

DOI:10.13296/j.1001-1609.hva.2026.06.006

## 基于改进麻雀搜索算法优化KELM的变压器故障诊断方法

徐松晓<sup>1</sup>, 赵军愉<sup>1</sup>, 张元波<sup>1</sup>, 路小军<sup>1</sup>, 王艳<sup>2</sup>, 李伟<sup>2</sup>

(1. 国网保定供电公司, 河北 保定 071051; 2. 华北电力大学电气与电子工程学院, 河北 保定 071003)

**摘要:** 针对传统浅层机器学习在特征提取方面的不足,为增强其对变压器故障诊断的能力,提出一种基于改进麻雀搜索算法优化KELM的变压器故障诊断方法。首先利用深度置信网络(deep belief networks, DBN)对变压器故障样本数据进行特征提取;其次,将引入惩罚因子 $C$ 和核函数参数 $S$ 的核极限学习机(kernel extreme learning machine, KELM)作为分类器,深入分析易混淆样本的特征值与变压器故障类型间的关联性,进一步提高故障诊断模型的稳定性和泛化能力;然后,利用Levy变异因子改进的麻雀搜索算法(improved sparrow search algorithm, ISSA)优化KELM的惩罚因子 $C$ 和核函数参数 $S$ ,以增强的麻雀搜索算法的全局搜索能力,进一步提高故障诊断模型的稳定性和准确率。最后,基于油中溶解气体数据的变压器故障诊断实验结果表明:所提基于ISSA优化KELM的变压器故障诊断方法,收敛速度更快、稳定性更好、诊断准确率更高,适用于变压器故障诊断。

**关键词:** 变压器; 故障诊断; 深度置信网络; 核极限学习机; Levy因子; 麻雀搜索算法

### Transformer Fault Diagnosis Method Based on KELM Optimized by Improved Sparrow Search Algorithm

XU Songxiao<sup>1</sup>, ZHAO Junyu<sup>1</sup>, ZHANG Yuanbo<sup>1</sup>, LU Xiaojun<sup>1</sup>, WANG Yan<sup>2</sup>, LI Wei<sup>2</sup>

(1. State Grid Baoding Power Supply Company, Hebei Baoding 071051, China; 2. School of Electrical and Electronic Engineering, North China Electric Power University, Hebei Baoding 071003, China)

**Abstract:** To address the limitations of traditional shallow machine learning in feature extraction and to enhance its capability for transformer fault diagnosis, a transformer fault diagnosis method based on KELM optimized by an improved sparrow search algorithm is proposed. First, the deep belief networks (DBN) is used for feature extraction of transformer fault sample data. Then, the kernel extreme learning machine (KELM) with penalty factor  $C$  and kernel function parameter  $S$  is used as a classifier to analyze deeply the correlation between features of confusable samples and fault types and improve the stability and generalization ability of the model. After that, the improved sparrow search algorithm (ISSA) with Levy mutation factor is used to optimize the penalty factor  $C$  and kernel function parameter  $S$  of KELM to enhance the global search ability of the algorithm and improve both stability and accuracy of fault diagnosis of the model. Finally, the experimental results of transformer fault diagnosis based on dissolved gas data in oil show that the proposed ISSA-KELM transformer fault diagnosis method has faster convergence speed, better stability and higher diagnostic accuracy, and is suitable for transformer fault diagnosis.

**Key words:** transformer; fault diagnosis; deep belief networks; kernel extreme learning machine; Levy factor; sparrow search algorithm

收稿日期:2025-11-15; 修回日期:2026-02-02

基金项目:国家自然科学基金项目(51807063);国家电网公司项目(智能配电网规划设计及设备态势感知及智能运维技术研究与应用)。

Project Supported by National Natural Science Foundation of China(51807063), State Grid Corporation of China Project(Research and Application of Planning and Design of Smart Distribution Networks, Equipment Situation Awareness, and Intelligent Operation and Maintenance Technologies).

## 0 引言

电力变压器作为电力系统中电能传输与分配的核心设备,其内部构造复杂且造价昂贵。变压器内部绝缘材料在电场、温度等因素的长期作用下,会逐步发生老化与裂解,严重时将导致变压器故障,影响电网的正常供配电,造成巨大的经济损失。因此,建立有效的变压器故障诊断方法有助于及时发现变压器中存在的潜在故障,提前安排检修计划,对提高电网安全稳定运行具有重要意义<sup>[1]</sup>。

目前,油中溶解气体分析(dissolved gas analysis, DGA)是油浸式电力变压器故障诊断的一种有效手段,该方法通过分析溶解气体数据判断变压器内部可能发生的故障类型,受外界环境干扰较小,可靠性高<sup>[2-3]</sup>。传统基于DGA的变压器故障诊断方法主要包括:特征气体含量及组份法、特征气体比值法(三比值法、四比值法)等。前者主要依赖于长期积累的经验而进行定性判断,应用于多重故障分析时较为复杂。后者主要基于阈值判断,仅当变压器油中溶解的气体组份及产气速率超过注意值时,才能做出有效判断,且气体比值边界处的编码划归过于绝对、模糊性较大,导致其对同性质故障的严重程度识别能力较弱,诊断结果存在局限性且误诊率高。

近年来,随着智能算法和机器学习等模型的不断优化与发展,电力设备的故障诊断方法也逐渐智能化,基于聚类<sup>[4]</sup>、神经网络<sup>[5-6]</sup>、支持向量机<sup>[7-8]</sup>、极限学习机<sup>[9]</sup>等理论的变压器智能故障方法,一定程度上提高了故障诊断的精度和速度。但传统聚类算法的分类结果受算法初始值及噪声数据的影响,聚类效果较差,故障识别准确率低,难以满足实际工程的需要。人工神经网络则需要通过误差的反向传播以调整网络权值和阈值,自动建立状态信息与故障类型之间的映射关系,无需人工干预;但该网络训练过程的收敛速度慢,耗时长。支持向量机本质上是一种二分类器,不适用于变压器的大数据、多分类故障诊断<sup>[10-11]</sup>。

极限学习机<sup>[12]</sup>是一种由单隐藏层的前馈神经网络,仅需确定模型的输入权值及隐藏层偏置,便能获得唯一解,一定程度上克服了传统神经网络因误差反向传播而导致训练时间长、参数困难等问题,具有较强的学习能力。但ELM模型中隐藏层节点与输入节点之间的输入权值、隐藏层节点的偏置是随机设定,导致模型存在泛化能力弱、故障诊断结果的不稳定等问题。

同时,随着智能电网的不断建设与发展,各种先进传感监测、网络通信等技术在电力设备运行维护中的广泛部署,导致电力变压器运行状态相关的信息呈现出多源、异构的大数据特征<sup>[13]</sup>。针对变压器油中溶解气体体积分数的海量数据,传统的故障诊断方法在特征学习、诊断准确率等方面逐渐呈现出一定的不足,同时也为基于人工智能的数据挖掘技术的应用奠定了基础。其中,深度置信网络作为深度学习<sup>[14-18]</sup>中的一种模型,主要是由多个受限玻尔兹曼机自下而上逐层堆叠而成,在学习能力及特征提取等方面具有显著优势。将其应用于变压器故障诊断时,可以自适应的分析、处理油中溶解气体数据,并进行特征提取,弥补传统浅层机器学习在学习能力、特征提取等方面的不足,进一步提高变压器故障诊断的精度,有助于及时、全面、准确地掌握变压器当前的运行状态及未来的发展趋势。

针对上述问题,文中提出一种基于改进麻雀搜索算法优化KELM的变压器故障诊断方法。首先利用深度置信网络对油中溶解气体体积分数的比值数据进行特征提取;然后利用引入惩罚因子 $C$ 和核函数参数 $S$ 的KELM分类器替换传统单一诊断模型中的softmax分类器,进一步分析易混淆样本的气体比值特征值与变压器运行状态之间的映射关系,并进行变压器故障诊断;最后利用改进后麻雀搜索算法(improved sparrow search algorithm, ISSA)对KELM模型中的惩罚因子及核函数参数进行优化,通过实验对比不同模型的诊断结果。实验结果表明:文中所提基于ISSA优化KELM的变压器故障诊断方法收敛速度更快、稳定性更好、诊断准确率更高,可为运行维护人员及时掌握变压器的运行状态并制定相应的维修策略提供可靠依据。

## 1 基于深度置信网络的特征提取

### 1.1 特征参量选取

油浸式电力变压器中的绝缘油及固体绝缘材料主要是由碳氢化合物构成。当设备内部发生故障时,碳氢化合物中的C-C键、C-H键发生断裂,产生不稳定的氢原子和碳氢自由基,并通过复杂的化学反应生成 $H_2$ 、低分子烃类( $CH_4$ 、 $C_2H_6$ 、 $C_2H_4$ 、 $C_2H_2$ )等气体溶于绝缘油中。由于变压器油中溶解的特征气体与故障类型密切相关,因此,文中根据变压器故障前后出现的温度与能量的不同,将变压器的运行状态划分为正常、中低温过热、高温过热、低能放电、高能放电、局部放电;参考三比值法,将 $H_2$ 、 $CH_4$ 、 $C_2H_6$ 、 $C_2H_4$ 和 $C_2H_2$  5种气体作为特征气体。

但传统比值法选取的特征量(CH<sub>4</sub>/H<sub>2</sub>、C<sub>2</sub>H<sub>4</sub>/C<sub>2</sub>H<sub>6</sub>、C<sub>2</sub>H<sub>2</sub>/C<sub>2</sub>H<sub>4</sub>)个数较少,且变压器故障时的产气机理复杂,仅利用浅层机器学习进行故障诊断时,无法建立特征气体数据与变压器运行状态之间准确、完善的映射关系。

因此,文中选取9种不同组合形式的气体无编码比值作为故障诊断模型的特征参量<sup>[19]</sup>,见表1。表1中: $n(\cdot)$ 表示气体体积分数;C<sub>1</sub>表示一阶碳氢化合物,如CH<sub>4</sub>;C<sub>2</sub>表示二阶碳氢化合物,如C<sub>2</sub>H<sub>6</sub>、C<sub>2</sub>H<sub>4</sub>、C<sub>2</sub>H<sub>2</sub>。

表1 气体比值特征

Table 1 Gas ratios features

特征参量编号	气体体积分数比值
1	$n(\text{CH}_4)/n(\text{H}_2)$
2	$n(\text{C}_2\text{H}_4)/n(\text{C}_2\text{H}_2)$
3	$n(\text{CH}_4)/n(\text{C}_1+\text{C}_2)$
4	$n(\text{C}_2\text{H}_2)/n(\text{C}_1+\text{C}_2)$
5	$n(\text{C}_2\text{H}_4)/n(\text{C}_2\text{H}_6)$
6	$n(\text{C}_2\text{H}_4)/n(\text{C}_1+\text{C}_2)$
7	$n(\text{H}_2)/n(\text{H}_2+\text{C}_1+\text{C}_2)$
8	$n(\text{CH}_4+\text{C}_2\text{H}_4)/n(\text{C}_1+\text{C}_2)$
9	$n(\text{C}_2\text{H}_6)/n(\text{C}_1+\text{C}_2)$

### 1.2 深度置信网络

深度置信网络是一种由若干层受限玻尔兹曼机(restricted boltzmann machine, RBM)组成的深层网络模型<sup>[20]</sup>,其结构见图1。单个RBM模型包含可见层( $n$ 个神经元)和隐藏层( $m$ 个神经元),且层内神经元之间无连接,层间神经元之间全连接。




图1 DBN 网络结构

Fig. 1 Structure of DBN

图1中: $\mathbf{v}=[v_1, v_2, \dots, v_n]^T$ 和 $\mathbf{h}=[h_1, h_2, \dots, h_m]^T$ 分别为可见层和隐藏层中神经元的状态向量,用0和1分别代表激活与未激活状态; $W_{ij}$ 为可见层中神经元 $v_n$ 和隐藏层中神经元 $h_m$ 之间的权重; $\mathbf{a}=[a_1, a_2, \dots, a_n]^T$ 和 $\mathbf{b}=[b_1, b_2, \dots, b_m]^T$ 分别为可见层

和隐藏层中神经元的偏置。则该RBM模型的能量函数定义为

$$E_{\theta}(\mathbf{v}, \mathbf{h}) = -\sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m h_j w_{ij} v_i \quad (1)$$

式(1)中, $\theta = \{W_{ij}, a_i, b_j | 1 \leq i \leq n, 1 \leq j \leq m\}$ 为该RBM模型的参数。

根据式(1)中能量函数,则可见层与隐藏层之间的联合概率分布可表示为

$$P(\mathbf{v}, \mathbf{h} | \theta) = \frac{e^{-E_{\theta}(\mathbf{v}, \mathbf{h})}}{\sum_{\mathbf{v}} \sum_{\mathbf{h}} e^{-E_{\theta}(\mathbf{v}, \mathbf{h})}} \quad (2)$$

训练RBM的过程中,引入最大似然函数,采用对比散度(contrastive divergence, CD)算法<sup>[21]</sup>快速求解并更新模型的 $\theta$ 值。

### 1.3 基于深度置信网络的特征提取

利用DBN提取变压器DGA数据特征的训练过程即是求解所有RBM模型的参数 $\theta$ 的过程,主要包括预训练和微调两个阶段,具体步骤如下:

1)预训练阶段。将归一化后的9种不同形式的气体比值作为底层RBM的输入,自下而上逐层训练RBM,保证单个RBM模型的参数 $\theta$ 对该层特征向量的映射达到最优。

2)微调阶段。结合变压器故障样本标签,利用BP算法对模型参数进行有监督微调,保证整个DBN模型实现输入气体比值数据到变压器故障类型特征空间的最优映射。

变压器油中溶解气体数据经上述DBN网络进行特征提取并输出6维特征值,利用t-SNE算法将6维特征值降维映射到二维空间,特征值分布情况与变压器6种运行状态之间的对应关系见图2,X轴、Y轴分别表示特征值降维后的相对位置。




图2 气体数据特征值

Fig. 2 Features of gas data

由图2可知,相同运行状态下的样本数据特征

值呈现高度集中,不同运行状态下的样本数据特征值呈现高度分离的现象。但针对同一故障性质中的不同故障类型特征值差异性较小的情况,如热故障中的中低温过热与高温过热、电故障中的低能放电与高能放电,仍存在混淆误判的可能性,故障识别效果较差。因此,文中利用引入惩罚因子  $C$  和核函数参数  $S$  的核极限学习机 (extreme learning machine, ELM) 作为分类器,充分保留易混淆样本数据的特征值之间的差异性,进一步分析其与变压器运行状态之间的映射关系,提升变压器故障诊断准确率的同时,提高模型的稳定性和泛化能力。

## 2 基于ISSA优化KELM的故障诊断模型

### 2.1 核极限学习机

极限学习机是一种由单隐藏层构成的前馈神经网络 (single - hidden layer feedforward neural network, SLFN)<sup>[22-24]</sup>,相比BP神经网络具有学习速度快、泛化能力强的优点。核极限学习机是在极限学习机的基础上,引入核函数将ELM中的随机映射替换为核映射,克服了隐藏层节点数、偏置和输入权值的干扰,增强了模型输出的稳定性和泛化能力。

对于给定  $N$  个训练样本的数据集  $(x_i, t_i)$ ,其中  $x_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T$  为输入样本,  $t_i = [t_{i1}, t_{i2}, \dots, t_{im}]^T$  为目标输出。设隐藏层节点个数为  $L$ ,激活函数为  $G(x)$ ,当ELM网络模型的输出数据  $y_i = [y_{i1}, y_{i2}, \dots, y_{im}]^T$  以较小误差逼近目标输出  $t_i$  时,ELM网络模型的输出转化为矩阵的形式可表示为

$$H\beta = T \quad (3)$$

式(3)中:  $H$  为ELM的隐藏层输出矩阵;  $T$  为期望的目标输出矩阵;  $\beta$  为ELM的输出权值矩阵。根据广义逆矩阵理论,  $\beta$  可表示为

$$\beta^* = H^T(I/C + HH^T)^{-1}T \quad (4)$$

式(4)中:  $I$  为对角矩阵;  $C$  为惩罚因子。

利用核矩阵代替ELM中的随机矩阵,可表示为

$$\begin{cases} \Omega_{\text{ELM}} = HH^T \\ \Omega_{\text{ELM}_{ij}} = h(x_i)h(x_j) = K(x_i, x_j) \end{cases} \quad (5)$$

式(5)中:  $\Omega_{\text{ELM}}$  为核矩阵;  $h(x)$  为隐藏层节点的输出函数;  $x_i, x_j$  为样本输入向量;  $K(x_i, x_j)$  为核函数,文中选取径向基(radial basis function, RBF)函数,可表示为

$$K(x_i, x_j) = \exp(-S\|x_i - x_j\|^2) \quad S > 0 \quad (6)$$

式(6)中,  $S$  为核函数参数。

结合式(3)-(5),可得KELM模型的输出为

$$f(x) = h(x)H^T(I/C + HH^T)^{-1}T = \begin{bmatrix} K(x, x_1) \\ \dots \\ K(x, x_N) \end{bmatrix}^T (I/C + \Omega_{\text{ELM}})^{-1}T \quad (7)$$

由式(7)可知,惩罚因子  $C$  和核函数参数  $S$  是影响KELM模型性能的重要因素,因此,文中利用麻雀搜索算法对惩罚因子  $C$  和核函数参数  $S$  进行优化,进一步提高KELM模型的稳定性和泛化能力。

### 2.2 基于改进麻雀搜索算法优化KELM

麻雀搜索算法<sup>[25]</sup>是受自然界中麻雀觅食行为启发而提出的一种智能优化算法。相比遗传算法(GA)、粒子群算法(PSO)、果蝇算法(FOA)、SSA算法在参数优化和选择过程中,收敛速度快,具有较强的全局搜索能力<sup>[26]</sup>。

文中采用SSA算法对KELM的惩罚因子  $C$  和核函数参数  $S$  进行优化时,首先初始化麻雀种群的信息矩阵为

$$\begin{cases} Z = [z_1 & z_2 & \dots & z_N]^T \\ z_N = [z_N^1 & z_N^2 & \dots & z_N^d] \end{cases} \quad (8)$$

式(8)中:  $N$  为麻雀种群数量;  $d$  为待优化的维度,文中对应惩罚因子  $C$  和核函数参数  $S$  两个维度;  $z_N$  为第  $N$  只麻雀个体的信息。

麻雀种群的适应度矩阵可表示为

$$\begin{cases} F = [f_1(z) & f_2(z) & \dots & f_N(z)]^T \\ f_N(z) = f([z_N^1 & z_N^2 & \dots & z_N^d]) \end{cases} \quad (9)$$

式(9)中:  $f(z)$  为适应度函数,文中将模型的诊断误差率作为适应度函数;  $f_N(z)$  为第  $N$  只麻雀个体的适应度值,其值大小对应参数的优劣。

适应度值最好的个体作为发现者,负责引导种群觅食的方向,其位置更新公式为

$$Z_{i,t+1}^j = \begin{cases} Z_{i,t}^j \cdot \exp(-\frac{i}{\alpha \cdot M}) & R_2 < S_r \\ Z_{i,t}^j + Q \cdot L & R_2 \geq S_r \end{cases} \quad (10)$$

式(10)中:  $t$  为当前迭代次数;  $Z_{i,t}^j$  为第  $t$  次迭代中第  $i$  个麻雀在第  $j$  维的信息;  $\alpha$  为  $(0, 1]$  间的随机数;  $M$  为最大迭代次数;  $Q$  为服从标准正态分布的随机数;  $L$  是一个  $1 \times d$  维的全1矩阵;  $R_2$  为  $[0, 1]$  之间的随机数,表示预警值;  $S_r$  为  $[0.5, 1]$  之间的常量,表示安全阈值。

除发现者以外的其余个体均为跟随者,当迭代到一定次数且适应度值不再变化时,跟随者会分布在发现者周围,甚至会成为发现者。因此,文中引入Levy变异因子<sup>[27]</sup>更新跟随者的位置,提高算法的全局搜索能力,避免陷入局部最优,其位置更新公

式为

$$Z_{i,t+1}^j = \begin{cases} Q \cdot \exp\left(\frac{Z_{\text{worst},t} - Z_{i,t}^j}{t^2}\right) & i > \frac{N}{2} \\ Z_{\text{best},t+1} + Z_{\text{best},t+1} \otimes L(d) & i \leq \frac{N}{2} \end{cases} \quad (11)$$

式(11)中:  $Z_{\text{worst},t}$ 、 $Z_{\text{best},t+1}$  为第  $t$ 、 $t+1$  次迭代后种群中个体的最差、最优位置;当  $i > N/2$  时,表示适应度较差的第  $i$  个跟随者附近食物较少,需要前往其他地方获取更多能量。 $L(d)$  为 Levy 飞行值,其飞行机制为

$$L(d) = 0.01 \times r_3 \times \sigma / |r_4|^{1/\xi} \quad (12)$$

式(12)中:  $r_3$ 、 $r_4$  均为  $1 \times d$  维取值范围为  $[0, 1]$  之间的随机数;  $\xi$  取值 1.5。 $\sigma$  计算方式为

$$\sigma = \left\{ \frac{\Gamma(1+\xi) \times \sin(\pi\xi/2)}{\Gamma[(1+\xi)/2] \times \xi \times 2^{(\xi-1)/2}} \right\}^{1/\xi} \quad (13)$$

式(13)中,  $\Gamma(x) = (x-1)!$ 。

在种群迭代优化的过程中,随机选取种群中的部分个体作为预警者,模拟麻雀觅食过程中的反捕食行为,放弃当前位置,前往新位置,其位置更新公式为

$$Z_{i,t+1}^j = \begin{cases} Z_{\text{best},t} + \beta \cdot \left| Z_{i,t}^j - Z_{\text{best},t} \right| & f_i \neq f_{\text{best}} \\ Z_{i,t}^j + K \left[ \frac{Z_{i,t}^j - Z_{\text{worst},t}}{(f_i - f_{\text{worst}}) + \varphi} \right] & f_i = f_{\text{best}} \end{cases} \quad (14)$$

式(14)中:  $\beta$  为步长调节系数,是一个服从均值为 0、方差为 1 的正态分布随机数;  $K$  为随机数,表示种群中麻雀个体的移动方向,取值范围为  $[-1, 1]$ ;  $f_i$  为第  $i$  只麻雀的适应度值,  $f_{\text{best}}$ 、 $f_{\text{worst}}$  分别为当前迭代次数下麻雀种群中的全局最优和最差的适应度;  $\varphi$  为极小常数,避免分母出现 0。当  $f_i \neq f_{\text{best}}$  时,表明麻雀种群中的预警者分布在种群的边缘地区,但其意识到危险时,会向种群的全局最优位置所在区域靠近;当  $f_i = f_{\text{best}}$  时,表明位于种群中最优位置的麻雀个体意识到危险,需要带领种群远离危险,前往新的安全位置进行觅食。

### 2.3 评价指标

文中选取变压器故障诊断的准确率作为适应度函数,计算公式为

$$f = n_{\text{True}} / n_{\text{样本总数}} \quad (15)$$

式(15)中,  $n_{\text{True}}$  为诊断结果正确的样本数量。

为了综合评估诊断模型的性能,文中选用基于混淆矩阵的多分类评价指标体系,将准确率、查准率、

查全率、Kappa 系数<sup>[28]</sup>作为评价指标,其计算式为:

$$\lambda_A = \frac{TP + TN}{TP + TN + FP + FN} \quad (16)$$

$$\lambda_P = \frac{TP}{TP + FP} \quad (17)$$

$$\lambda_R = \frac{TP}{TP + FN} \quad (18)$$

$$\lambda_{\text{Kappa}} = \frac{\lambda_A - \sum_{i=1}^6 n_{Ri} n_{Pi} / N^2}{1 - \sum_{i=1}^6 n_{Ri} n_{Pi} / N^2} \quad (19)$$

式(16)-(19)中:  $N$  表示样本总数;  $TP$  表示正样本预测为正样本的个数;  $FN$  为正样本预测为负样本的个数;  $FP$  为负样本预测为正样本的个数;  $TN$  为负样本预测为负样本的个数;  $i=1, 2, \dots, 6$  为变压器的故障类型。

Kappa 系数用于分类问题评价指标时,表征预测结果与真实结果之间的一致性程度,见表 2。

表 2 Kappa 系数分类标准

Table 2 Classification criterion based on Kappa coefficient

Kappa 系数	一致性程度
0.00~0.20	微弱
0.21~0.40	弱
0.41~0.60	适中
0.61~0.80	显著
0.81~1.00	最佳

## 3 基于 ISSA-KELM 的变压器故障诊断模型

文中提出的 ISSA-KELM 变压器故障方法主要包括 DBN 特征提取、ISSA 优化 KELM 参数、KELM 故障诊断 3 部分,基于 ISSA-KELM 变压器诊断流程图 3。

## 4 实验与结果分析

### 4.1 数据预处理

1)文中所选用的油中溶解气体数据来源于变压器生产厂家针对型号为 SSZ11-20000kVA/110kV 的变压器的在线监测及故障试验记录,共计 3 000 组,各类故障的样本容量均为 500,样本间比例为 1:1:1:1:1:1:1。模型训练及故障诊断的过程中,按照 8:2 的比例随机将总样本划分为训练集和测试集,样本分布情况及故障编码见表 3,部分样本数据见表 4。

2)利用局部异常因子检测(LOF)算法对原始数据集中的噪声数据,进行异常识别与数据清洗。并将其归一化处理后作为模型的输入量。

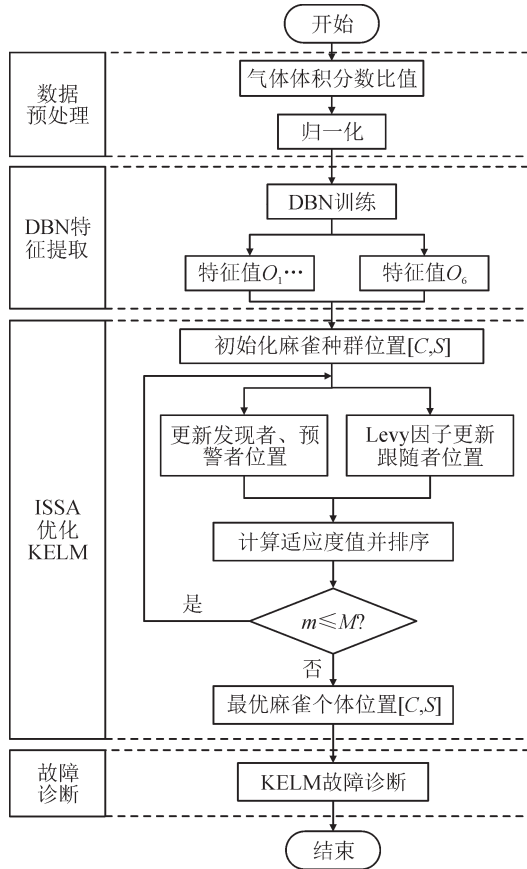


图3 ISSA-KELM故障诊断流程图

Fig. 3 Flow-chart of fault diagnosis with ISSA-KELM

表3 样本数据分布及编码

Table 3 Distribution and codes of label samples

故障类型	故障类型	0-1 编码	样本容量	训练集:测试集
1	正常	1 0 0 0 0	500	8:2
2	中低温过热	0 1 0 0 0	500	
3	高温过热	0 0 1 0 0	500	
4	低能放电	0 0 0 1 0	500	
5	高能放电	0 0 0 0 1	500	
6	局部放电	0 0 0 0 1	500	

表4 标签样本数据

Table 4 Gas composition data of label samples

样本体积分数/( $\mu\text{L}\cdot\text{L}^{-1}$ )					故障类型
H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	
3.40	6.70	2.60	0.90	0.40	正常
42.31	145.67	16.41	92.80	0.01	中低温过热
81.94	160.97	78.28	405.94	8.53	高温过热
53.77	8.27	0.90	5.94	6.95	低能放电
100.11	21.71	1.50	26.31	33.11	高能放电
627.00	65.00	37.00	23.00	0.00	局部放电

#### 4.2 参数设置

DBN模型中隐藏层层数、神经元个数是影响其分类结果的重要因素。经多次实验发现,当DBN网

络的隐藏层层数和神经元个数增加时,模型的故障识别准确率有明显增加的趋势,但由于层数不足,可能会出现欠拟合,导致无法充分提取数据特征;随着两者的不断增加,网络结构更加复杂,模型的故障识别准确率提升效果却甚微,甚至可能发生拟合,导致对新数据的泛化能力降低。

因此,为保证DBN网络能够充分提取故障数据的特征,进一步提高后续KELM故障诊断的准确率,经多次实验,文中选用DBN网络的结构为:9-40-20-6。由于KELM分类器的性能受惩罚因子C和核函数参数S的影响,故文中利用Levy因子改进后的麻雀搜索算法(ISSA)对KELM模型的参数进行优化,且惩罚因子C和核函数参数S分别对应2.2节中麻雀个体位置的两个维度信息。文中基于ISSA-KELM的变压器故障诊断模型的具体参数设置见表5。

表5 模型参数

Table 5 The parameters of model

算法	参数	数值
SSA	种群数(N)	20.0
	迭代次数(M)	30.0
	发现者占比	0.7
	预警者占比	0.2
	安全值(S <sub>t</sub> )	0.6
	优化维度(d)	2.0
KELM	核函数	RBF
	核函数参数S	[0.1, 10.0]
	惩罚系数C	[0.1, 100.0]

#### 4.3 基于ISSA-KELM的变压器故障诊断及评估

针对变压器故障的小概率事件导致故障样本长期依赖于历史数据,数据差异性较大,质量低且缺乏代表性,严重影响浅层机器学习算法对样本数据与故障类型之间的映射,导致诊断准确率较低等问题,文中利用DBN模型对3.1节中9种不同气体组合形式的特征参量进行特征提取,将输出的6维特征值(如图2)作为ISSA-KELM故障诊断模型的输入进行故障诊断。

为验证基于ISSA-KELM故障诊断模型的性能,根据测试集样本的诊断输出结果绘制混淆矩阵,并计算2.3节中的评价指标,见图4。

由图4可知,文中所提基于ISSA-KELM的故障诊断模型对变压器6种不同类型的运行状态的查全率和查准率均高于90%,中低温过热故障样本的查准率高达100%。其中,模型将1例高温过热故障样本误判为局部放电、4例误判为正常运行,查准率为94.94%,查全率为100%;将1例低能放电样本误判为高能放电、6例误判为局部放电,查准率为





图4 诊断结果评价指标

Fig. 4 Evaluation indicators based on diagnostic results

93.75%,查全率为94.59%;将2例高能放电样本误判为低能放电、1例误判为局部放电、1例误判为正常运行,查准率为96.30%,查全率为99.05%;将1例局部放电样本误判为低能放电、2例误判为正常运行,查准率为96.97%,查全率为91.43%。经多次实验,模型整体平均识别准确率可达94.94%,表明该模型能够充分挖掘故障样本的数据特征,实现故障样本与故障类型之间的最优映射,对变压器故障样本的识别能力强、故障诊断精度高。

基于图4(a)所示的混淆矩阵,计算得其对应的Kappa系数为0.94,由表3所示的Kappa系数分类标准可知,基于ISSA-KELM模型的变压器故障诊断预测结果和真实分类结果几乎完全一致,表明模型的预测效果理想,故障判断可信度高。

为验证模型对实际运行变压器的故障诊断效果,采用河北地区供电公司的260组(正常:中低温过热:高温过热:低能放电:高能放电:局部放电=57:44:33:46:33:47)数据进行故障诊断,诊断结果的混

淆矩阵,见图5。




图5 实测数据的诊断混淆矩阵

Fig. 5 Diagnostic confusion matrix based on measured data

由图5可知,模型对实际运行中变压器6种不同类型的运行状态的查准率分别为:98.25%、88.64%、90.91%、91.30%、96.97%、93.62%,查全率分别为:96.55%、90.70%、88.24%、97.67%、86.49%、97.78%,整体准确率高达93.46%,表明模型整体的诊断准确率高、泛化能力强。

为进一步验证所提模型的可靠性和对典型数据集的泛化能力,使用国际IEC TC 10数据和国家电网公司数据对模型进行训练诊断的结果见表6。

表6 不同数据集的诊断结果

Table 6 Diagnostic results based on different datasets

类型	IEC TC 10			国家电网		
	样本分布	$\lambda_p/\%$	$\lambda_r/\%$	样本分布	$\lambda_p/\%$	$\lambda_r/\%$
1	26	96.15	96.15	60	96.67	98.31
2	23	91.30	91.30	55	96.36	94.64
3	45	93.33	97.67	41	90.24	92.50
4	10	90.00	81.82	36	91.67	86.84
5	14	100.00	92.86	50	96.00	92.31
6	—	—	—	47	89.36	97.67

由表6可知,所提ISSA-KELM故障诊断模型基于国际IEC TC 10数据集和国家电网数据集的整体准确率分别高达93.22%和93.77%,表明模型对变压器油中溶解气体故障诊断的可靠性、对不同数据集的泛化能力均较强。

#### 4.4 模型诊断效果对比

为进一步验证所提基于ISSA-KELM的变压器故障诊断模型中进行特征提取的必要性及有效性,文中在GRNN、SVM、ELM、KELM算法的基础上,对比分析了DBN模型特征提取前后故障诊断的结果,其诊断准确率及Kappa系数见图6。

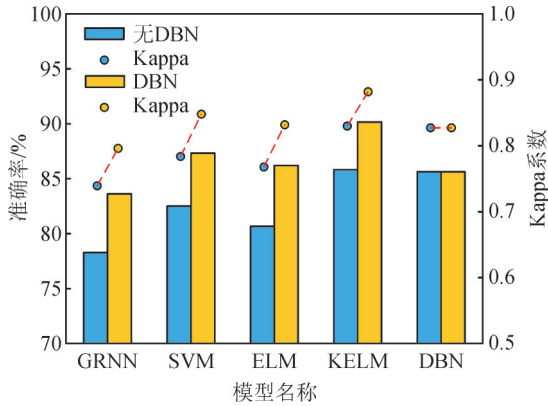


图6 模型的评价指标

Fig. 6 Comparison of evaluation indicators

由图6可知,基于DBN进行特征提取改进后的GRNN、SVM、ELM、KELM模型故障诊断准确率分别为83.625%、87.33%、86.21%、90.17%,相比于单一GRNN、SVM、ELM、KELM模型的故障诊断准确率分别提高了5.335%、4.82%、5.54%、4.34%,表明改进后的模型充分发挥了DBN提取抽象特征的能力,弥补传统单一智能算法在特征提取方面的不足,模型提取的数据特征更加丰富、全面,能够实现故障数据与故障类型之间的映射,进一步提高后续机器学习的准确率。同时,改进后模型诊断结果的Kappa系数均有一定程度的提升且均高于0.75,

根据Kappa系数分类标准可知,改进后的模型预测结果与真实情况的一致性程度显著。

单一ELM模型的故障诊断准确率为80.67%,引入核函数后的KELM模型故障诊断准确率达85.83%,提高了5.16%,且Kappa系数提升了0.062;经DBN特征提取后,准确提高了3.96%,Kappa系数提升了0.050,实验结果表明引入核函数后的KELM模型相比ELM模型具有更高的诊断准确率、更理想的预测结果及更好的稳定性。

#### 4.5 不同优化算法对比

为进一步验证所提基于ISSA-KELM的变压器故障诊断模型中基于Levy因子改进SSA算法优化KELM参数的有效性,文中在KELM模型的基础上,对比分析了GA、PSO、FOA、SSA 4种算法优化模型后的诊断结果,见表7,收敛曲线见图7。

表7 不同模型诊断结果对比

Table 7 Comparison of results with different models

模型名称	准确率/%	Kappa系数
GA-KELM	93.54	0.920 0
PSO-KELM	94.41	0.935 0
FOA-KELM	92.77	0.911 8
ISSA-KELM	94.94	0.938 5




图7 不同优化算法准确率对比

Fig. 7 Comparison of fault diagnosis accuracy of different models

由表7、图7可知,在DBN进行特征提取的基础上,利用优化算法改进后的GA-KELM、PSO-KELM、FOA-KELM、ISSA-KELM变压器故障诊断模型,通过对KELM分类器中惩罚因子C和核函数参数S进行优化,相比于KELM模型的故障准确率分别提升了3.37%、4.24%、2.60%、4.77%,Kappa系数分别提升了0.038、0.053、0.029 8、0.056 5,实现准确率提升的同时,保证了预测结果与真实结果的高度一致性,进一步提高了模型的稳定性和泛化能力。

文中利用ISSA优化KELM模型参数的过程中,引入Levy变异因子更新麻雀个体位置,增加种群多样性,加强SSA算法跳出局部最优搜索的能力,基于改进后的模型进行故障诊断,迭代12次后模型趋于稳定且诊断准确率可达94.94%,实现了收敛精度

与收敛速度的同时提升,有效避免了惩罚因子C和核函数参数S陷入局部最优。实验结果表明,文中所提基于ISSA-KELM的变压器故障诊断方法,收敛速度快、诊断精度高、稳定性好,适用于变压器故障诊断。

## 5 结论

1)文中提出的基于ISSA优化KELM的变压器故障诊断模型,相较于传统单一的浅层机器学习故障诊断模型,在利用深度置信网络充分提取油中溶解气体数据特征的基础上,深入分析特征值与故障类型间的关联性,实现故障数据与故障类型之间的最优映射,进一步提高了变压器故障诊断的准确率。

2)文中利用Levy因子改进后的SSA算法优化KELM模型中的惩罚因子和核函数参数,相较于GA、PSO、FOA、SSA优化算法,实现了收敛速度及收敛精度提升的同时,进一步提高了模型的故障诊断准确率及稳定性,可为运行维护人员及时掌握变压器

的运行状态并制定相应的维修策略提供可靠依据。

## 参考文献:

- [1] 梁 栋,朱建华,张 翠,等. 变压器状态评估及故障诊断研究综述[J]. 变压器,2024,61(2):35-43.  
LIANG Dong, ZHU Jianhua, ZHANG Cui, et al. Review of transformer condition assessment and fault diagnosis[J]. Transformer, 2024,61(2):35-43.
- [2] 王 杰,李永鑫,张军亮,等.基于SBOA-TVFMED的变压器油中溶解气体浓度预测[J]. 变压器,2025,62(5):23-31.  
WANG Jie, LI Yongxin, ZHANG Junliang, et al. Prediction of dissolved gas concentration in transformer oil based on SBOA-TVFMED[J]. Transformer, 2025,62(5):23-31.
- [3] 杨金鑫,廖才波,胡 雄,等.基于DGA与TPE-LightGBM的变压器故障诊断[J]. 电力科学与技术学报,2024,39(4):70-77.  
YANG Jinxin, LIAO Caibo, HU Xiong, et al. Transformer fault diagnosis based on DGA and TPE-LightGBM[J]. Journal of Electric Power Science and Technology, 2024,39(4):70-77.
- [4] 邹 阳,黄 煜,俞豪奕,等.融合频谱特性与聚类云—证据推理的油纸绝缘老化程度诊断[J]. 电力系统保护与控制,2024,52(17):105-114.  
ZOU Yang, HUANG Yu, YU Haoyi, et al. Diagnosis of oil-paper insulation aging degree by fusing spectral properties and clustered cloud-evidence reasoning[J]. Power System Protection and Control, 2024,52(17):105-114.
- [5] 林 师.基于改进灰狼算法优化BP神经网络的变压器故障高精度诊断方法[J]. 电子设计工程,2025,33(14):144-149.  
LIN Shi. The high-precision diagnosis method for transformer fault based on the improved gray wolf algorithm to optimize BP neural network[J]. Electronic Design Engineering, 2025,33(14):144-149.
- [6] 沈国堂,郭振宇,黄道均,等.基于特征提取和神经网络的电力变压器声纹诊断方法建立与应用[J]. 变压器,2024,61(6):39-43.  
SHEN Guotang, GUO Zhenyu, HUANG Daojun, et al. Establishment and application of power transformer voiceprint diagnosis method based on feature fusion and neural network[J]. Transformer, 2024,61(6):39-43.
- [7] HUANG Xinyi, HUANG Xiaoli, WANG Binrong, et al. Fault diagnosis of transformer based on modified grey wolf optimization algorithm and support vector machine[J]. IEEE Transactions on Electrical and Electronic Engineering, 2020,15(3):409-417.
- [8] 李 峰,陈皖皖,李晓华,等.基于SVMD-CMSEE与GSA-SVM的新型电力系统变压器故障状态智能诊断方法[J]. 电测与仪表,2024,61(12):17-25.  
LI Feng, CHEN Wanwan, LI Xiaohua, et al. An intelligent fault diagnosis method for transformer in novel power system based on SVMD-CMSEE and GSA-SVM[J]. Electrical Measurement & Instrumentation, 2024,61(12):17-25.
- [9] 孙世明,岑红星,白建民,等.基于集成SAO优化互相关熵极限学习机模型的变压器故障诊断方法[J]. 电测与仪表,2024,61(9):56-64.  
SUN Shiming, CEN Hongxing, BAI Jianmin, et al. Transformer fault diagnosis method based on integrated correntropy extremelearning machine model optimized by SAO[J]. Electrical Measurement & Instrumentation, 2024,61(9):56-64.
- [10] 代杰杰,宋 辉,杨 祎,等.基于油中气体分析的变压器故障诊断ReLU-DBN方法[J]. 电网技术,2018,42(2):658-664.  
DAI Jiejie, SONG Hui, YANG Yi, et al. Dissolved gas analysis of insulating oil for power transformer fault diagnosis based on ReLU-DBN[J]. Power System Technology, 2018,42(2):658-664.
- [11] 刘建锋,董倩雯,田书欣,等.基于ReliefF-mRMR漏磁场特征优选和改进LSSVM的变压器绕组早期故障诊断[J]. 电测与仪表,2025,62(11):198-209.  
LIU Jianfeng, DONG Qianwen, TIAN Shuxin, et al. Early fault diagnosis of transformer winding based on ReliefF-mRMR leakage magnetic field feature optimization and improved LSSVM[J]. Electrical Measurement & Instrumentation, 2025,62(11):198-209.
- [12] 吴杰康,覃炜梅,梁浩浩,等.基于自适应极限学习机的变压器故障识别方法[J]. 电力自动化设备,2019,39(10):181-186.  
WU Jiekang, QIN Weimei, LIANG Haohao, et al. Transformer fault identification method based on self-adaptive extreme learning machine[J]. Electric Power Automation Equipment, 2019,39(10):181-186.
- [13] 王晓蓉,等.基于大数据挖掘的电力变压器健康状态差异预警规则策略[J]. 电测与仪表,2024,61(2):216-224.  
WANG Xiaorong. Early warning rule strategy of power transformer health status difference based on big data mining[J]. Electrical Measurement & Instrumentation, 2024,61(2):216-224.
- [14] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006,18(7):1527-1554.
- [15] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006,313(5786):504-507.
- [16] 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 VMDDBN[J]. Electrical Measurement & Instrumentation, 2024,61(2):157-163.
- [17] 周 萱,吴伟丽.基于改进SMOTE不均样本处理和IHPO-DBN的变压器故障诊断方法研究[J]. 电力系统保护与控制,2024,52(11):21-30.  
ZHOU Xuan, WU Weili. Transformer fault diagnosis method based on improved SMOTE unbalanced sample processing and IHPO-DBN[J]. Power System Protection and Control, 2024,52(11):21-30.
- [18] 李 璞,王 奕,张 博.基于深度学习的电力变压器匝间短路故障辨识方法[J]. 变压器,2025,62(6):41-50.  
LI Pu, WANG Yi, ZHANG Bo. Fault identification method for interturn short circuit of power transformer based on deep learning[J]. Transformer, 2025,62(6):41-50.
- [19] 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.  
LI Yuan, LI Xinghui, SUN Weiwei, et al. Fault diagnosis method of oil-immersed power transformer based on multi-model cascade fusion[J]. Smart Power, 2023,51(6):86-92.

(下转第69页)

- [16] 王浩楠, 崔宝珍, 彭智慧, 等. 应用ICEEMDAN和SVM的行星齿轮箱故障诊断[J]. 机械科学与技术, 2023, 42(1):24-30.  
WANG Haonan, CUI Baozhen, PENG Zhihui, et al. Fault diagnosis of planetary gearbox using ICEEMDAN and SVM[J]. Mechanical Science and Technology for Aerospace Engineering, 2023, 42(1): 24-30.
- [17] ROSTAGHI M, AZAMI H. Dispersion entropy: A measure for time-series analysis[J]. IEEE Signal Processing Letters, 2016, 23(5): 610-614.
- [18] 骆钊, 张涛, 阮彦俊, 等. 基于APSO-SSD-SVD的特高压换流站OLTC振动信号降噪方法[J]. 电力系统保护与控制, 2024, 52(21):13-23.  
LUO Zhao, ZHANG Tao, RUAN Yanjun, et al. Noise reduction method for the OLTC vibration signal of a UHV converter station based on APSO - SSD - SVD[J]. Power System Protection and Control, 2024, 52(21): 13-23.
- [19] COSTA M, GOLDBERGER A L, PENG C K. Multiscale entropy analysis of biological signals[J]. Physical Review E Statistical Nonlinear and Soft Matter Physics, 2005, 71(2 Pt 1):021906.
- [20] 程珩, 励文艳, 权龙, 等. 基于VMD-MDE和ELM的柱塞泵微弱故障诊断[J]. 振动、测试与诊断, 2020, 40(4):635-642.  
CHENG Hang, LI Wenyuan, QUAN Long, et al. Weak fault diagnosis of piston pump based on VMD-MDE and ELM[J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(4): 635-642.
- [21] AZAMI H, ROSTAGHI M, ABASOLO D, et al. Refined composite multiscale dispersion entropy and its application to biomedical signals[J]. IEEE Transactions on Biomedical Engineering, 2017, 64(12):2872-2879.
- [22] 韩国国, 史小军, 王晖, 等. 基于RCMDE和KFCM的煤矿电网故障选线方法[J]. 工矿自动化, 2022, 48(8):92-99.  
HAN Guoguo, SHI Xiaojun, WANG Hui, et al. Fault line selection method for coal mine power grid based on RCMDE and KFCM[J]. Industry and Mine Automation, 2022, 48(8):92-99.
- [23] 颜湘武, 李君岩. 基于主成分分析法的直驱式风电场分群方法[J]. 电力系统保护与控制, 2020, 48(5):127-133.  
YAN Xiangwu, LI Junyan. Grouping method of direct drive wind farm based on principal component analysis[J]. Power System Protection and Control, 2020, 48(5): 127-133.
- [24] 韩平平, 夏雨, 丁明, 等. 基于PCA和CA-ST方法的风电场等值建模研究[J]. 太阳能学报, 2020, 41(11):267-277.  
HAN Pingping, XIA Yu, DING Ming, et al. Equivalent modeling of wind farm based on PCA and CA-ST methods[J]. Acta Energetica Solaris Sinica, 2020, 41(11): 267-277.
- [25] 杨金东, 李文. 基于K-Means算法的配电网负荷和拓扑等效方法[J]. 电力电容器与无功补偿, 2022, 43(2):147-153.  
YANG Jindong, LI Wen. Equivalent method of distribution network load and topology based on K-Means algorithm[J]. Power Capacitor & Reactive Power Compensation, 2022, 43(2): 147-153.

连恒鹏(1997—), 男, 硕士研究生, 主要研究方向为电力变压器状态监测与故障诊断(通信作者)(E-mail: 2424965984@qq.com)。

(上接第58页)

- [20] 孙同敏. 基于DBN-SVM的航空发动机健康状态评估方法[J]. 控制工程, 2021, 28(6):1163-1170.  
SUN Tongmin. Research on aero engine health state assessment using DBN and SVM[J]. Control Engineering of China, 2021, 28(6): 1163-1170.
- [21] HINTON G E. Training products of experts by minimizing contrastive divergence[J]. Neural Computation, 2002, 14(8): 1771-1800.
- [22] HUANG Guangbin, ZHOU Hongming, DING Xiaojian, et al. Extreme learning machine for regression and multiclass classification [J]. IEEE Transactions on Systems, Man, and Cybernetics. Part B, Cybernetics: A Publication of the IEEE Systems, Man, and Cybernetics Society, 2012, 42(2):513-529.
- [23] HUANG Guangbin. An insight into extreme learning machines: Random neurons, random features and kernels[J]. Cognitive Computation, 2014, 6(3):376-390.
- [24] 杨锡运, 关文渊, 刘玉奇, 等. 基于粒子群优化的核极限学习机模型的风电功率区间预测方法[J]. 中国电机工程学报, 2015(s1):146-153.  
YANG Xiyun, GUAN Wenyuan, LIU Yuqi, et al. Prediction intervals forecasts of wind power based on PSO - KELM[J]. Proceedings of the CSEE, 2015(s1): 146-153.
- [25] XUE Jiankai, BO Shen. A novel swarm intelligence optimization approach: Sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1):22-34.
- [26] 李雅丽, 王淑琴, 陈倩茹, 等. 若干新型群智能优化算法的对比研究[J]. 计算机工程与应用, 2020, 56(22): 1-12.  
LI Yali, WANG Shuqin, CHEN Qianru, et al. Comparative study of several new swarm intelligence optimization algorithms[J]. Computer Engineering and Applications, 2020, 56(22): 1-12.
- [27] 毛清华, 张强, 毛承成, 等. 混合正弦余弦算法和Lévy飞行的麻雀算法[J]. 山西大学学报(自然科学版), 2021(6):1086-1091.  
MAO Qinghua, ZHANG Qiang, MAO Chengcheng, et al. Mixing sine and cosine algorithm with Lévy flying chaotic sparrow algorithm[J]. Journal of Shanxi University(Natural Science Edition), 2021(6): 1086-1091.
- [28] 李腾飞, 郝玉杰, 袁方, 等. 基于多源特征信息融合的油浸式变压器故障智能诊断模型[J]. 电工电能新技术, 2023, 42(1): 48-57.  
LI Tengfei, HAO Yujie, YUAN Fang, et al. Intelligent transformer fault diagnosis model based on multi-source feature information fusion[J]. Advanced Technology of Electrical Engineering and Energy, 2023, 42(1): 48-57.

徐松晓(1981—), 男, 硕士, 高级工程师, 主要研究方向为电力系统及其自动化(E-mail: xusongxiao@163.com)。

赵军愉(1989—), 男, 硕士研究生, 工程师, 主要研究方向为电力系统及其自动化(E-mail: 770015335@qq.com)。

张元波(1984—), 男, 硕士, 高级工程师, 主要研究方向为电力系统及其自动化(E-mail: 437106183@qq.com)。

王艳(1981—), 女, 博士, 副教授, 主要研究方向为电力设备态势感知与智能运维、电力系统通信、电力系统继电保护(通信作者)(E-mail: 18288061@qq.com)。