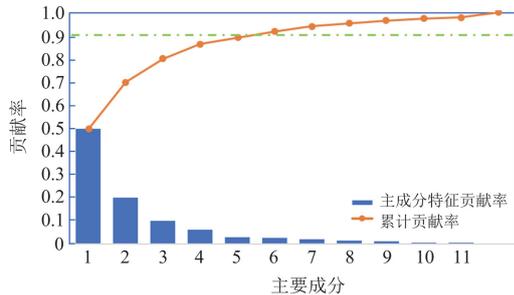


图 4 KPCA 特征贡献率

Fig. 4 Feature contribution rate of KPCA

#### 4.2 MSIDBO-KELM 故障诊断模型评价

将随机森林属性约简与核主成分分析(KPCA)相结合, 对原始数据进行特征降维处理后作为输入, 利用 MSIDBO-KELM 的变压器故障进行训练。实验结果表明, 该模型的准确率能够达到 94.07%, 各类型故障的分类结果如图 5 所示。其中, 混淆矩阵的单列元素和为各类型样本数, 单行元素和为预测故障的样本数, 而对角线元素反映了各故障类型的预测数。表 7 为各类故障的精确率、召回率、F1-score 和准确率。由表 7 可知, 该模型的精确率和召回率值良好, 能够减少样本误分类情况; F1-score 作为衡量变压器故障识别性能的指标, F1-score 均大于 90%, 这充分验证了 MSIDBO-KELM 模型在变压器故障诊断中的有效性和准确

性, 能够实现故障类型的精准识别。

输出标签	1	2	3	4	5	6	
1	18 15.25%	0 0.00%	0 0.00%	0 0.00%	0 0.00%	0 0.00%	100% 0.00%
2	1 5.00%	18 15.25%	0 0.00%	0 0.00%	0 0.00%	1 5.00%	90.00% 10.00%
3	0 0.00%	1 6.25%	15 12.71%	0 0.00%	0 0.00%	0 0.00%	93.80% 6.20%
4	0 0.00%	0 0.00%	1 5.00%	19 16.10%	0 0.00%	0 0.00%	95.00% 5.00%
5	0 0.00%	0 0.00%	0 0.00%	1 4.17%	23 19.49%	0 0.00%	95.80% 4.20%
6	0 0.00%	0 0.00%	0 0.00%	2 10.00%	0 0.00%	18 15.25%	90.00% 10.00%
	94.70% 5.30%	94.70% 5.30%	93.80% 6.20%	86.40% 13.60%	100% 0.00%	94.70% 5.30%	111 94.07%
	1	2	3	4	5	6	

图 5 混淆矩阵

Fig. 5 Confusion matrix

表 7 模型评价指标

Table 7 Model evaluation index

编号	故障类型	评价指标			
		精确率	召回率	F1-score	准确率
1	中低温过热	100	94.70	97.28	94.07
2	高温过热	90.00	94.70	92.29	
3	局部放电	93.80	93.80	93.80	
4	低能放电	95.00	86.40	90.50	
5	高能放电	95.80	100	97.85	
6	正常	90.00	94.70	92.29	

#### 4.3 不同模型的诊断结果对比

为了验证该模型的有效性和准确性, 将该模型与传统的智能模型进行对比分析, 由图 6—图 11 可知, MSIDBO-KELM 模型的故障诊断准确率为 94.07%。采用 PSO-KELM、GWO-KELM、HHO-KELM、WOA-KELM、DBO-KELM 进行变压器故障诊断, 准确率分别为 80.51%、86.44%、88.14%、90.68%和 91.53%; 传统的算法相比该模型的准确率分别提高了 13.56%、7.63%、5.93%、3.39%和 2.54%。结果表明, 通过随机森林约简与 KPCA 结合算法对数据进行降维处理, 采用改进蜣螂算法优化 KELM 算法对变压器进行故障诊断, 其诊断结果最高, 说明该模型分类效果更好, 有效提高了故障诊断的准确率。

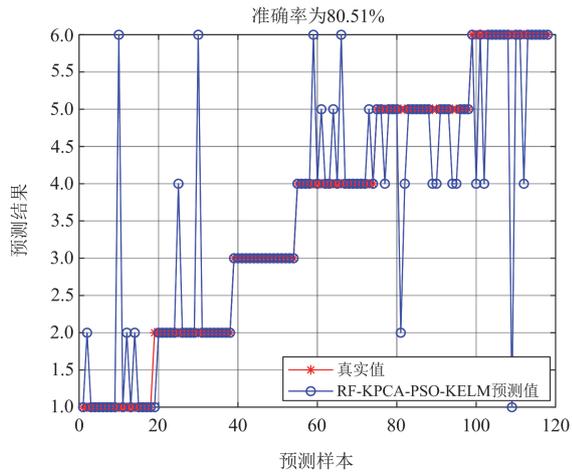


图 6 RF-KPCA-PSO-KELM 诊断结果  
Fig. 6 RF-KPCA-PSO-KELM diagnostic results

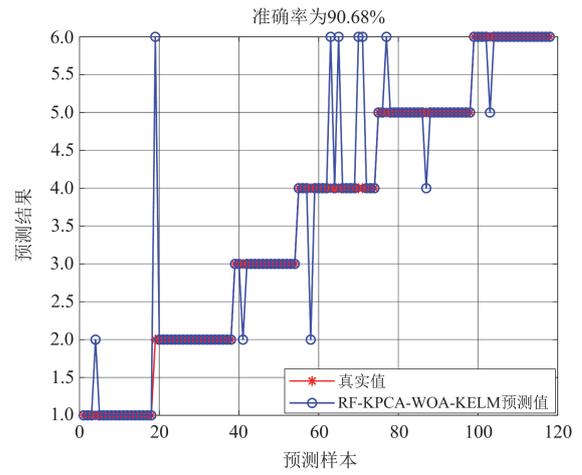


图 9 RF-KPCA-WOA-KELM 诊断结果  
Fig. 9 RF-KPCA-WOA-KELM diagnostic results

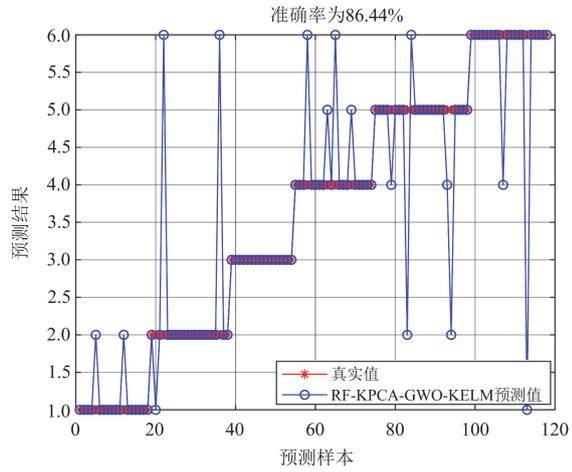


图 7 RF-KPCA-GWO-KELM 诊断结果  
Fig. 7 RF-KPCA-GWO-KELM diagnostic results

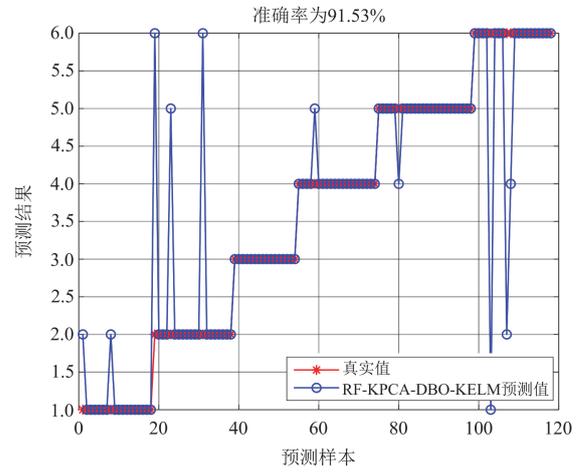


图 10 RF-KPCA-DBO-KELM 诊断结果  
Fig. 10 RF-KPCA-DBO-KELM diagnostic results

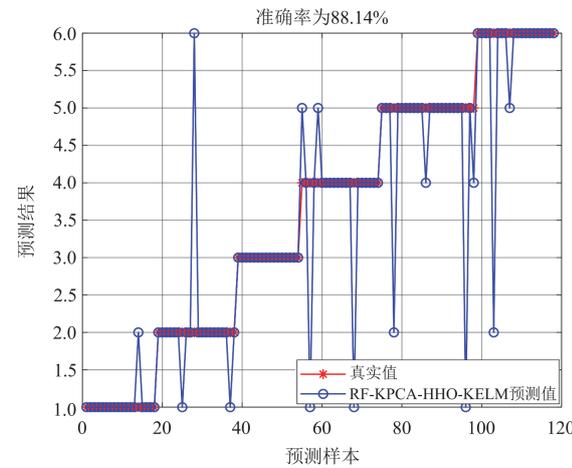


图 8 RF-KPCA-HHO-KELM 诊断结果  
Fig. 8 RF-KPCA-HHO-KELM diagnostic results

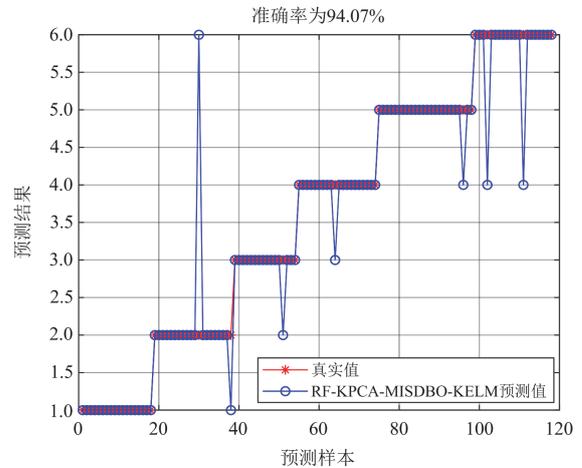


图 11 RF-KPCA-MSIDBO-KELM 诊断结果  
Fig. 11 RF-KPCA-MSIDBO-KELM diagnostic results

## 5 结论

针对油浸式变压器故障诊断中因样本冗余特征导致故障诊断精度受限的问题, 提出一种基于融合随机森林、核主成分分析与多策略改进蜣螂算法优化核极限学习机的变压器故障诊断模型。经实例验证, 得到以下结论。

1) 利用随机森林约简与 KPCA 方法对变压器原始数据进行特征优选, 将数据从 20 个特征量降到 6 个特征量。该方法不仅成功剔除冗余特征, 还提取出与故障诊断高度相关的核心指标, 为提升模型准确率奠定基础。

2) 本文引入改进的 Circle 混沌映射、变螺旋搜索机制、非线性控制因子、融合正余弦算法和融合多种群差分进化算法的变异策略对蜣螂算法进行改进, 提高了全局搜索能力和收敛精度, 通过试验证明 MSIDBO 算法的有效性。

3) 相比其他 5 种故障辨识模型, 本文所提 RF-KPCA-MSIDBO-KELM 的变压器故障诊断模型的准确率为 94.07%, 表明所提方法具有较高的准确性, 且具有一定的工程指导意义。

## 参考文献

- [1] 李婷, 肖京, 刘赞, 等. 基于信息融合和神经网络的变压器内部故障快速诊断方法[J]. 电测与仪表, 2023, 60(11): 194-200.  
LI Ting, XIAO Jing, LIU Yun, et al. Fast diagnosis method of transformer internal fault based on information fusion and neural network[J]. Electrical Measurement & Instrumentation, 2023, 60(11): 194-200.
- [2] 赵一钧, 石雷, 齐笑, 等. 基于加强灰狼优化 VMD-DBN 的变压器故障检测[J]. 电测与仪表, 2024, 61(2): 157-163.  
ZHAO Yijun, SHI Lei, QI Xiao, et al. Transformer fault detection based on enhanced gray wolf optimization VMD-DBN[J]. Electrical Measurement & Instrumentation, 2024, 61(2): 157-163.
- [3] 马向南, 杨涛, 王云龙, 等. 基于轻量化神经网络及模型压缩的变压器油色谱故障诊断方法[J]. 供用电, 2023, 40(5): 84-91.  
MA Xiangnan, YANG Tao, WANG Yunlong, et al. Transformer dissolved gas fault diagnosis method based on lightweight neural network and model quantization[J]. Distribution & Utilization, 2023, 40(5): 84-91.
- [4] 李平, 胡根铭. 基于数据增强型一维改进卷积神经网络的变压器故障诊断方法[J]. 电网技术, 2023, 47(7): 2957-2967.  
LI Ping, HU Genming. Transformer fault diagnosis based on data enhanced one-dimensional improved convolutional neural network[J]. Power System Technology, 2023, 47(7): 2957-2967.
- [5] 李强, 张睿智, 范晓丹, 等. 基于特征气体和比值准则的 RAPO 植物油变压器故障诊断方法[J]. 高压电器, 2023, 59(9): 294-303.  
LI Qiang, ZHANG Ruizhi, FAN Xiaodan, et al. Fault diagnosis method of RAPO vegetable oil transformer based on characteristic gas and ratio criterion[J]. High Voltage Apparatus, 2023, 59(9): 294-303.
- [6] 徐龙舞, 张英, 张倩, 等. 基于正交实验法改进的蝠鲞算法优化 BP 在变压器故障诊断上的研究[J]. 南方电网技术, 2022, 16(7): 46-54.  
XU Longwu, ZHANG Ying, ZHANG Qian, et al. Orthogonal experiment method based improved MRFO algorithm to optimize BP in transformer fault diagnosis[J]. Southern Power System Technology, 2022, 16(7): 46-54.
- [7] ZHAO Yao, SONG Ziyu, LI Dongdong, et al. Wind turbine gearbox fault diagnosis based on multi-sensor signals fusion[J]. Protection and Control of Modern Power Systems, 2024, 9(4): 96-109.
- [8] 刘迪迪, 王洋, 刘辉乾, 等. 基于 ADASYN 平衡化数据集的 POA-SVM 变压器故障诊断[J]. 电网与清洁能源, 2023, 39(8): 36-44.  
LIU Didi, WANG Yang, LIU Huiqian, et al. POA-SVM transformer fault diagnosis based on ADASYN Balanced data set[J]. Power System and Clean Energy, 2023, 39(8): 36-44.
- [9] 谢国民, 江海洋. 基于 Adaboost-INGO-HKELM 的变压器故障辨识[J]. 电力系统控制与保护, 2024, 52(5): 94-104.  
XIE Guomin, JIANG Haiyang. Transformer fault identification based on Adaboost-INGO-HKELM[J]. Power System Protection and Control, 2024, 52(5): 94-104.
- [10] 李笑竹, 陈志军, 樊小朝, 等. 基于 ACS-SA 文化基因算法的 BP 神经网络变压器故障诊断[J]. 高压电器, 2018, 54(2): 134-139, 146.  
LI Xiaozhu, CHEN Zhijun, FAN Xiaochao, et al. BP neural network transformer fault diagnosis based on ACS-SA cultural gene algorithm[J]. High Voltage Apparatus, 2018, 54(2): 134-139, 146.
- [11] 周晓华, 冯雨辰, 陈磊, 等. 改进秃鹰搜索算法优化 SVM 的变压器故障诊断研究[J]. 电力系统保护与控制, 2023, 51(8): 118-126.  
ZHOU Xiaohua, FENG Yuchen, CHEN Lei, et al. Transformer fault diagnosis based on SVM optimized by bald eagle search algorithm[J]. Power System Protection and Control, 2023, 51(8): 118-126.
- [12] 赵鑫, 王东丽, 彭泓, 等. 基于多策略改进蜣螂算法优化的变压器故障诊断[J]. 电力系统保护与控制, 2024, 53(6): 120-130.  
ZHAO Xin, WANG Dongli, PENG Hong, et al. Transformer fault diagnosis based on a multi-strategy improved dung beetle optimizer[J]. Power System Protection and Control, 2024, 53(6): 120-130.
- [13] 王雨虹, 孙远星, 包伟川, 等. 基于数据均衡化与改进鲸鱼算法优化核极限学习机的变压器故障诊断方法[J]. 信息与控制, 2023, 52(2): 235-244.  
WANG Yuhong, SUN Yuanxing, BAO Weichuan, et al. Transformer fault diagnosis method based on data equalization and KERN-based extreme learning machine

- of improved whale algorithm[J]. *Information and Control*, 2023, 52(2): 235-244.
- [14] 谢国民, 刘东阳, 刘明. 多策略改进 MPA 算法与 HKELM 的变压器故障辨识[J]. *电子测量与仪器学报*, 2023, 37(4): 172-182.  
XIE Guomin, LIU Dongyang, LIU Ming. Transformer fault identification based on multi-strategy improved MPA algorithm and HKELM[J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(4): 172-182.
- [15] 王雨虹, 王志中, 付华, 等. 多策略改进麻雀算法与 BiLSTM 的变压器故障诊断研究[J]. *仪器仪表学报*, 2022, 43(3): 87-97.  
WANG Yuhong, WANG Zhizhong, FU Hua, et al. Research on transformer fault diagnosis based on the improved multi-strategy sparrow algorithm and BiLSTM[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(3): 87-97.
- [16] 武文栋, 施保华, 郑传良, 等. 基于 KPCA-ISSA-KELM 的光伏阵列故障诊断方法[J]. *智慧电力*, 2022, 50(11): 69-76.  
WU Wendong, SHI Baohua, ZHENG Chuanliang, et al. Fault diagnosis method of PV array based on KPCA-ISSA-KELM[J]. *Smart Power*, 2022, 50(11): 69-76.
- [17] XUE Jiankai, SHEN Bo. Dung beetle optimizer: a new metaheuristic algorithm for global optimization[J]. *The Journal of Supercomputing*, 2023, 79(7): 7305-7336.
- [18] 吕鑫, 慕晓冬, 张钧, 等. 混沌麻雀搜索优化算法[J]. *北京航空航天大学学报*, 2021, 47(8): 1712-1720.  
LÜ Xin, MU Xiaodong, ZHANG Jun, et al. Chaos sparrow search optimization algorithm[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2021, 47(8): 1712-1720.
- [19] HERBADJI D, DEROUICHE N, BELMEGUENAI A, et al. A tweakable image encryption algorithm using an improved logistic chaotic map[J]. *Traitement Du Signal*, 2019, 36(5): 407-417.
- [20] ARORA S, ANAND P. Chaotic grasshopper optimization algorithm for global optimization[J]. *Neural Computing and Applications*, 2019, 31(8): 4385-4405.
- [21] 宋立钦, 陈文杰, 陈伟海, 等. 基于混合策略的麻雀搜索算法改进及应用[J]. *北京航空航天大学学报*, 2023, 49(8): 2187-2199.  
SONG Liqin, CHEN Wenjie, CHEN Weihai, et al. Improvement and application of hybrid strategy-based sparrow search algorithm[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2023, 49(8): 2187-2199.
- [22] MIRJALILI S, LEWIS A. The whale optimization algorithm[J]. *Advances in Engineering Software*, 2016, 95: 51-67.
- [23] 黄学雨, 罗华. 融合正余弦策略的算术优化算法[J]. *计算机工程与科学*, 2023, 45(7): 1320-1330.  
HUANG Xueyu, LUO Hua. An arithmetic optimization algorithm integrating sine-cosine strategy[J]. *Computer Engineering & Science*, 2023, 45(7): 1320-1330.
- [24] 李玉贞. 差分进化的优化方法研究及其在飞行冲突解脱中的应用[D]. 成都: 四川大学, 2023.  
LI Yuzhen. Research on optimization method for differential evolution and its application to flight conflict resolution[D]. Chengdu: Sichuan University, 2023.
- [25] 张娜, 任强, 刘广忱, 等. 基于 VMD-GWO-ELMAN 的光伏功率短期预测方法[J]. *中国电力*, 2022, 55(5): 57-65.  
ZHANG Na, REN Qiang, LIU Guangchen, et al. Short-term PV power prediction method based on VMD-GWO-ELMAN[J]. *Electric Power*, 2022, 55(5): 57-65.
- [26] 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): 171-178.  
AN Guoqing, SHI Zhewen, MA Shifeng, et al. Fault diagnosis of WOA-SVM transformer based on RF feature optimization[J]. *High Voltage Apparatus*, 2022, 58(2): 171-178.
- [27] 杨昊, 胡文秀, 张璐, 等. 基于 ADASYN 数据平衡化的 PSO-BPNN 变压器套管故障诊断[J]. *电力工程与技术*, 2024, 43(2): 170-178.  
YANG Hao, HU Wenxiu, ZHANG Lu, et al. Fault diagnosis of oil-paper bushings in PSO-BPNN algorithm based on ADASYN data balancing[J]. *Electric Power Engineering Technology*, 2024, 43(2): 170-178.
- [28] 宋立业, 范抑伶, 王焱增. 基 KPCA 与 IHHO-LSSVM 的电力变压器故障诊断方法研究[J]. *电气工程学报*, 2022, 17(1): 96-102.  
SONG Liye, FAN Yiling, WANG Yizeng. Research on fault diagnosis method of power transformer based on KPCA and IHHO-LSSVM[J]. *Journal of Electrical Engineering*, 2022, 17(1): 96-102.
- [29] 李云溟, 咸日常, 张海强, 等. 基于改进灰狼算法与最小二乘支持向量机耦合的电力变压器故障诊断方法[J]. *电网技术*, 2023, 47(4): 1470-1478.  
LI Yunhao, XIAN Richang, ZHANG Haiqiang, et al. A power transformer fault diagnosis method based on the coupling of improved grey wolf algorithm and least squares support vector machine[J]. *Power System Technology*, 2023, 47(4): 1470-1478.
- [30] 尹金良. 基于相关向量机的油浸式电力变压器故障诊断方法研究[D]. 北京: 华北电力大学, 2013.  
YIN Jinliang. Research on fault diagnosis method of oil-immersed power transformer based on relevance vector machine[D]. Beijing: North China Electric Power University, 2013.
- [31] 孙琛. 基于机器学习算法的变压器故障诊断[D]. 上海: 上海交通大学, 2019.  
SUN Chen. Transformer fault diagnosis based on machine learning algorithm[D]. Shanghai: Shanghai Jiao Tong University, 2019.

收稿日期: 2024-09-13; 修回日期: 2025-02-19

作者简介:

谭贵生(1986—), 男, 硕士, 副教授, 研究方向为电力设备故障诊断等; E-mail: tgs\_jl@163.com

赵波(1985—), 男, 博士, 教授, 博士生导师, 研究方向为表面污垢监测与控制, 新能源发电检测技术与自动化装置等。E-mail: rerbertzhao@163.com

(编辑 许威)