

基于 SCSSA-BiLSTM 的变压器故障诊断模型

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: 针对变压器故障诊断存在诊断精度不高和麻雀搜索算法(sparrow search algorithm, SSA)存在易陷入局部最优的问题, 提出了一种基于融合正余弦和柯西变异的麻雀搜索算法(sine-cosine and Cauchy mutation sparrow search algorithm, SCSSA)优化双向长短期记忆网络(bi-directional long-short term memory, BiLSTM)的变压器故障诊断模型。首先, 基于油中溶解气体分析(dissolved gas analysis, DGA)法, 以 5 种特征量作为输入, 其次利用正余弦策略和柯西变异策略对麻雀算法进行改进, 然后将 SCSSA 算法、SSA 算法和灰狼优化算法(grey wolf optimizer, GWO)在 4 种测试函数上进行性能对比, 验证了 SCSSA 算法的优越性。最后利用 SCSSA 算法对 BiLSTM 网络中的参数进行优化, 从而提高 BiLSTM 网络在变压器故障诊断中的性能。实验结果表明, 所提 SCSSA-BiLSTM 故障诊断模型的综合诊断精度为 95.1 %, 相比于 SSA-BiLSTM、GWO-BiLSTM、BiLSTM 和 LSTM 模型分别提高了 7.3 %、12.2 %、14.6 %、19.5 %, 并且 SCSSA-BiLSTM 模型有着更好的鲁棒性。

关键词: 变压器; 故障诊断; 麻雀搜索算法; 双向长短期记忆网络; 诊断精度

Transformer Fault Diagnosis Model Based on SCSSA-BiLSTM

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 and easy to fall into local optimization of sparrow search algorithm (SSA) for transformer fault diagnosis, a transformer fault diagnosis model is proposed based on the optimized by sine-cosine and Cauchy mutation sparrow search algorithm (SCSSA). Firstly, based on the dissolved gas analysis (DGA) method in oil, five feature quantities are used as inputs. Secondly, the sparrow algorithm is improved by using the positive cosine strategy and Cauchy variation strategy, and then the performance of SCSSA algorithm, SSA algorithm and grey wolf optimizer (GWO) are compared on four kinds of test functions for performance comparison and verified the superiority of SCSSA algorithm. Finally, SCSSA algorithm is used to optimize the parameters in the BiLSTM network, so as to improve the performance of BiLSTM network in transformer fault diagnosis. The experimental results show that the proposed SCSSA-BiLSTM fault diagnosis model has an integrated diagnostic accuracy of 95.1 %, which is 7.3 %, 12.2 %, 14.6 %, and 19.5 % higher than the SSA-BiLSTM, GWO-BiLSTM, BiLSTM, and LSTM models, respectively, and the SCSSA-BiLSTM model has better robustness.

Key words: transformer; fault diagnosis; sparrow search algorithm; bi-directional long-short term memory networks; diagnostic accuracy

0 引言

作为电网中最重要的设备之一, 变压器承担着转换和传输电能的任务^[1-2]。当变压器发生故障时, 不仅会造成经济损失, 甚至会发生安全事故。因此

对变压器的运行状态进行实时监测、建立精准稳定的变压器故障诊断模型有着重要意义^[3-5]。

目前输配电系统大多用的是油浸式变压器, 当这类变压器发生故障时, 其内部的绝缘材料会分解产生氢气(H_2)、甲烷(CH_4)、乙炔(C_2H_2)、乙烯(C_2H_4)和乙烷(C_2H_6)等气体^[6-7]。这些气体的含量与变压器故障类型之间的关系十分复杂, 因此油中溶解气体分析(dissolved gas analysis, DGA)法成为变压器故障诊断的有效方法^[8-10], 但是传统的 DGA

基金项目: 国家自然科学基金资助项目(61903129)。

Foundation item: Supported by the National Natural Science Foundation of China (61903129).

方法还存在着编码不全和依赖于专家经验等缺陷^[11]。因此,学者们开始利用人工智能技术^[12]进行研究,这些智能方法可分为支持向量机(support vector machines, SVM)、极限学习机(extreme learning machine, ELM)和神经网络等。文献[13]利用改进神经网络与三比值法结合进行研究,将被网络错误分类的样本转化为传统比值法进行诊断,从而提高了诊断性能,但神经网络需要大量的数据,训练时间长且稳定性不好。文献[14]提出一种改进ELM结合动态加权AdaBoost的变压器故障诊断方法,提高了ELM在故障诊断中的诊断精度,但是ELM的训练速度较慢,易陷入局部最小值。文献[15]利用秃鹰算法对SVM的核函数参数 g 和 c 进行优化,提高了SVM的诊断性能,但SVM对核函数参数较为敏感,计算复杂度较高。深度学习有强大的学习能力和适应性,适于解决复杂的变压器故障诊断问题,其中双向长短期记忆网络(bi-directional long-short term memory, BiLSTM)能够同时考虑过去和未来的信息,有很强的稳定性,但是BiLSTM网络的参数较为复杂,合适的参数设置能够有效提高BiLSTM网络在变压器故障诊断中的性能,因此如何快速准确找到BiLSTM网络的最优超参数组合是当前变压器故障诊断中的热点问题。人工进行参数寻优会消耗大量的时间和精力,因此学者们开始利用智能算法对BiLSTM网络的参数进行优化,文献[16]将MAML元学习算法与BiLSTM网络结合进行研究,得到了较好的准确度,但是BiLSTM网络随机产生的超参数增加了模型的不稳定性;文献[17]利用粒子群算法对BiLSTM网络的超参数进行寻优,提高了模型的诊断精度和鲁棒性,但是所提方法容易陷入局部最优。

针对以上问题,提出了一种基于SCSSA-BiLSTM的变压器故障诊断模型。首先利用正余弦策略和柯西变异策略对麻雀搜索算法进行改进,然后通过改进麻雀算法(sine-cosine and Cauchy mutation sparrow search algorithm, SCSSA)优化BiLSTM的超参数,从而提高BiLSTM的诊断性能;最后将SSA-BiLSTM、GWO-BiLSTM、BiLSTM、LSTM模型与SCSSA-BiLSTM模型做对比实验,验证了SCSSA-BiLSTM模型的可行性。

1 麻雀搜索算法

麻雀搜索算法(sparrow search algorithm, SSA)是2020年提出的一种新型群体智能优化算法^[18-19],主要通过模拟麻雀的觅食和反捕食行为实现优化过程。SSA具有收敛速度快和寻优能力强的优点,根据觅食能力的强弱,该算法将麻雀种群分为发现者和加入者,并按一定比例选择麻雀个体成为警戒者。

1) 发现者

发现者拥有更大的觅食搜索范围,主要负责为种群寻找食物并为加入者提供觅食的方向。发现者的位置更新如式(1)所示。

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot \exp(-\frac{i}{a \cdot i_{\max}}), R_2 < S_T \\ X_{i,j}^t + Q \cdot L, R_2 \geq S_T \end{cases} \quad (1)$$

式中: $X_{i,j}^{t+1}$ 为第 $t+1$ 次迭代中第 i 只麻雀位于第 j 维的位置; $a \in [0, 1]$; R_2 为种群的警戒值; S_T 为安全值; Q 为随机数且服从正态分布; L 为一个 $1 \times d$ 的矩阵且元素均为1; $i_{\max}$ 为最大迭代数量。

2) 加入者

加入者的任务是跟随发现者进行觅食,加入者的位置更新如式(2)所示。

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

式中: X_p^{t+1} 为第 $t+1$ 次迭代中发现者的最优位置; X_{worst}^t 为最差位置; A 代表元素为1或-1的 $1 \times d$ 的矩阵,并且 $A^+ = A^T(AA^T)^{-1}$,当 $i > n/2$ 时,第 i 个加入者会飞往其他地方进行觅食; n 为种群规模。

3) 警戒者

警戒者负责规避风险和进行反捕食行为,警戒者的位置更新如式(3)所示。

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

式中: X_{best}^t 为当前的最优位置; β 为步长控制参数; K 为-1~1之间的随机数; ε 为避免分母出现0的极小值; f_i 为第 i 只麻雀的适应度值; f_g 为最优的适应度值; f_w 为当前最差的适应度值。

1.1 SCSSA 算法

SSA 算法简单高效且易于实现,可以在变压器故障诊断问题中得到良好的应用,但是 SSA 算法还存在着易陷入局部最优和全局搜索能力不足的问题,为了解决这个问题,利用正余弦策略和柯西变异策略对 SSA 算法进行改进,从而提高 SSA 算法的性能^[20]。

1) 正余弦策略

基本正余弦算法的步长搜索因子呈线性递减的趋势,这种趋势会影响 SSA 算法全局搜索能力和局部开发能力的平衡,因此优化算法的步长搜索因子尤为重要,优化过程如式(4)所示。

$$r'_1 = a \times (1 - (\frac{t}{T_{\max}})^{\eta})^{1/\eta} \quad (4)$$

式中: $T_{\max}$ 为最大迭代数量; r'_1 为优化后的搜索因子; t 为目前迭代数量; η 为调节系数,且 $\eta \geq 1$, $a=1$ 。

麻雀种群个体在搜索过程中的位置更新会经常受到当前位置的影响,因此提出非线性权重因子(ω)来调整麻雀种群位置更新对此时个体信息的依赖度, ω 在寻优前期使得种群个体位置更新对当前解位置的影响减少,这提高了 SSA 算法的全局搜索能力, ω 在寻优后期利用当前位置信息与个体位置更新的高度依赖性,使得 SSA 算法的收敛速度加快。新的发现者位置更新可由式(5)表示,非线性权重因子 ω 的表达式如式(6)表示。

$$X_{i,j}^{t+1} = \begin{cases} \omega \cdot X_{i,j}^t + r'_1 \cdot \sin r_2 \cdot |r_3 \cdot X_{\text{best}}^t - X_{i,j}^t|, R_2 < S_T \\ \omega \cdot X_{i,j}^t + r'_1 \cdot \cos r_2 \cdot |r_3 \cdot X_{\text{best}}^t - X_{i,j}^t|, R_2 \geq S_T \end{cases} \quad (5)$$

$$\omega = \frac{e^{\frac{t}{T_{\max}}} - 1}{e - 1} \quad (6)$$

式中 r_2 和 r_3 均为 $0 \sim 2\pi$ 之间的随机数, r_2 决定麻雀的移动距离, r_3 为最优位置对下一位置的影响。

2) 柯西变异策略

在寻觅食物的过程中,加入者会跟随在发现者的周围,一旦种群之间发现食物,加入者就可能会和发现者抢夺食物,从而使得加入者变成发现者。为了避免麻雀搜索算法陷入局部最优,将柯西变异策略引入到加入者的位置更新中,从而让算法的全局搜索能力得到加强,新的加入者的位置更新如式(7)所示。

$$X_{i,j}^{t+1} = X_{\text{best}}^t + \text{cauchy}(0, 1) \oplus X_{i,j}^t(t) \quad (7)$$

式中: $\text{cauchy}(0, 1)$ 为标准柯西分布函数; $\oplus$ 为相乘函数。

1.2 SCSSA 算法性能验证

为了对 SCSSA 算法进行性能验证,这里将 SCSSA 算法和 SSA 算法、GWO 算法在 4 种测试函数上做对比实验,其中 f_1 、 f_2 、 f_3 为单峰函数, f_4 为多峰函数,每个测试函数的维度均设置为 30,最大迭代次数均设置为 300,表 1 为 4 种测试函数的数学表达式及相关参数设置,图 1 为各算法在不同测试函数上的寻优曲线。

表 1 4 种测试函数的数学表达式及相关参数设置

Tab. 1 Mathematical expressions for the 4 kinds of test functions and related parameter settings

测试函数	寻优范围	最优解
$f_1(x) = \sum_{i=1}^{30} x_i^2$	$[-100, 100]$	0
$f_2(x) = \sum_{i=1}^{30} (\sum_{j=1}^i x_j)^2$	$[-100, 100]$	0
$f_3(x) = \max_i \{ x_i , 1 \leq i \leq 30 \}$	$[-100, 100]$	0
$f_4(x) = -20 \exp(-0.2 \sqrt{\frac{1}{30} \sum_{i=1}^{30} x_i^2}) - \exp(\frac{1}{30} \sum_{i=1}^{30} \cos 2\pi x_i) + 20 + e$	$[-32, 32]$	0

由图 1 可以看出,在寻优范围内 SCSSA 算法相比于麻雀搜索算法和灰狼优化算法在 4 种测试函数上能够更快地接近最优解,说明 SCSSA 算法有着更好的寻优性能

2 SCSSA-BiLSTM

2.1 BiLSTM 网络

长短期记忆(long short-term memory, LSTM)网络是一种时间递归神经网络,由于其特殊的结构,不仅解决了梯度爆炸的问题,还缓解了长期依赖性问题^[21]。LSTM 的结构如图 2 所示。

由图 2 可知, LSTM 主要由输入门、遗忘门和输出门组成。输入门主要通过 sigmoid 函数与 tanh 层更新细胞状态,控制当前的输入信息是否应被记忆单元所接受,此过程可由式(8)表示。

$$\begin{cases} i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\ C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \end{cases} \quad (8)$$

式中: i_t 为输入门的输出; σ 为 sigmoid 函数; W_i 为




图1 各算法在不同测试函数上的寻优曲线

Fig. 1 Optimisation curves for each algorithm on different test functions




图2 LSTM结构图

Fig. 2 Structural diagram of LSTM

输入门权重矩阵, W_c 为细胞状态权重矩阵; x_t 为输入向量; b_i 为输入门偏置; b_c 为细胞状态偏置; C_t 为记忆单元的输出; $\tilde{C}_t$ 为 $\tanh$ 函数的输出; h_{t-1} 为上一时刻的输出状态; f_t 为遗忘门输出; * 为元素

级乘法。

信息的保留或丢弃由遗忘门决定, 这个过程可以决定变压器故障特征信息的通过量, 从而过滤掉没用的信息, 此过程可由式(9)表示。

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (9)$$

式中: f_t 为遗忘门的输出; b_f 为遗忘门的偏置向量, W_f 为遗忘门的权重矩阵。

输出门确定输出值, 前面的输入信息包含于隐藏状态中, 下一隐藏状态的值由输出门确定, 输出门的表达式如式(10)所示。

$$\begin{cases} o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \\ h_t = o_t * \tanh(C_t) \end{cases} \quad (10)$$

式中: o_t 为输出门的输出; W_o 为输出门的权重矩阵。

BiLSTM 网络不仅拥有 LSTM 网络的所有优点,

并且运行时间更短、准确性更高, BiLSTM 网络的结构图如图 3 所示。




图 3 BiLSTM 结构图

Fig. 3 Structural diagram of BiLSTM

由图 3 可知, BiLSTM 由前向 LSTM 和反向 LSTM 组成, BiLSTM 网络的更新方程可由式(11)表示。

$$\begin{cases} h_t^1 = \text{LSTM}(x_t, h_{t-1}^1) \\ h_t^2 = \text{LSTM}(x_t, h_{t-1}^2) \\ y_t = W_{hy}^1 h_t^1 + W_{hy}^2 h_t^2 + b_y \end{cases} \quad (11)$$

式中: h_t^1 为前向 LSTM 的输出; h_t^2 为反向 LSTM 的输出; y_t 为 BiLSTM 的输出; W_{hy}^1 和 W_{hy}^2 为输出层连接权重矩阵; b_y 为 BiLSTM 的偏置。

2.2 SCSSA-BiLSTM 诊断模型

为提高 BiLSTM 网络的诊断性能, 利用 SCSSA 算法对 BiLSTM 的参数进行优化, 本文优化的参数为学习率、隐含单元数量及正则化参数。SCSSA-BiLSTM 模型的诊断流程图如图 4 所示。

SCSSA 算法优化 BiLSTM 网络的诊断流程由以下几步组成。

1) 将数据划分为训练集和测试集, 并对这些数据进行预处理。

2) 初始化 SSA 算法和 BiLSTM 网络的参数, 将麻雀种群设置为 10, 最大迭代次数设置为 20, 学习率的寻优范围设置为 $[0.001, 0.1]$, 隐含单元数量的寻优范围设置为 $[1, 100]$, 正则化参数的寻优范围设置为 $[10^{-1}, 10^{-5}]$, 并在 BiLSTM 网络的末尾加上一层随机丢失层, 以防止模型出现过拟合, 随机丢失层的丢失率设置 0.15。

3) 利用正余弦策略和柯西变异策略对 SSA 算法进行改进, 利用改进后的 SSA 算法对 BiLSTM 网络的参数进行优化。




图 4 SCSSA-BiLSTM 模型诊断流程图

Fig. 4 Diagnostic flowchart of the SCSSA-BiLSTM model

4) 当模型达到最大迭代次数时, 输出获得的最优参数, 将这些参数导入到 BiLSTM 中进行训练, 从而获得最优的 BiLSTM 模型。

3 数据介绍及处理

根据变压器的故障性质, 可将其分为热性故障和电性故障^[22-23], 其中热性故障可分为中低温过热和高温过热; 电性故障分为低能放电、高能放电和局部放电^[24-25]。正常的数据记录也十分重要, 因此将正常情况作为模型的一个输入记录。本文从文献[26-28]中收集到 273 组数据, 将其中 70 % 的数据作为训练集, 30 % 的数据作为测试集, 同时将故障类型以数字的形式表达, 数据分布和故障编号如表 2 所示。

由于气体含量的分布较为分散, 因此本文使用 min-max 归一化法对数据进行处理, min-max 法的表达式如式(12)所示。

$$Z' = \frac{Z - Z_{\min}}{Z_{\max} - Z_{\min}} \quad (12)$$

式中: Z' 为归一化的数据; Z 为原始数据; $Z_{\max}$ 为数据的最大值; $Z_{\min}$ 为数据的最小值。

表 2 数据分布及编号			
Tab. 2 Distribution and numbering of the data			
故障类型	训练集	测试集	编号
中低温过热	31	14	1
高温过热	41	18	2
低能放电	26	11	3
高能放电	40	17	4
局部放电	25	10	5
正常	28	12	6

4 算例分析

将 5 种气体(H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2)作为特征输入进行研究, 为验证 SCSSA-BiLSTM 模型在变压器故障诊断中的有效性与可行性, 利用 SSA-BiLSTM、GWO-BiLSTM、BiLSTM 和 LSTM 模型做对比实验, 经过多次调试得到各模型的最优参数设置如下: SSA 算法和 GWO 算法的种群均设置为 5, 最大迭代次数均设置为 10, BiLSTM 网络的隐藏层单元数量设置为 80, 学习率设置为 0.01, LSTM 网络的隐藏层数量设置为 5 层, 学习率设置为 0.05。图 5—9 分别为各模型的诊断结果, 表 3 为各模型在不同故障类型上的诊断精度。




图 5 SCSSA-BiLSTM 模型诊断结果

Fig. 5 Diagnostic results of SCSSA-BiLSTM model

由图 5—9 和表 3 可知, SCSSA-BiLSTM 模型对中低温过热、高温过热、低能放电、高能放电和局部放电诊断效果最好, 对正常诊断效果不佳, 但是 SCSSA-BiLSTM 模型的综合诊断精度最好, 在 82 组测试样本中, SCSSA-BiLSTM 模型诊断正确组数为 78 组, 综合诊断达到了 95.1 %。SSA-BiLSTM




图 6 SSA-BiLSTM 模型诊断结果

Fig. 6 Diagnostic results of SSA-BiLSTM model




图 7 GWO-BiLSTM 模型诊断结果

Fig. 7 Diagnostic results of GWO-BiLSTM model




图 8 BiLSTM 模型诊断结果

Fig. 8 Diagnostic results of BiLSTM model




图9 LSTM模型诊断结果
Fig. 9 Diagnostic results of LSTM model

表3 各模型在不同故障类型上的诊断精度
Tab. 3 Diagnostic accuracies of various models on different faults types %

类型	诊断精度				
	SCSSA-BiLSTM	SSA-BiLSTM	GWO-BiLSTM	Bi-LSTM	LSTM
中低温过热	92.9	78.6	85.7	71.4	85.7
高温过热	100.0	100.0	94.4	94.4	100.0
低能放电	100.0	72.7	63.6	72.7	36.4
高能放电	94.1	82.4	64.7	70.6	58.5
局部放电	100.0	100.0	90.0	70.0	70.0
正常	83.3	91.7	100.0	100.0	91.7
综合诊断精度	95.1	87.8	82.9	80.5	75.6

模型诊断正确组数量为72组，综合诊断精度为87.8%。GWO-BiLSTM模型诊断正确组数量为68组，综合诊断精度为82.9%。BiLSTM模型诊断正确组数量为66组，综合诊断精度为80.5%。LSTM模型诊断正确组数量为62组，综合诊断精度为75.6%。其中SCSSA-BiLSTM模型的综合诊断精度相比于SSA-BiLSTM、GWO-BiLSTM、BiLSTM和LSTM模型分别提高了7.3%、12.2%、14.6%、19.5%，说明SCSSA算法能够有效提高BiLSTM网络的故障诊断精度。

鲁棒性是评价模型性能的一个重要指标，是指模型受到扰动后系统仍能保持先前的稳定性和有效性。目前验证鲁棒性的主流方向有3种，分别为修改模型的输入数据、修改模型结构和添加外部模块。本文以第1种方法验证所提模型的鲁棒性，这里将数据集10%的数据进行修改，通过5种气体含

量均置0的方式模拟此情况，修改输入数据对模型诊断精度的影响如表4所示。

表4 修改输入数据对模型诊断精度的影响
Tab. 4 Effects of modifying input data on model diagnostic accuracies %

模型	诊断精度		下降百分比
	正常	修改数据	
SCSSA-BiLSTM	95.1	89.0	6.1
SSA-BiLSTM	87.8	76.8	11.0
GWO-BiLSTM	82.9	75.6	7.3
BiLSTM	80.5	70.7	9.8
LSTM	75.6	64.6	11.0

由表4可知，当修改输入数据时，SCSSA-BiLSTM、SSA-BiLSTM、GWO-BiLSTM、BiLSTM和LSTM模型的诊断精度分别下降了6.1%、11.0%、7.3%、9.8%和11.0%，其中SCSSA-BiLSTM模型的诊断精度下降最少，说明SCSSA-BiLSTM模型有着更强的鲁棒性。

5 结论

为了提高BiLSTM网络在变压器故障诊断中的性能，提出了一种基于SCSSA-BiLSTM的变压器故障诊断模型，主要结论如下。

1)通过引入正余弦策略和柯西变异策略对SSA算法进行改进，能够有效提高算法的收敛速度和全局搜索能力，相比于SSA算法和GWO算法，SCSSA算法具有更好的寻优性能。

2)利用SCSSA算法能有效提高BiLSTM网络在变压器故障诊断中的性能，通过实验结果可知，SCSSA-BiLSTM诊断模型有着最好的诊断性能，与SSA-BiLSTM、GWO-BiLSTM、BiLSTM和LSTM模型相比，综合诊断精度分别提高了7.3%、12.2%、14.6%、19.5%。当修改输入数据时，SCSSA-BiLSTM模型的诊断精度下降最少，说明所提模型有着较强的鲁棒性，适用于变压器的故障诊断研究。

但本文模型训练时间较长，因此下一步的研究是在保证精度和鲁棒性的前提下缩短模型的训练时间。

参考文献

[1] 廖才波, 杨金鑫, 胡雄, 等. 基于油中溶解气体特征量筛选的

- 变压器故障诊断方法[J]. 电力工程技术, 2024, 43(1):192-200.
- LIAO Caibo, YANG Jinxin, HU Xiong, et al. Fault diagnosis method for transformers based on feature selection of dissolved gas in oil[J]. Electric Power Engineering Technology, 2024, 43(1):192-200.
- [2] 李佰霖, 陈昱锐, 褚凡武, 等. 基于混合采样和CAWOA-BP的变压器故障诊断[J]. 水电能源科学, 2024, 42(3):216-220.
- LI Baolin, CHEN Yurui, CHU Fanwu, et al. Transformer fault diagnosis based on hybrid sampling and CAWOA-BP[J]. Water Resources and Power, 2024, 42(3):216-220.
- [3] 李雷军, 吴超, 付华, 等. 基于油中溶解气体分析的ISSA优化LSSVM变压器故障诊断研究[J]. 电工电能新技术, 2023, 42(10):84-94.
- LI Leijun, WU Chao, FU Hua, et al. Research on transformer fault diagnosis based on analysis of dissolved gas in oil of ISSA-LSSVM[J]. Advanced Technology of Electrical Engineering, 2023, 42(10):84-94.
- [4] 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.
- OUYANG Xin, LI Zhibing. Transformer fault diagnosis technology based on sample expansion and feature selection and SVM optimized by IGWO[J]. Power System Protection and Control, 2023, 51(18):11-20.
- [5] 郑业爽, 李世春, 鲁玲. 基于多策略ISOA优化SVM的变压器故障诊断研究[J]. 智慧电力, 2023, 51(2):38-44.
- ZHENG Yeshuang, LI Shichun, LU Ling. Transformer fault diagnosis based on multi-strategy ISOA optimized SVM[J]. Smart Power, 2023, 51(2):38-44.
- [6] 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.
- XU Yaosong, BAO Liming, GUAN Zhifeng, et al. Research on transformer fault diagnosis based on IPPA optimization PNN[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(10):138-145.
- [7] 霍浩, 马天龙, 李宁瑞, 等. 基于贝叶斯与深度学习结合的变压器故障诊断[J]. 电力系统及其自动化学报, 2023, 35(9):137-144.
- HUO Hao, MA Tianlong, LI Ningrui, et al. Transformer fault diagnosis based on Bayesian method and deep learning[J]. Proceedings of the CSU-EPSA, 2023, 35(9):137-144.
- [8] 张国治, 陈康, 方荣行, 等. 基于DGA与鲸鱼算法优化Logit Boost-决策树的变压器故障诊断方法[J]. 电力系统保护与控制, 2023, 51(7):63-72.
- ZHANG Guozhi, CHEN Kang, FANG Rongxing, et al. Transformer fault diagnosis based on DGA and a whale algorithm optimizing a Logit Boost-decision tree[J]. Power System Protection and Control, 2023, 51(7):63-72.
- [9] 戚日常, 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.
- XIAN Richang, FAN Huifang, LI Fei, et al. Power transformer fault diagnosis based on improved GSA-SVM Model[J]. Smart Power, 2022, 50(6):50-56.
- [10] 田双双, 李哲, 张晓星, 等. $C_6F_{12}O$ 与 CO_2/N_2 对变压器油分解气体火焰及HF的抑制作用[J]. 南方电网技术, 2024, 18(4):96-105.
- TIAN Shuangshuang, LI Zhe, ZHANG Xiaoxing, et al. Inhibition effect of $C_6F_{12}O$ and CO_2/N_2 on transformer oil decomposition gas flame and HF[J]. Southern Power System Technology, 2024, 18(4):96-105.
- [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 the improved bald eagle search algorithm[J]. Power System Protection and Control, 2023, 51(8):118-126.
- [12] 陈艺璇, 王嘉阳, 卓映君, 等. 人工智能在电力系统运行模拟加速中的应用综述[J]. 发电技术, 2025, 46(3):467-481.
- CHEN Yixuan, WANG Jiayang, ZHUO Yingjun, et al. Review of artificial intelligence applications in accelerating operational simulation of power systems[J]. Power Generation Technology, 2025, 46(3):467-481.
- [13] 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.
- LI Ping, HU Genming. Transformer fault diagnosis method based on the fusion of improved neural network and ratio method[J]. High Voltage Engineering, 2023, 49(9):3898-3906.
- [14] 黄新波, 王享, 田毅, 等. 基于PSO-ELM融合动态加权AdaBoost的变压器故障诊断方法[J]. 高压电器, 2020, 56(5):39-46.
- HUANG Xinbo, WANG Xiang, TIAN Yi, et al. Transformer fault diagnosis algorithm based on PSO-ELM fusion dynamically weighted AdaBoost[J]. High Voltage Apparatus, 2020, 56(5):39-46.
- [15] 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.
- ZHOU Xiaohua, FENG Yuchen, HU Xuchu, et al. Transformer fault diagnosis based on SVM optimized by bald eagle search algorithm[J]. Southern Power System Technology, 2023, 17(6):99-106, 116.
- [16] 徐超, 叶宁, 徐康, 等. 融合MAML与BiLSTM的微博负面情感多分类方法[J]. 计算机工程与应用, 2022, 58(5):179-185.
- XU Chao, YE Ning, XU Kang, et al. Multiple classification method for microblog negative emotions integrating MAML and BiLSTM[J]. Computer Engineering and Applications, 2022, 58(5):179-185.
- [17] 樊清川, 于飞, 宣敏. 基于优化Bi-LSTM模型的电力变压器故障诊断[J]. 计算机仿真, 2022, 39(11):136-140.
- FAN Qingchuan, YU Fei, XUAN Min. Power transformer fault diagnosis based on optimized Bi-LSTM model[J]. Computer Simulation, 2022, 39(11):136-140.
- [18] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science Control Engineering, 2020, 8(1):22-34.
- [19] 王艳, 李伟, 赵洪山, 等. 基于油中溶解气体分析的DBN-SSAELM变压器故障诊断方法[J]. 电力系统保护与控制, 2023, 51(4):32-42.
- WANG Yan, LI Wei, ZHAO Hongshan, et al. Transformer DGA fault diagnosis method based on DBN-SSAELM[J]. Power System Protection and Control, 2023, 51(4):32-42.
- [20] 李爱莲, 全凌霄, 崔桂梅, 等. 融合正余弦和柯西变异的麻雀

- 搜索算法[J]. 计算机工程与应用, 2022, 58(3):91-99.
- LI Ailian, QUAN Lingxiang, CUI Guimei, et al. Sparrow search algorithm combining sine-cosine and Cauchy mutation [J]. Computer Engineering and Applications, 2022, 58(3):91-99.
- [21] 吴晓欣, 何怡刚, 段嘉珺, 等. 考虑复杂时序关联特性的 Bi-LSTM 变压器 DGA 故障诊断方法[J]. 电力自动化设备, 2020, 40(8):184-193.
- WU Xiaoxin, HE Yigang, DUAN Jiajun, et al. Bi-LSTM-based transformer fault diagnosis method based on DGA considering complex correlation characteristics of time sequences [J]. Electric Power Automation Equipment, 2020, 40(8):184-193.
- [22] 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.
- FENG Zhiliang, XIAO Hanqi, REN Wenfeng, et al. Transformer fault diagnosis based on principal component analysis and seagull optimization support vector machine [J]. China Measurement & Testing Technology, 2023, 49(2):99-105.
- [23] 王爽, 罗倩, 唐波, 等. 考虑样本类内不平衡的 CHPOA-DBN 变压器故障诊断方法[J]. 中国电力, 2023, 56(10):133-144.
- WANG Shuang, LUO Qian, TANG Bo, et al. CHPOA-DBN transformer fault diagnosis method considering sample within-class imbalance[J]. Electric Power, 2023, 56(10):133-144.
- [24] 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.
- [25] 郝玲玲, 朱永利, 王永正. 基于 DCAE-KSSELM 的变压器故障诊断方法[J]. 中国电力, 2022, 55(2):125-130.
- HAO Lingling, ZHU Yongli, WANG Yongzheng. Transformer fault diagnosis method based on DCAE-KSSELM [J]. Electric Power, 2022, 55(2):125-130.
- [26] 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.
- [27] 李云谔, 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. Fault diagnosis for power transformers based on improved grey wolf algorithm coupled with least squares support vector machine [J]. Power System Technology, 2023, 47(4):1470-1478.
- [28] 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.
-
- 收稿日期: 2024-04-17; 网络首发日期:2024-07-31
- 作者简介:
- 汪繁荣(1979), 男, 副教授, 硕士生导师, 博士, 研究方向为电网控制与智能制造, wfr@whu.edu.cn;
- 李州(2001), 男, 通信作者, 硕士研究生, 研究方向为变压器故障诊断, 1099946458@qq.com。