

DOI:10.19651/j.cnki.emt.2415747

# 基于 EBWO-SVM 的变压器故障诊断研究<sup>\*</sup>

汪繁荣 李州

(湖北工业大学电气与电子工程学院 武汉 430074)

**摘要:** 针对 SVM 在变压器故障诊断中存在诊断精度不高和 BWO 算法存在易陷入局部最优的问题,提出一种基于 EBWO-SVM 的变压器故障诊断方法。首先通过引入准反向学习策略和旋风式觅食策略对 BWO 算法进行改进,然后将 EBWO 算法与粒子群优化算法、灰狼优化算法、鲸鱼优化算法、白鲸优化算法在 6 种测试函数上进行寻优测试,验证了 EBWO 算法的优越性。其次利用 EBWO 算法对 SVM 中的核函数参数  $g$  和  $C$  进行优化,从而提高 SVM 的分类能力。最后提出其他方法与 EBWO-SVM 模型进行对比。结果表明:所构建的 EBWO-SVM 变压器故障诊断模型与 BWO-SVM、WOA-SVM、GWO-SVM、PSO-SVM 相比,综合诊断精度分别提高了 7.7%、9.7%、11.6%、15.4%,且稳定性更强,验证了 EBWO-SVM 模型的可行性与有效性。

**关键词:** 支持向量机;白鲸优化算法;变压器;故障诊断;准反向学习策略;旋风式觅食策略

**中图分类号:** TM41;TN06 **文献标识码:** A **国家标准学科分类代码:** 470.40

## Research on transformer fault diagnosis based on EBWO-SVM

Wang Fanrong Li Zhou

(School of Electrical and Electronic Engineering, Hubei University of Technology, Wuhan 430074, China)

**Abstract:** Aiming at the problems of low diagnostic accuracy of SVM and easy to fall into local optimum of BWO algorithm in transformer fault diagnosis, a transformer fault diagnosis method based on EBWO-SVM is proposed. Firstly, the BWO algorithm is improved by introducing quasi-opposition-based learning strategy and cyclone foraging strategy, and then the EBWO algorithm and particle swarm optimization algorithm, grey wolf optimization algorithm, whale optimization algorithm, and beluga optimization algorithm are tested for optimality seeking on six test functions, which verifies the superiority of the EBWO algorithm. Secondly, the EBWO algorithm is used to optimise the kernel function parameters  $g$  and  $C$  in SVM so as to improve the classification ability of SVM. Finally other methods are proposed to compare with the EBWO-SVM model. The results indicate that the constructed EBWO-SVM transformer fault diagnosis model improves the comprehensive diagnostic accuracy by 7.7%, 9.7%, 11.6%, and 15.4% compared with BWO-SVM, WOA-SVM, GWO-SVM, and PSO-SVM, respectively, and is more stable, which verifies the feasibility and effectiveness of the EBWO-SVM model.

**Keywords:** support vector machines; beluga whale optimization; transformers; fault diagnosis; quasi-opposition-based learning strategy; cyclonic foraging strategy

## 0 引言

变压器作为电力系统中不可替代的关键设备之一,不仅提高了电能的传输质量,还保障了电网的供电稳定性。变压器发生故障会造成一系列的负面影响,因此精准进行变压器故障诊断对电力系统的稳定运行有着重要意义<sup>[1-3]</sup>。

变压器中有着大量的绝缘材料和绝缘油,变压器在运行时,绝缘油中的气体处于一种平衡稳定状态。当变压器

发生故障时,绝缘材料会分解产生大量的氢气( $H_2$ )、甲烷( $CH_4$ )、乙烷( $C_2H_6$ )、乙烯( $C_2H_4$ )和乙炔( $C_2H_2$ )等气体<sup>[4-5]</sup>,此时油中气体平衡被破坏,这使得气体含量与故障类型之间有着复杂的非线性关系,因此油中溶解气体分析(dissolved gas analysis, DGA)法被普遍用于变压器的故障诊断研究<sup>[6-8]</sup>。传统的 DGA 技术主要有国际电工委员会(international electrotechnical commission, IEC)三比值法和大卫三角法等,运用这些方法判断变压器故障非常方便

收稿日期:2024-04-01

<sup>\*</sup> 基金项目:国家自然科学基金(61903129)项目资助

简单,但还存在着编码不全、依赖于专家经验等缺陷<sup>[9]</sup>。随着人工智能的发展,极限学习机(extreme learning machine, ELM)、神经网络和支持向量机(support vector machine, SVM)等智能方法开始在变压器故障诊断中得到广泛运用<sup>[10]</sup>。文献[11]利用三比值法结合 ELM 进行变压器的故障诊断研究,从而提高了诊断精度,但该方法在收敛速度和泛化能力方面仍有不足;文献[12]将神经网络与三比值法相结合,提高了模型分类的精度和泛化能力,但神经网络需要大量的训练样本,且稳定性不高。SVM 有着良好的适用性,能够很好地处理多分类问题,但 SVM 对于核函数参数的设置较为敏感,这两个参数在很大程度上决定了 SVM 的分类性能,因此选择合适的参数是提高故障诊断精度的重点问题。人工进行参数调试较为困难,因此很多学者利用智能算法来对 SVM 的参数进行寻优。文献[13]利用改进的引力搜索算法对 SVM 的参数进行寻优,从而提高了 SVM 的分类精度;文献[14]提出海鸥算法来优化 SVM 的核函数参数,克服了算法容易陷入局部最优的缺陷,提高了 SVM 的性能;文献[15]引入改进萤火虫算法与 SVM 相结合,提高了 SVM 的诊断性能,但上述方法还存在着收敛速度慢和诊断精度不高的问题。白鲸优化算法(beluga whale optimization, BWO)具有较强的全局搜索能力,在解决优化问题中有着良好的效率,但仍存在易陷入局部最优和自适应能力有限的问题。文献[16]利用混沌反向学习策略和水波算法对 BWO 进行改进,从而提高了 BWO 算法跳出局部最优的能力和收敛速度,文献[17]提出基于切线飞行和适应度距离平衡策略的改进 BWO 算法,提高了 BWO 算法的鲁棒性和寻优能力。

综上所述,本文提出一种基于改进白鲸算法(enhanced version of the beluga whale optimization, EBWO)优化 SVM 的变压器故障诊断模型。首先通过引入准反向学习(quasi-opposition-based learning, QOBL)策略和旋风式觅食策略(cyclone foraging strategy, CFS)对 BWO 算法进行改进,并利用 6 种经典的测试函数验证了 EBWO 算法有着更好的寻优能力。然后利用 EBWO 算法对 SVM 的核函数参数进行寻优,并将最优参数导入 SVM 进行训练,从而提高了 SVM 在变压器故障诊断中的分类性能。最后提出 BWO-SVM、GWO-SVM、PSO-SVM、WOA-SVM 模型与 EBWO-SVM 模型进行对比实验,验证了 EBWO-SVM 模型的可行性与有效性。

## 1 BWO 算法

受白鲸生活行为的启发,李刚等<sup>[18]</sup>于 2022 年提出 BWO 算法,该算法具有全局搜索能力强和收敛速度快的优点,该算法主要包括以下几个阶段:

### 1) 种群初始化

白鲸是一种种群制度的动物,这里设每条白鲸为一个候选解决方案,种群初始化位置如式(1)所示,白鲸对应的

适应度值如式(2)所示。

$$\mathbf{X} = \begin{bmatrix} x_{1,1} & x_{1,2} & \cdots & x_{1,d} \\ x_{2,1} & x_{2,2} & \cdots & x_{2,d} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n,1} & x_{n,2} & \cdots & x_{n,d} \end{bmatrix} \quad (1)$$

$$\mathbf{F}_x = \begin{bmatrix} f(x_{1,1}, x_{1,2}, \cdots, x_{1,d}) \\ f(x_{2,1}, x_{2,2}, \cdots, x_{2,d}) \\ \vdots \\ f(x_{n,1}, x_{n,2}, \cdots, x_{n,d}) \end{bmatrix} \quad (2)$$

式中: $n$  为种群大小, $d$  为设计变量维度。

白鲸优化算法从探索转向开发的过程取决于平衡因子  $B_f$ ,此过程的数学表达式如式(3)所示。

$$B_f = B_0 \left(1 - \frac{t}{2T_{\max}}\right) \quad (3)$$

式中: $t$  为目前的迭代次数, $T_{\max}$  为最大迭代次数, $B_0$  为 0~1 之间的随机数。

### 2) 勘探阶段

白鲸通过游泳行为来进行勘探,此过程中白鲸的位置更新可由式(4)所示。

$$\begin{cases} \mathbf{X}_{i,j}^{t+1} = \mathbf{X}_{i,P_j}^t + (\mathbf{X}_{i,P_1}^t - \mathbf{X}_{i,P_j}^t)(1 + r_1)\sin(2\pi r_2), & j = \text{even} \\ \mathbf{X}_{i,j}^{t+1} = \mathbf{X}_{i,P_j}^t + (\mathbf{X}_{i,P_1}^t - \mathbf{X}_{i,P_j}^t)(1 + r_1)\cos(2\pi r_2), & j = \text{odd} \end{cases} \quad (4)$$

式中: $\mathbf{X}_{i,j}^{t+1}$  代表第  $i$  头白鲸在第  $j$  维的新位置, $P_j$  为从  $d$  维中选取的随机数, $\mathbf{X}_{i,P_j}^t$  为第  $i$  头白鲸的当前位置, $\mathbf{X}_{i,P_1}^t$  为第  $r$  头白鲸的当前位置, $r$  为随机选择的白鲸, $r_1$  和  $r_2$  为 0~1 的随机数, $\sin(2\pi r_2)$  和  $\cos(2\pi r_2)$  代表镜像白鲸鱼鳍对向水面。

### 3) 开发阶段

白鲸利用捕食行为来进行开发阶段,并通过感知邻近白鲸的位置来合作觅食和移动位置,假设白鲸可以通过 Levy 飞行策略来捕捉食物,该过程的数学表达式可由式(5)所示。

$$\mathbf{X}_i^{t+1} = r_3 \mathbf{X}_{\text{best}}^t - r_4 \mathbf{X}_i^t + C_1 \cdot L_F \cdot (\mathbf{X}_i^t - \mathbf{X}_i^t) \quad (5)$$

式中: $\mathbf{X}_i^t$  代表第  $i$  头白鲸的当前位置, $\mathbf{X}_i^t$  代表随机选择的白鲸位置, $\mathbf{X}_{\text{best}}^t$  为当前迭代次数中白鲸的最优位置, $r_3$  和  $r_4$  为 0~1 的随机数, $C_1$  为测量 Levy 飞行的随机跳跃高度,且  $C_1 = 2r_4(1 - t/T_{\max})$ , $L_F$  为飞行函数,其数学表达式如式(6)和(7)所示。

$$L_F = 0.05 \times \frac{u \times \sigma}{|v|^{1/\beta}} \quad (6)$$

$$\sigma = \left( \frac{\Gamma(1 + \beta) \times \sin(\pi\beta/2)}{\Gamma((1 + \beta/2) \times \beta \times 2^{(\beta-1)/2})} \right)^{1/\beta} \quad (7)$$

式中: $u$  和  $v$  为服从正态分布的随机数, $\beta = 1.5$ 。

### 4) 坠落阶段

由于天敌和环境的威胁,白鲸要么转移至其他位置生活,要么坠落海底。为维持种群数量不变,利用白鲸位置与

坠落步长更新位置,白鲸在此过程中的位置更新可由式(8)所示。

$$\begin{cases} \mathbf{X}_i^{t+1} = r_5 \mathbf{X}_i^t - r_6 \mathbf{X}_r^t + r_7 \mathbf{X}_{step} \\ \mathbf{X}_{step} = (\mathbf{u}_b - \mathbf{l}_b) \exp(-C_2 \frac{t}{T_{max}}) \\ W_f = 0.1 - 0.05 \frac{t}{T_{max}} \end{cases} \quad (8)$$

式中: $r_5, r_6, r_7$ 为 $0 \sim 1$ 之间的随机数, $\mathbf{X}_{step}$ 代表白鲸坠落步长, $C_2 = 2W_f \times n$ ,代表与鲸鱼下降概率和种群大小相关的步长因子, $\mathbf{u}_b$ 为优化问题的上界, $\mathbf{l}_b$ 为优化问题的下界, $W_f$ 为白鲸坠落的概率。

### 1.1 EBWO 算法

#### 1) 准反向学习策略

使用准反向学习策略能够增强白鲸种群的多样性与随机性,可以避免算法陷入局部最优,准反向学习策略可由式(9)和(10)所示。

$$\begin{cases} \mathbf{X}_{i,j}^o = \mathbf{Lb}_j + \mathbf{Ub}_j - \mathbf{X}_{i,j} \\ \mathbf{C}_{i,j} = (\mathbf{Lb}_j + \mathbf{Ub}_j) / 2 \\ \mathbf{X}_{i,j}^{t+1} = \mathbf{C}_{i,j} + (\mathbf{X}_{i,j}^o - \mathbf{C}_{i,j}) \times \text{rand}, \quad (\mathbf{X}_{i,j} < \mathbf{C}_{i,j}) \\ \mathbf{X}_{i,j}^{t+1} = \mathbf{C}_{i,j} + (\mathbf{C}_{i,j} - \mathbf{X}_{i,j}^o) \times \text{rand}, \quad \text{其他} \end{cases} \quad (9)$$

$$(10)$$

式中: $\mathbf{X}_{i,j}$ 为白鲸的位置, $\mathbf{X}_{i,j}^o$ 为 $\mathbf{X}_{i,j}$ 的镜像反向解, $\mathbf{X}_{i,j}^{t+1}$ 为由QOBL策略新生成的反向解, $\mathbf{Lb}_j$ 为第 $j$ 维变量的下限, $\mathbf{Ub}_j$ 为第 $j$ 维变量的上限, $\mathbf{C}_{i,j}$ 为第 $j$ 维变量的均值。

#### 2) 旋风式觅食策略

CFS策略依据于最优解的螺旋运动,主要作用于BWO算法的开发阶段,白鲸种群会以螺旋运动的方式接近最优解,白鲸种群的这个过程可由式(11)和(12)所示。

$$\mathbf{X}_i^{t+1} = \begin{cases} \mathbf{X}_{best}^t + r_8 (\mathbf{X}_{best}^t - \mathbf{X}_i^t) + \delta (\mathbf{X}_{best}^t - \mathbf{X}_i^t), & i = 1 \\ \mathbf{X}_{best}^t + r_8 (\mathbf{X}_{i-1}(t) - \mathbf{X}_i^t) + \delta (\mathbf{X}_{best}^t - \mathbf{X}_i^t), & i = 1, 2, \dots, n \end{cases} \quad (11)$$

$$\delta = 2e^{-r_9 \frac{T_{max} - t + 1}{T_{max}}} \cdot \sin(2\pi r_9) \quad (12)$$

式中: $\delta$ 为随着迭代次数改变的权重系数, $r_8$ 和 $r_9$ 为 $0 \sim 1$ 之间的随机数。

### 1.2 EBWO 算法性能测试

为了测试EBWO算法的性能,选取6个经典的测试函数进行仿真实验,表1为6个测试函数的数学表达式及相关的参数设置。同时利用粒子群算法(particle swarm optimization, PSO)、灰狼算法(grey wolf optimizer, GWO)、鲸鱼算法(whale optimization algorithm, WOA)和BWO算法做对比,其中每个测试函数的维度均设置为30,迭代次数均设置为500次,其中 $f_1 \sim f_4$ 测试函数为单峰函数, $f_5$ 和 $f_6$ 测试函数为多峰函数。图1(a)~(f)分别为6个测试函数的可视化图,图2(a)~(f)分别为5种算法在不同测试函数上的寻优过程图。由图2中可以看出,EBWO算法在每个测试函数上都有着明显的优势,EBWO算法相比于其他算法能够更快的接近于最优解,说明EBWO算法有着更好的寻优能力。

表1 测试函数

测试函数	搜索区间	最优解	维度	迭代次数
$f_1(x) = \sum_{i=1}^{30} x_i^2$	$[-100, 100]$	0		
$f_2(x) = \sum_{i=1}^{30}  x_i  + \prod_{i=1}^{30}  x_i $	$[-10, 10]$	0		
$f_3(x) = \sum_{i=1}^{30} (\sum_{j=1}^i x_j)^2$	$[-100, 100]$	0	30	500
$f_4(x) = \max\{ x_i , 1 \leq i \leq 30\}$	$[-100, 100]$	0		
$f_5(x) = \sum_{i=1}^{30} (x_i^2 - 10 \cos(2\pi x_i)) + 10$	$[-5.12, 5.12]$	0		
$f_6(x) = -20 \exp(-0.2 \sqrt{\frac{1}{30} \sum_{i=1}^{30} x_i^2}) - \exp(\frac{1}{30} \sum_{i=1}^{30} \cos 2\pi x_i) + 20 + e$	$[-32, 32]$	0		

## 2 EBWO-SVM 模型

### 2.1 支持向量机

SVM以统计学习理论的VC维理论和结构风险最小原理为基础,能够很好的解决小样本分类问题,因此SVM在变压器故障诊断中可以得到很好的应用。为实现分类,SVM会利用非线性核函数和最优超平面的构建来将输入

样本从原始空间映射到高维特征空间,其中最优超平面问题可表示为最大间隔分类问题,该过程的优化方程可由式(13)所示。

$$\begin{cases} \min \frac{1}{2} \boldsymbol{\omega} \boldsymbol{\omega}^T + C \sum_{i=1}^n \xi_i \\ \text{s. t. } y_i (\boldsymbol{\omega}^T \cdot \mathbf{x}_i + b) \geq 1 - \xi_i \end{cases} \quad (13)$$

式中: $\boldsymbol{\omega}$ 为最优超平面法向量, $C$ 为惩罚因子, $b$ 为偏置,

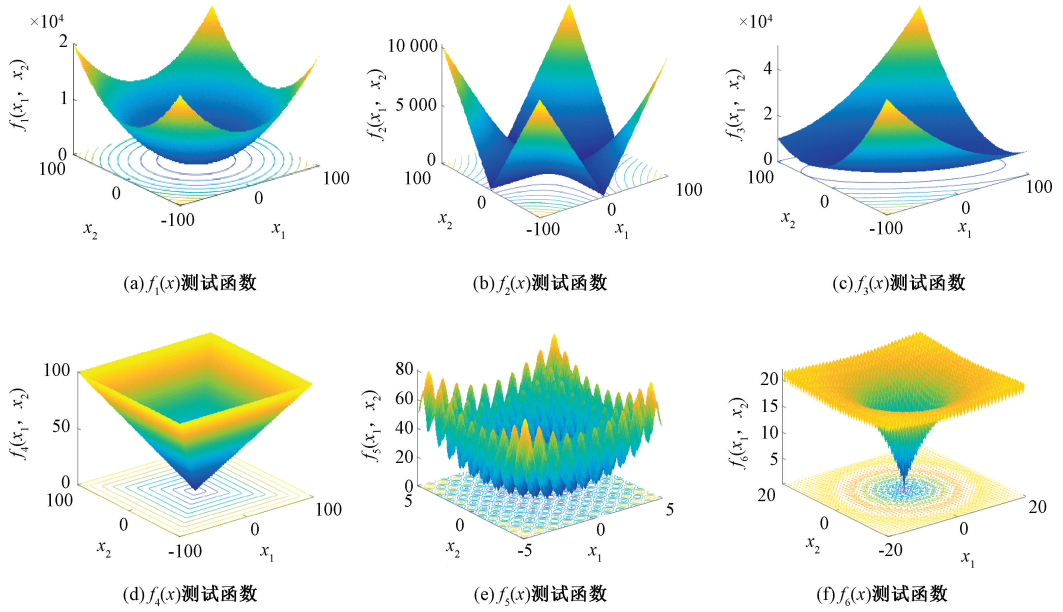


图 1 测试函数图

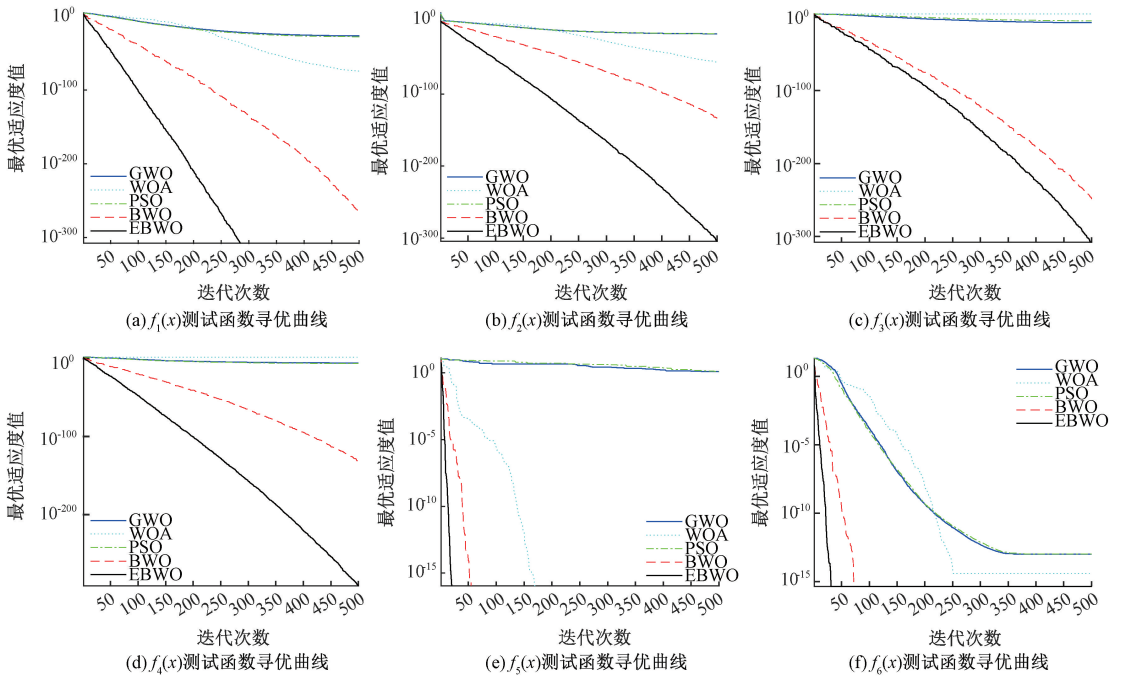


图 2 各算法在不同测试函数上的寻优过程曲线

$x_i$  为输入,  $y_i$  为故障类型,  $\xi_i$  为松弛项。

为处理非线性问题,需要用核函数对 SVM 做非线性处理,从而将问题转化为对偶问题,并得到最优决策函数,该过程对偶优化形式和决策函数分别由式(14)和(15)所示。

$$\begin{cases} \min Q(\alpha) = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(\mathbf{x} \cdot \mathbf{x}_j) - \sum_{i=1}^N \alpha_i \\ \text{s. t. } \sum_{i=1}^N \alpha_i y_i, \alpha_i \geq 0 \end{cases} \quad (14)$$

$$f(x) = \text{sign} \left[ \sum_{i=1}^l a_i y_i K(\mathbf{x}, \mathbf{x}_i) + b \right] \quad (15)$$

式中:  $K(\mathbf{x}, \mathbf{x}_i)$  为核函数,本文利用的核函数类型是径向基核函数(radial basis function, RBF),  $\alpha$  为拉格朗日乘子。

$K(\mathbf{x}, \mathbf{x}_i)$  和惩罚因子  $C$  直接影响着 SVM 的分类性能, RBF 核函数的表达式可以由式(16)所示。

$$K(\mathbf{x}, \mathbf{x}_i) = \exp(-g \|\mathbf{x} - \mathbf{x}_i\|^2), g > 0 \quad (16)$$

式中:  $g$  为自由参数。

### 2.2 EBWO 优化 SVM 故障诊断模型

为了提高 SVM 在变压器故障诊断中的分类性能,以

EBWO算法对其进行优化,EBWO优化SVM的主要步骤如下:

1)将数据的80%作为训练集,其余的20%作为测试集,并对数据进行预处理操作。

2)初始化模型的参数,将白鲸种群个数设置为20,最大迭代次数设置为50,核函数参数 $g$ 的寻优范围设置为 $[0.01,100]$ ,惩罚因子 $C$ 的寻优范围设置为 $[0.01,1000]$ 。

3)利用准反向学习策略和CFS策略对BWO算法进行优化,然后利用改进的BWO算法对SVM的核函数参数 $g$ 和惩罚因子 $C$ 进行寻优。

4)模型进行循环迭代,直至达到最大循环次数,将最优参数输出至SVM中,从而得到最优模型。

基于EBWO-SVM的故障诊断流程如图3所示。

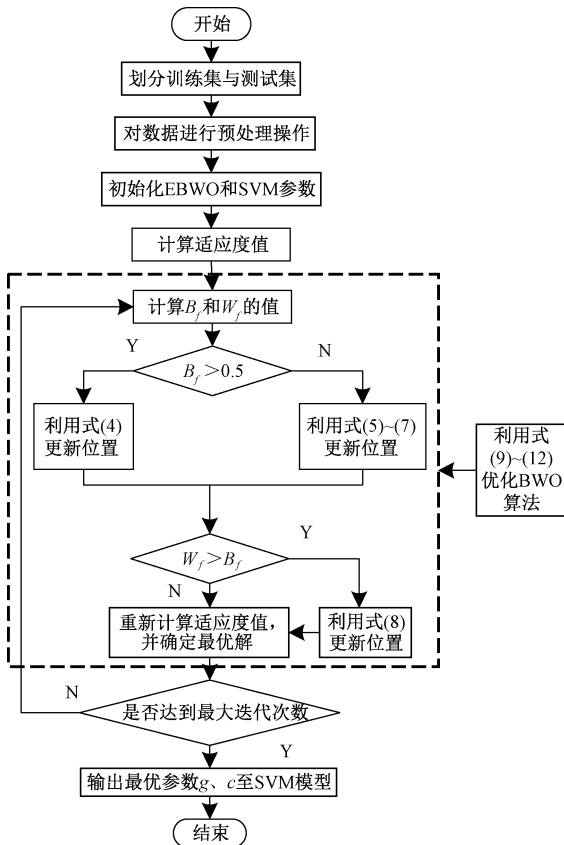


图3 EBWO-SVM流程图

### 3 数据处理

不同的 $H_2$ 、 $CH_4$ 、 $C_2H_6$ 、 $C_2H_4$ 、 $C_2H_2$ 含量及比值对应着不同的变压器故障类型,因此本文以这5种气体作为特征输入。由于各气体含量比较分散,因此在实验前利用min-max归一化法对数据进行预处理,预处理的公式如式(17)所示。

$$y' = \frac{y - y_{\min}}{y_{\max} - y_{\min}} \quad (17)$$

式中: $y'$ 为归一化后的数据, $y$ 为归一化前的数据, $y_{\max}$ 的

值为1, $y_{\min}$ 的值为0。

本文数据集来源于文献[19],一共有260组油气数据,并将变压器故障划分为低能放电、高能放电、局部放电、中低温过热、高温过热和正常6种类型。为了便于在Matlab中做仿真实验,将6种故障类型以数字的形式表达,其中数据划分和编码如表2所示,部分故障数据如表3所示。

表2 数据划分及编码

故障类型	训练集个数	测试集个数	编码
中低温过热	36	9	1
高温过热	36	9	2
低能放电	36	9	3
高能放电	36	9	4
局部放电	36	9	5
正常	28	7	6

表3 部分故障数据

	体积分数/ $(\mu L \cdot L^{-1})$					故障类型
	$H_2$	$CH_4$	$C_2H_6$	$C_2H_4$	$C_2H_2$	
23	11.8	3	0.6	0	0	中低温过热(1)
95	110	160	50	0	0	中低温过热(1)
115	332	104	604	2.9	0	高温过热(2)
12	23	9	98	0	0	高温过热(2)
4.1	3.5	0.68	1.2	5.2	0	低能放电(3)
49.1	12.2	0.3	3.9	4.8	0	低能放电(3)
200	48	14	117	131	0	高能放电(4)
32.4	5.5	1.4	12.6	13.6	0	高能放电(4)
980	73	58	12	0	0	局部放电(5)
654	55	34	20	0	0	局部放电(5)
46	11.6	33.1	8.5	0.6	0	正常(6)
39	24.5	18.4	11.4	6	0	正常(6)

### 4 算例分析

为了提高SVM在变压器故障诊断中的性能,利用EBWO算法对其进行优化。本文实验均在MATLAB2022b中进行,实验平台搭建为Windows11系统、13th Gen Intel(R) Core(TM) i5-13400F处理器和NVIDIA GeForce GTX1660 Ti显卡。

为了验证EBWO-SVM模型的可行性,将PSO-SVM、GWO-SVM、WOA-SVM、BWO-SVM模型做对比实验,其中PSO-SVM、GWO-SVM、WOA-SVM、BWO-SVM模型的参数设置如下:PSO、GWO、WOA和BWO的种群数量均设置为20,最大迭代次数均设置为50, $g$ 的寻优区间均设置为 $[0.01,100]$ , $C$ 的寻优区间均设置为 $[0.01,1000]$ 。图4~8分别为各模型的故障诊断结果,表4为各方法在不同故障类型上的诊断正确率。




图 4 EBWO-SVM 诊断结果图




图 7 GWO-SVM 诊断结果图




图 5 BWO-SVM 诊断结果图




图 8 PSO-SVM 诊断结果图




图 6 WOA-SVM 诊断结果图

表 4 各方法在不同故障类型上的诊断精度

故障类型	诊断精度/%				
	EBWO-SVM	BWO-SVM	WOA-SVM	GWO-SVM	PSO-SVM
中低温过热	100	100	88.9	77.8	88.9
高温过热	100	100	100	77.8	88.9
低能放电	100	100	77.8	100	66.7
高能放电	88.9	66.7	66.7	77.8	77.8
局部放电	100	77.8	100	100	77.8
正常	100	100	100	85.7	100
综合诊断精度	98.1	90.4	88.4	86.5	82.7

结合图 4~8 和表 4 的诊断结果可知,在 52 组测试样本中,EBWO-SVM 模型只有 1 组诊断错误,综合诊断精度为 98.1%;BWO-SVM 模型只有 5 组诊断错误,综合诊断精度为 90.4%;WOA-SVM 模型有 6 组诊断错误,综合诊断精度为 88.4%;GWO-SVM 模型有 7 组诊断错误,综合

诊断精度为 86.5%;PSO-SVM 模型有 9 组诊断错误,综合诊断精度为 82.7%,其中 EBWO-SVM 模型的综合诊断精度相比于 BWO-SVM、WOA-SVM、GWO-SVM、PSO-SVM 模型分别提高了 7.7%、9.7%、11.6%、15.4%,且 EBWO-SVM 模型在每个故障类型上的诊断精度都有着明显的优势,说明 EBWO 算法能够有效提高 SVM 的分类能力。

稳定性是评价一个模型的重要指标,因此这里将 EBWO-SVM、BWO-SVM、WOA-SVM、GWO-SVM 和

PSO-SVM模型分别进行15次实验,并记录下每次实验的诊断精度,图9为15次实验中各模型的诊断结果图,表5为15次实验中各模型诊断精度的方差。

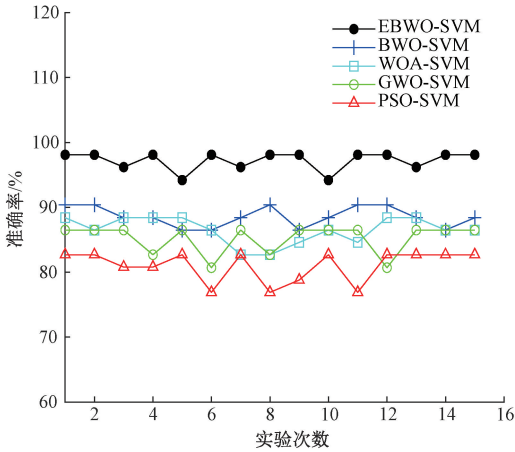


图9 15次实验各模型的诊断结果图

表5 多次实验各方法的诊断精度及方差

模型	诊断精度/%			方差
	最大	最小	平均	
EBWO-SVM	98.1	94.2	97.2	2.08
BWO-SVM	90.4	86.5	88.6	2.43
WOA-SVM	88.4	82.7	86.5	4.13
GWO-SVM	86.5	80.7	85.2	5.11
PSO-SVM	82.7	76.9	81.0	5.81

结合图9和表5的结果可得知,EBWO-SVM模型的诊断精度方差相比于其他模型更小,说明EBWO-SVM有着更好的稳定性,诊断效果更好。

## 5 结论

为了解决SVM用于变压器故障诊断时存在着核函数参数 $g$ 和惩罚因子 $C$ 难以寻优而导致诊断精度不高的问题,提出一种基于EBWO-SVM的故障诊断模型,通过实验得到结论如下:利用准反向学习策略和旋风式觅食策略能够很好的提高BWO的性能,通过6种测试函数得出EBWO算法有着更快的收敛速度和更好的寻优性能;EBWO算法能够有效提高SVM的分类性能,EBWO-SVM模型相比于BWO-SVM、WOA-SVM、GWO-SVM、PSO-SVM模型有着更高的诊断精度和更好的稳定性,说明EBWO-SVM模型能够有效进行变压器的故障诊断研究。但是本文模型的训练时间较长,因此下一步的研究是在保证精度和稳定性的前提下,缩短模型的训练时间。

## 参考文献

[1] 陈铁,陈卫东,李咸善,等.基于油中溶解气体分析的变压器故障预测[J].电子测量技术,2021,44(22):25-31.  
 [2] 肖云波,范菁,张宜,等.基于改进粒子群算法与油中溶解气体的变压器故障诊断的研究[J].电子测量技术,

2021,44(18):122-128.

- [3] 欧阳鑫,李志斌.基于样本扩充和特征优选的IGWO优化SVM的变压器故障诊断技术[J].电力系统保护与控制,2023,51(18):11-20.  
 [4] 李元,李星辉,孙渭薇,等.基于多模型级联的油浸式电力变压器故障诊断方法[J].智慧电力,2023,51(6):86-92.  
 [5] 徐耀松,包力铭,管智峰,等.基于IPPA优化PNN的变压器故障诊断研究[J].电子测量与仪器学报,2022,36(10):138-145.  
 [6] 汤茂祥,王聪,朱超平,等.少标签下油浸式变压器双层故障诊断模型[J].电子测量技术,2023,46(16):112-118.  
 [7] 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.  
 [8] 陈铁,陈一夫,李咸善,等.基于SDS-SSA-LSTM的变压器油中溶解气体浓度预测[J].电子测量技术,2022,45(12):6-11.  
 [9] 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.  
 [10] 周晓华,冯雨辰,胡旭初,等.基于秃鹰搜索算法优化SVM的变压器故障诊断[J].南方电网技术,2023,17(6):99-106,116.  
 [11] 何宇辉,丁培,马飞越,等.基于优化极限学习机的变压器故障诊断方法研究[J].电子器件,2021,44(4):897-902.  
 [12] 李平,胡根铭.基于改进神经网络与比值法融合的变压器故障诊断方法[J].高电压技术,2023,49(9):3898-3906.  
 [13] 咸日常,范慧芳,李飞,等.基于改进GSA-SVM模型的电力变压器故障诊断[J].智慧电力,2022,50(6):50-56.  
 [14] 冯志亮,肖涵麒,任文凤,等.基于主成分分析的海鸥优化支持向量机变压器故障诊断[J].中国测试,2023,49(2):99-105.  
 [15] 李俊,冯俊杰,武文吉,等.基于改进萤火虫算法和多元支持向量机的变压器故障诊断[J].电测与仪表,2022,59(3):131-135.  
 [16] 王亚辉,张虎晨,王学兵,等.基于混沌反向学习和水波算法改进的白鲸优化算法[J].计算机应用研究,2024,41(3):729-735.  
 [17] 陈曦明,张军伟.融合FDB策略和切线飞行的改进白鲸优化算法[J].计算机时代,2023(11):46-51.  
 [18] ZHONG C T, LI G, MENG Z. Beluga whale optimization: A novel nature-inspired metaheuristic algorithm[J]. Knowledge-Based Systems,2022,251.  
 [19] 田晓飞.基于改进蝙蝠算法优化支持向量机的变压器故障诊断研究[D].成都:西华大学,2019.

## 作者简介

汪繁荣,博士,主要研究方向为电网控制与智能制造方向。

E-mail:wfr@whu.edu.cn

李州(通信作者),硕士研究生,主要研究方向为故障诊断。

E-mail:1099946458@qq.com