

DOI: 10.13382/j.jemi.B2003485

# 基于 ISSA 优化 SVM 的变压器故障诊断研究\*

李黄曼 张勇 张瑶

(陕西科技大学 机电工程学院 西安 710021)

**摘要:**针对传统的变压器故障诊断方法准确率较低的问题,提出了改进麻雀搜索算法(improved sparrow search algorithm, ISSA)优化支持向量机(SVM)的变压器故障诊断方法。首先引入动态反向学习因子对种群进行优化选择以提高麻雀搜索算法(SSA)全局寻优能力,其次用 ISSA 优化 SVM 的核函数参数和惩罚系数,建立基于油中溶解气体分析(DGA)的 ISSA 算法优化 SVM 的故障诊断模型。然后采用核主成分分析法(KPCA)对故障数据进行非线性降维。将经过 KPCA 处理后的数据输入 ISSA-SVM 进行故障诊断。并与灰狼算法-支持向量机(GWO-SVM),粒子群算法-支持向量机(PSO-SVM)诊断结果进行对比。结果表明,ISSA-SVM 故障诊断率为 92%,比 GWO-SVM, PSO-SVM, SSA-SVM 分别提高了 10.67%、8%、5.33%,可以更精准的预测变压器运行状态。

**关键词:**麻雀搜索算法;支持向量机;故障诊断;变压器;反向学习

**中图分类号:** TM42; TN06 **文献标识码:** A **国家标准学科分类代码:** 470.4017

## Study of transformer fault diagnosis based on improved sparrow search algorithm optimized support vector machine

Li Huangman Zhang Yong Zhang Yao

(School of Mechanical and Electrical Engineering, Shaanxi University of Science and Technology, Xi'an 710021, China)

**Abstract:** To solve the problem of low accuracy of tradition transformer fault diagnosis methods, a transformer fault diagnosis method based on the improved sparrow search algorithm was proposed. First, the opposition-based learning (OBL) is introduced to optimize the selection of the population to improve the global optimization ability of the sparrow search algorithm. Then use the ISSA to dynamically optimize the kernel function parameters and penalty coefficients of the support vector machine, and obtain the fault diagnosis model of the support vector machine optimized by the ISSA based on DGA. The original data is processed through very sparse random projection to remove redundant features. At last input the processed data into ISSA-SVM for fault diagnosis, and compare it with GWO-SVM, PSO-SVM and SSA-SVM. The results show that the fault diagnosis rate of the ISSA-SVM is 92%, which is 10.67%, 8% and 5.33% higher than that of GWO-SVM, PSO-SVM and SSA-SVM. So it can predict the operating status of the transformer more accurately.

**Keywords:** sparrow search algorithm; support vector machines; fault diagnosis; transformer; opposition-based learning

## 0 引言

在电力系统中,变压器是用于电压转换与传输的关键设备,对电网稳定运行起着重要作用<sup>[1]</sup>。因此需要对变压器运行状态进行实时监测,及时发现潜伏故障<sup>[2]</sup>,以保障电力系统的安全<sup>[3]</sup>。变压器运行时,绝缘油中溶解气体的成分和浓度与变压器故障类型之间存在复杂的映

射关系,当变压器发生故障,油中溶解的各气体体积分数比值会随之发生变化,因此油中溶解气体分析法(dissolved gas analysis, DGA)成为变压器故障诊断的首要方法<sup>[4]</sup>。

人工智能诊断技术如神经网络<sup>[5]</sup>、粗糙集<sup>[6]</sup>、支持向量机<sup>[7]</sup>(support vector machine, SVM)、极限学习机<sup>[8]</sup>等与 DGA 相结合的故障诊断模型可以有效的提高故障诊断率。目前对于智能故障诊断应用最广泛的是神经网络

与 SVM。神经网络的自学习能力较强,但是存在训练样本太大,网络结构模型复杂及收敛速度慢等缺点<sup>[9]</sup>,容易出现过拟合,影响其准确性。SVM 的故障诊断模型有较强的泛化能力,可以有效解决非线性问题及小样本分类问题<sup>[10]</sup>。因此利用 SVM 进行故障分类成为变压器故障诊断的研究热点,但 SVM 的诊断准确率与所选取的核函数的参数和惩罚因子有关,因此许多学者通过智能优化算法对参数进行选取。文献[11]用灰狼算法(GWO)优化收敛因子以提高故障分类精度;文献[12]用差分进化算法优化 SVM 的参数以提高故障诊断率;文献[13]用粒子群算法(PSO)对核函数参数进行优化,提高了变压器的故障诊断精度;文献[14]用遗传算法(GA)进行参数优化,以提高变压器故障诊断准确率。文献[15]用主成分分析(PCA)对变压器数据进行处理,同时用优化蜂群算法优化 SVM 进行故障诊断;但这些算法都有各自的局限性,存在收敛速度慢,易陷入局部最优等缺点难以达到高的准确率。因此可以通过采用新的智能优化算法去解决全局寻优问题。

综上所述,本文提出了改进麻雀搜索算法的变压器故障诊断方法。首先采用核主成分分析(KPCA)对变压器的故障数据进行非线性降维去除数据无效特征,然后通过引入动态反向学习因子对麻雀搜索算法(SSA)进行改进,用改进后的麻雀搜索算法优化 SVM 的参数,以提升支持向量机的分类性能。最后将 ISSA-SVM 与 SSA-SVM、PSO-SVM、GWO-SVM 做对比试验,结果表明,ISSA-SVM 对变压器故障具有较高的诊断准确率。

## 1 SSA 算法

### 1.1 SSA 算法

SSA 是 2020 年 Xue 等<sup>[16]</sup>根据麻雀觅食并逃避捕食者的行为提出的一种新颖的群体智能优化算法。将食物在空间内的分布看成函数在三维空间内的数值。该算法中麻雀的觅食行为相当于在给定范围内寻优的过程,麻雀搜索的目的便是找到全局最优值。

在寻优过程中找到食物的丰富性代表个体的能量储备水平。当遇到危险时,种群会做出反捕食行为。在算法迭代中发现者个体位置更新如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp\left(\frac{-i}{\alpha \cdot \text{iter}_{\max}}\right), R_2 < ST \\ X_{i,j}^t + Q \cdot L, R_2 \geq ST \end{cases} \quad (1)$$

式中: $t$  代表当前迭代次数,  $\text{iter}_{\max}$  表示最大的迭代次数,  $X_{i,j}^t$  表示第  $i$  个麻雀在第  $j$  维中的位置信息,  $\alpha \in (0, 1]$  是一个随机数,  $R_2 (R_2 \in [0, 1])$  和  $ST (ST \in [0.5, 1])$

分别表示预警值和安全值。 $Q$  是服从正态分布的随机数,  $L$  表示一个元素全部为 1 的矩阵。

加入者位置更新如下:

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}}^t - X_{i,j}^t}{i^2}\right), i > n/2 \\ X_{i,j}^{t+1} + |X_{i,j}^{t+1} - X_p^{t+1}| \cdot A^+ \cdot L, \text{其他} \end{cases} \quad (2)$$

式中:  $X_p$  是目前发现者所占据的最优位置;  $X_{\text{worst}}$  则表示当前全局最差的位置;  $A$  表示一个  $1 \times d$  的矩阵, 其中每个元素随机赋值为 1 或 -1, 并且  $A^+ = A^T (AA^T)^{-1}$ 。

对比本次迭代个体适应度值与当前最佳适应度值, 当算法陷入局部最优时按照如下公式更新位置。

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta \cdot |X_{i,j}^t - X_{\text{best}}^t|, f_i > f_g \\ X_{i,j}^t + K \cdot \left(\frac{|X_{i,j}^t - X_{\text{worst}}^t|}{(f_i - f_w) + \varepsilon}\right), f_i = f_g \end{cases} \quad (3)$$

式中:  $X_{\text{best}}$  是当前的全局最优位置;  $\beta$  作为步长控制参数, 是服从均值为 0, 方差为 1 的正态分布的随机数;  $K \in [-1, 1]$  是一个随机数, 表示麻雀移动的方向同时也是步长控制参数;  $f_i$  则是当前麻雀个体的适应度值;  $f_g$  和  $f_w$  分别是当前最佳和当前最差的适应度值;  $\varepsilon$  是最小的常数, 以避免分母出现 0。

通过文献[16]算法测试性能分析可知, 用 SSA 求解最优解在原点附近的函数时的算法性能远高于其它群体智能优化算法。用 SSA 求解最优解离原点较远的函数时算法性能会有所下降。但在实际的全局寻优过程中, 并不能确定最优解的位置, 因此本文用式(4)对发现者位置进行修正, 提高 SSA 对最优解离原点较远问题的寻优精度。进而提高算法的全局寻优性能。发现者位置更新更正如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot (1 + Q), R_2 < ST \\ X_{i,j}^t + Q \cdot L, R_2 \geq ST \end{cases} \quad (4)$$

### 1.2 ISSA 算法

反向学习策略(opposition-based learning, OBL)指在种群的进化过程中每个个体的位置信息均对应一个反向的位置<sup>[17]</sup>。本文将动态反向学习策略应用到麻雀算法的寻优过程中。在每次迭代中, 根据当前个体信息生成反向个体, 并对当前个体适应度与反向个体的适应度进行评价, 选择出较优的作为下一代个体, 不仅提高了麻雀种群的多样性, 也加快了算法的收敛速度, 进而提高 SSA 的全局搜索能力。

$X_{ij}$  对应的反向个体位置定义为:

$$X_{ij}^*(t) = k_1(a_j(t) + k_2 b_j(t)) - X_{ij}(t) \quad (5)$$

$$a_j(t) = \min(X_{ij}(t)), b_j(t) = \max(X_{ij}(t))$$

式中:  $k_1, k_2$  属于  $(0, 1)$  之间的随机数。

SSA 算法引入动态反向学习后步骤如下:

1) 计算出种群中所有个体更新后的位置信息  $X_{ij}$ ;

- 2) 根据式(5)计算出麻雀个体  $X_{ij}$  的反向个体  $X_{ij}^*$ ;
- 3) 计算所有个体的适应度值,选出个体  $X_{ij}$  和反向个体  $X_{ij}^*$  的最优适应度作为新个体进入下一次迭代。

### 1.3 SVM

SVM 是基于统计学习理论的结构风险最小原理和 VC 维理论,根据有限的样本信息在模型的复杂性和学习能力之间寻找平衡,以获得最好的泛化能力<sup>[18]</sup>,来解决小样本数据的分类问题。

对于非线性样本,需要将样本集从原空间非线性映射到高维特征空间,并在特征空间建立一个最优分类超平面<sup>[19]</sup>,使样本数据按照特征分离开来,同时隔离边缘最大化,从而解决样本难以区分的问题<sup>[20]</sup>。超平面表达式为:

$$w\varphi(x) + b = 0 \quad (6)$$

式中:  $\varphi(x)$  为映射函数表达式;  $w$  是最优分类超平面的法向量;  $b$  是分类阈值。

针对线性不可分问题,支持向量机需要大于 0 的惩罚因子  $C$  和松弛变量  $\xi$  其目标函数为:

$$L(\omega, \xi) = \frac{1}{2} \|\omega\|^2 + C \left( \sum_{i=1}^l \xi_i \right) \quad (7)$$

$$d = \frac{|1 - (-1)|}{\sqrt{\omega_1^2 + \omega_2^2 + \dots + \omega_N^2}} = \frac{2}{\|\omega\|} \quad (8)$$

在最优超平面上样本分类间隔  $d$  需达到最大值,即  $\|\omega\|$  最小化才能得到正确分类。因此超平面的寻优问题就归结成为一个二次规划问题。

$$\min_{w,b} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^l \xi_i \quad (9)$$

$$\text{s. t. } y_i(wx_i + b) \geq 1 - \xi_i \quad (10)$$

$$\xi_i \geq 0, i = 1, 2, \dots, l$$

利用拉格朗日乘子算法来解决上述问题,则最优超平面函数为:

$$y = \text{sign} \left( \sum_{SV} a_i y_i K(x_i, y_i) + b \right) \quad (11)$$

式中:  $SV$  为支持向量。

核函数表达式为:

$$K(x_i, y_i) = \exp \left( - \frac{\|x_i - y_i\|^2}{\partial^2} \right) \quad (12)$$

由以上公式可得,SVM 需要确定的参数有惩罚参数  $C$  与和径向基函数参数  $\partial$ 。惩罚参数越大越不能容许出现误差,惩罚参数过小容易出现欠拟合现象,核参数反映分类的准确率。因此在使用支持向量机进行故障分类时,得到最优的  $(C, \partial)$  组合可以在很大程度上提高故障诊断精度。

## 2 基于 ISSA 的故障诊断模型

### 2.1 ISSA-SVM

ISSA 优化 SVM 的故障诊断流程主要有以下几个步骤。ISSA 优化 SVM 流程如图 1 所示。

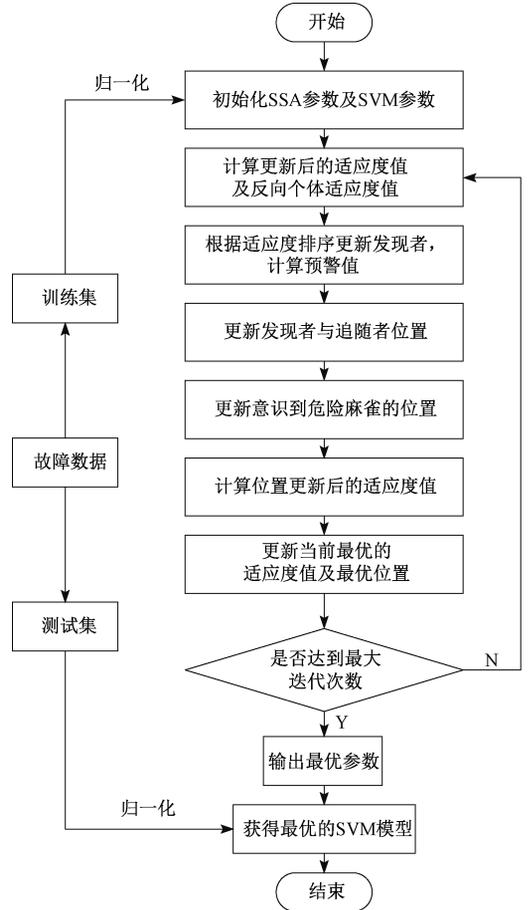


图 1 参数优化流程

Fig. 1 ISSA optimization SVM flowchart

1) 确定故障诊断模型的输入与输出。提取故障数据的特征量作为模型的输入信号,输出为变压器的故障类型。并将故障数据分为训练样本和测试样本进行归一化处理。

2) 初始化麻雀搜索算法与 SVM 相关参数。设置种群规模、最大迭代次数。

3) 训练样本进行分类,以交叉验证的准确率作为麻雀个体的适应度值。

4) 根据式(5)生成反向麻雀种群。对所有麻雀种群个体的适应度进行排序,较高适应度值的个体为发现者其余为加入者。

5) 根据式(4)更新发现者的位置。处于安全状态时麻雀可以进行广泛搜索,若大于预警值种群会有反捕食

行为。

6) 根据式(2)更新加入者的位置。根据排序原则,当  $i>n/2$  时,个体适应度值比较低,这些加入者需要到其他位置进行搜索以提高个体适应度。

7) 将本次迭代的适应度值与当前最佳适应度值进行对比,并更新全局最优信息。按照式(3)更新侦查麻雀的位置,提高种群的全局搜索能力。

8) 判断迭代次数是否满足终止条件,如不满足,则返回步骤 3),若达到最大迭代次数则停止,输出最优参数,建立 ISSA 优化的 SVM 的故障诊断模型。

### 2.2 故障特征提取

当变压器运行处于故障状态时,绝缘油中溶解的气体成分与含量会发生变化。因此可以通过对油中溶解的气体组分与含量进行检测来判断变压器是否存在潜伏性的过热,放电故障。

变压器原始的故障数据属于非线性数据,且存在的无效和冗余特征会影响诊断的准确率。因此需要对数据中的有效信息进行综合提取,并去除无用和噪音信息。本文选用 KPCA 对数据进行非线性降维,从而缓解模型的过拟合现象,并提高模型诊断的准确率。

## 3 基于 ISSA-SVM 的变压器故障诊断分析

本文数据由国家电网西北某电网提供。根据变压器油中溶解气体分析和判断导则,通过对油中溶解的气体进行分析可以判断除出设备的运行状况。本文选取了最能反映故障状态的 5 种特征气体,即  $H_2$ 、 $CH_4$ 、 $C_2H_6$ 、 $C_2H_4$  和  $C_2H_2$  作为变压器故障特征,用 KPCA 进行降维处理后作为诊断模型的输入量,通过 ISSA-SVM 进行诊断,输出为变压器故障类型,分为中低温过热,高温过热,局部放电,低能放电,高能放电与正常 6 种类型。表 1 为部分故障数据。

表 1 变压器故障数据

Table 1 Transformer fault data ( $\mu L \cdot L^{-1}$ )

$H_2$	$CH_4$	$C_2H_6$	$C_2H_4$	$C_2H_2$	故障类型
40.5	81.7	11.3	15.6	0.1	中低温过热
165.8	331.6	151.5	820.4	37.5	高温过热
4.6	16.1	3.2	4.7	49.6	低能放电
301.5	48.6	13.9	115.8	123.6	高能放电
3.4	4.8	5.8	10.6	1.8	正常
180.5	0.6	0.1	0.2	0	局部放电

将变压器的故障数据分为训练样本和测试样本,首先用训练样本对 ISSA-SVM 进行分类学习,然后对测试样本进行故障诊断,通过对比实际故障与预测故障得到

ISSA-SVM 的分类准确率。为了验证本文所述方法的准确性与可行性,选用了 PSO-SVM、GWO-SVM 与 SSA-SVM、ISSA-SVM 进行对比分析。故障编号与样本分布如表 2 所示。

表 2 样本编号及分布

Table 2 Data number and classification

故障类型	中低温过热	高温过热	正常	低能放电	高能放电	局部放电
编号	1	2	3	4	5	6
训练样本数	30	35	35	30	30	35
测试样本数	10	15	15	10	10	15

### 3.1 算法寻优比较

本文以训练样本的最高分类准确率为优化准则建立目标函数。用 SSA、PSO、GWO 分别对 SVM 参数进行优化并与 ISSA 寻优结果进行对比。图 2 所示为各算法交叉验证准确率的寻优迭代曲线。

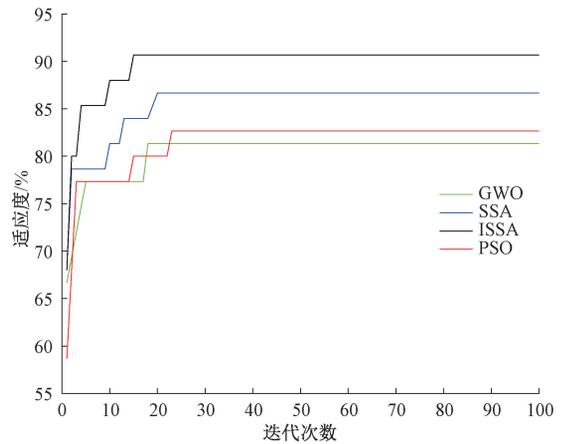


图 2 分类准确率寻优曲线

Fig. 2 Classification accuracy optimization curve

由图 2 可得,GWO 算法在寻优过程中最容易陷入局部最优。PSO 算法由于其自身存在对离散的优化问题处理不佳的缺陷使其无法获得更高的诊断准确率。ISSA 加入了侦察预警机制与动态反向学习机制,其收敛速度快,对训练样本的分类准确率高。由此可见,用 ISSA 优化 SVM 参数建立变压器故障诊断模型具有可行性。

### 3.2 测试样本分类结果分析

将训练样本最高分类准确率对应的优化参数输入诊断模型对测试样本进行分类,并将预测的故障状态与实际出现的故障进行对比,验证其分类准确性。表 4 为 4 种算法对每种故障的分类准确率。图 3~6 所示为不同算法的预测结果与实际结果对比。

表 4 不同方法故障检测对比

Table 4 Comparison of different methods of fault detection

故障类型	GWO-SVM	PSO-SVM	SSA-SVM	ISSA-SVM
中低温过热	9(0.9)	10(1)	10(1)	10(1)
高温过热	12(0.8)	9(0.6)	11(0.73)	14(0.93)
正常	13(0.87)	14(0.93)	13(0.87)	14(0.93)
低能放电	8(0.8)	10(1)	10(1)	9(0.9)
高能放电	6(0.6)	7(0.7)	8(0.8)	9(0.9)
局部放电	13(0.87)	13(0.87)	13(0.87)	13(0.87)
总正确率	61(81.33%)	63(84%)	65(86.67%)	69(92%)

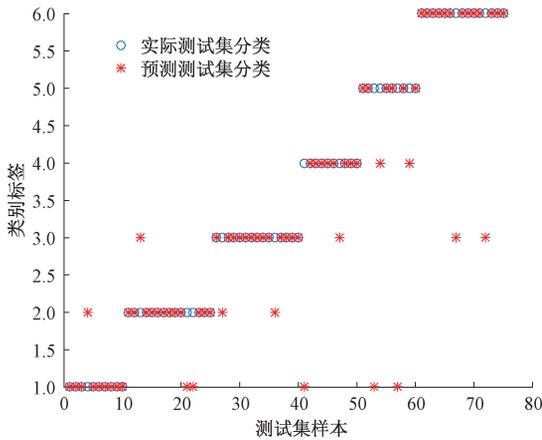


图 3 GWO-SVM 诊断模型实际与预测分类  
Fig. 3 GWO-SVM diagnosis model actual and predicted classification

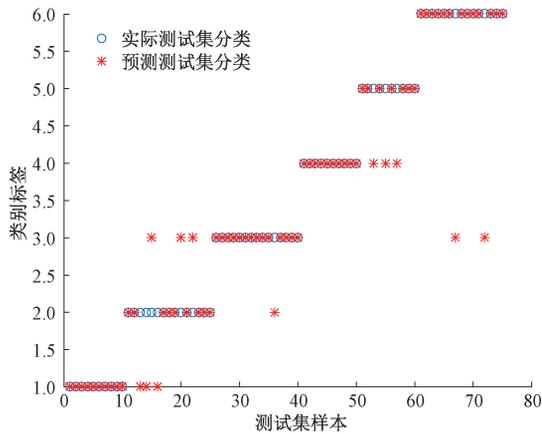


图 4 PSO-SVM 诊断模型实际与预测分类  
Fig. 4 PSO-SVM diagnostic model actual and predicted classification

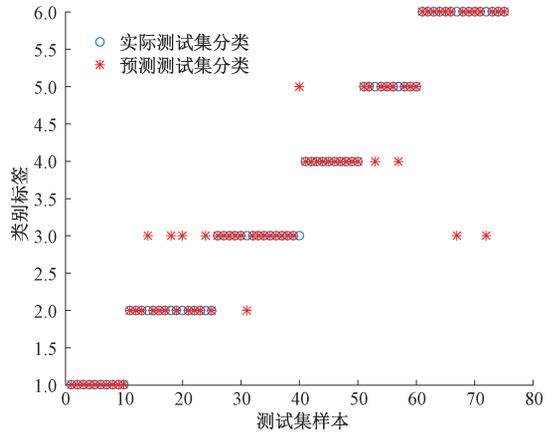


图 5 SSA-SVM 诊断模型实际与预测分类  
Fig. 5 SSA-SVM diagnostic model actual and predicted classification

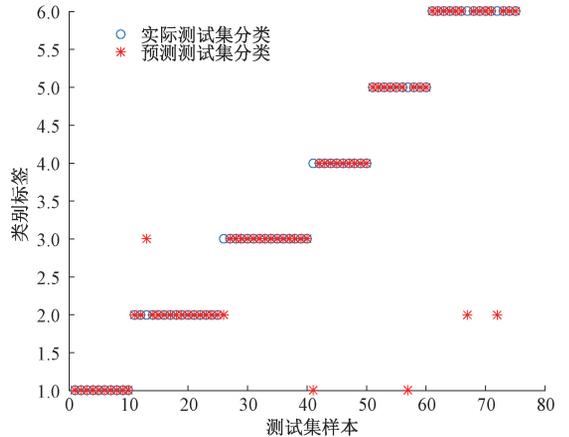


图 6 ISSA-SVM 诊断模型实际与预测分类  
Fig. 6 ISSA-SVM diagnostic model actual and predicted classification

更精确的预测变压器实际运行状态。

### 4 结论

本文提出了基于改进麻雀搜索算法优化支持向量机的变压器故障诊断的方法。通过引入动态反向学习对 SSA 进行优化,进而建立 ISSA-SVM 故障诊断模型,由变压器实际故障预测结果可得,与 GWO-SVM 和 PSO-SVM 相比,ISSA-SVM 故障诊断精度高,泛化能力强,可以对变压器出现的异常状态进行初步判定,从而及时发现运行中存在的隐藏故障,保障变压器的安全运行。

采用改进麻雀搜索算法优化支持向量机建立的故障诊断模型具有普遍性,不仅可应用于变压器的故障诊断,也可将此应用到其他类型的故障分类上,为解决小样本分类问题提供了一种新的思想。

由图 3~6 可得,在训练数据与测试数据相同的情况下,ISSA-SVM 正确预测变压器的故障个数为 69 个。故障诊断正确率为 92%,SSA-SVM、PSO-SVM、GWO-SVM 诊断正确率分别为 86.67%、84%、81.33%。结果表明,ISSA-SVM 对变压器的故障诊断具有更高的可靠性,可以

## 参考文献

- [ 1 ] JAMES H. Harlow electric power transformer engineering[M]. 3rd ed. USA: CRC Press, 2012: 601-602.
- [ 2 ] 周光宇, 马松龄. 基于机器学习与 DGA 的变压器故障诊断及定位研究[J]. 高压电器, 2020, 56(6): 262-268.
- ZHOU G Y, MA S L. Study of transformer fault diagnosis and location based on machine learning and DGA[J]. High Voltage Apparatus, 2020, 56(6): 262-268.
- [ 3 ] 张朝龙, 何怡刚, 杜博伦, 等. 基于深度学习的电力变压器智能故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(1): 81-89.
- ZHAO CH L, HE Y G, DU B L, et al. Intelligent fault diagnosis method of power transformer using deep learning [ J ]. Journal of Electronic Measurement and Instrumentation, 2020, 34(1): 81-89.
- [ 4 ] 陈嘉宁, 杨翮, 叶承晋, 等. 基于缺失数据修复的变压器在线故障诊断方法[J]. 电力系统保护与控制, 2019, 47(15): 86-92.
- CHEN J N, YANG X, YE CH J, et al. On-line fault diagnosis method for power transformer based on missing data repair [ J ]. Power System Protection and Control, 2019, 47(15): 86-92.
- [ 5 ] 陈里里, 何颖, 董绍江. 基于深度神经网络的液压泵泄漏状态识别[J]. 仪器仪表学报, 2020, 41(4): 86-94.
- CHEN L L, HE Y, DONG SH J. Recognition of hydraulic pump leakage status based on deep neural network [ J ]. Chinese Journal of Scientific Instrument, 2020, 41(4): 86-94.
- [ 6 ] 林晓宁, 蔡金锭. 基于粗糙集理论的变压器油纸绝缘状态评估[J]. 电力系统保护与控制, 2019, 47(7): 22-29.
- LIN X N, CAI J D. Evaluation of transformer oil-paper insulation based on rough set theory [ J ]. Power System Protection and Control, 2019, 47(7): 22-29.
- [ 7 ] 谈恩民, 李峰. 结合 LMD 云模型和 ABC-LSSVM 的模拟电路故障诊断[J]. 电子测量与仪器学报, 2020, 34(2): 80-87.
- TAN EN M, LI F. Analog circuit fault diagnosis combined with LMD cloud model and ABC-LSSVM [ J ]. Journal of Electronic Measurement and Instrumentation, 2020, 34(2): 80-87.
- [ 8 ] 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.
- ZHANG SH Q, YUAN SH Y, YAO Y Y. Machinery fault diagnosis method based on ICEEMD and AWOA optimized ELM [ J ]. Instrumentation, 2019, 40(11): 172-180.
- [ 9 ] 雷帆, 高波, 袁海满, 等. 基于 DGA 的粗糙集与人工鱼群极限学习机的变压器故障诊断[J]. 高压电器, 2017, 53(10): 124-130.
- LEI F, GAO B, YUAN H M, et al. Transformer Fault Diagnosis by Using Rough Set and Artificial Fish Swarm Extreme Learning Machine Based on DGA [ J ]. High Voltage Apparatus, 2017, 53(10): 124-130.
- [ 10 ] MAGALHÃES S, BORGES R, CALÇADA L, et al. Development of an expert system to remotely build and control drilling fluids [ J ]. Journal of Petroleum Science and Engineering, 2019: 181.
- [ 11 ] 王旭, 姚强, 国辉, 等. 基于多频超声波技术和改进灰狼优化算法的变压器油检测系统研究[J]. 电气自动化, 2020, 42(1): 10-12, 21.
- WANG X, YAO Q, GUO H, et al. Research on the transformer oil detection system based on multi-frequency ultrasonic wave and improved grey wolf optimization [ J ]. Electrical Automation, 2020, 42(1): 10-12, 21.
- [ 12 ] 贾立敬, 张建文, 王传林, 等. 基于 DGA 的差分进化支持向量机电力变压器故障诊断[J]. 高压电器, 2015, 51(4): 13-18.
- JIA L J, ZHANG J W, WANG CH L, et al. Fault diagnosis of power transformer based on DGA of Algorithm for SVM [ J ]. High Voltage Apparatus, 2015, 51(4): 13-18.
- [ 13 ] 谭贵生, 石宜金, 刘丹丹, 等. 基于混沌粒子群优化支持向量机的变压器故障诊断[J]. 昆明理工大学学报(自然科学版), 2019, 44(5): 54-61.
- TAN G SH, SHI Y J, LIU D D, et al. Fault diagnosis of transformers based on support vector machine with improved particle swarm optimization [ J ]. Journal of Kunming University of Science and Technology ( Natural Science ), 2019, 44(5): 54-61.
- [ 14 ] 吐松江·卡日, 高文胜, 张紫薇, 等. 基于支持向量机和遗传算法的变压器故障诊断[J]. 清华大学学报(自然科学版), 2018, 58(7): 623-629.
- KARI T S J, GAO W SH, ZHANG Z W, et al. Power transformer fault diagnosis based on a support vector machine and a genetic algorithm [ J ]. Journal of Tsinghua University ( Sci Technol ), 2018, 58(7): 623-629.
- [ 15 ] 谢国民, 倪乐水. 基于 IABC 优化 SVM 的变压器故障诊断[J]. 电力系统保护与控制, 2020, 48(15): 156-163.
- XIE G M, NI L SH. Transformer fault diagnosis based on an artificial bee colony-support vector machine optimization algorithm [ J ]. Power System Protection and Control, 2020, 48(15): 156-163.

- [16] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm [J]. Systems Science & Control Engineering, 2020(8):1, 22-34.
- [17] 李二超, 杨蓉蓉. 基于自适应反向学习的多目标分布估计算法 [J/OL]. 计算机应用: 1-8 [2020-10-19]. <http://kns.cnki.net/kcms/detail/51.1307.TP.20200812.1831.010.html>.  
LI ER CH, YANG R R. Multi-objective estimation of distribution algorithm with adaptive opposition-based learning [J/OL]. CODENJYIIDU: 1-8 [2020-10-19]. [http://kns.cnki.net/kcms/detail/51.1307.TP.20200812.1831.010htm](http://kns.cnki.net/kcms/detail/51.1307.TP.20200812.1831.010.htm).
- [18] 陈鹏, 赵小强, 朱奇先. 基于多尺度排列熵和改进多分类相关向量机的滚动轴承故障诊断方法 [J]. 电子测量与仪器学报, 2020, 34(2): 20-28.  
CHEN P, ZHAO X Q, ZHU Q X. Rolling bearing fault diagnosis method based on multi-scale permutation entropy and improved multi-class relevance vector machine [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(2): 20-28.
- [19] 郭创新, 朱承治, 张琳, 等. 应用多分类多核学习支持向量机的变压器故障诊断方法 [J]. 中国电机工程学报, 2010, 30(13): 128-134.  
GUO CH X, ZHU CH ZH, ZHANG L, et al. A fault diagnosis method for power transformer based on multiclass multiple-kernel learning support vector machine [J]. Proceedings of the CSEE, 2010, 30(13): 128-134.
- [20] 陈金猛, 李屹. 基于故障树的变压器质量缺陷分类方法研究 [J]. 变压器, 2017, 54(9): 43-46.  
CHEN J M, LI Y. Research on quality defect classification method for transformer based on fault tree analysis [J]. Transformer, 2017, 54(9): 43-46.

### 作者简介



**李黄曼**, 2016 年于山西大学获得学士学位, 现为陕西科技大学硕士研究生, 主要研究方向为电力系统智能检测。

E-mail: 1139536425@qq.com

**Li Huangman** received her B. Sc. degree from Shanxi University in 2016. Now she is a M. Sc candidate at Shaanxi University of Science and Technology. Her main research interests include intelligent detection of power system.