

基于 MIC 与 IAOA-DBN 的充油电缆终端故障诊断方法

连鸿松¹, 杨静雨², 李长云²

(1. 国网福建省电力有限公司电力科学研究院, 福州 350007;
2. 山东科技大学电气与自动化工程学院, 青岛 266590)

摘要: 高压充油电缆终端的可靠运行是电缆线路稳定运行的前提, 但传统充油电缆终端故障诊断模型存在效率低、可靠性差等问题。为准确判断充油电缆终端故障, 提出一种最大互信息系数(maximal information coefficient, MIC)结合改进阿基米德算法(improved Archimedes optimization algorithm, IAOA)优化深度置信网络(deep belief network, DBN)的充油电缆终端故障诊断方法。首先, 采用 MIC 理论对电缆终端用硅油中溶解气体浓度的特征量进行降维处理并提取特征量; 其次, 将优选的特征量作为 DBN 网络模型的输入, 并针对 DBN 网络超参数选取困难的缺点, 提出采用 IAOA 优化 DBN 网络模型的超参数; 再者, 针对 AOA 算法容易陷入局部最优和搜索能力差等不足, 引入多种改进策略优化 AOA 的方法提高 AOA 的寻优能力。最后, 通过搭建充油电缆终端故障模拟实验平台, 收集充油电缆终端故障样本数据并创建类别样本标签, 验证了该模型的可行性。实例表明, 所提出的诊断方法可以较好地完成故障诊断, 测试集的准确率为 98.33%。与传统故障诊断模型相比, 该方法稳定性好、识别精度高, 可为保障高压充油电缆终端的可靠运行提供理论基础。

关键词: 充油电缆终端; 故障诊断; 最大互信息系数; 改进阿基米德优化算法; 深度置信网络

Fault Diagnosis Method for Oil Filled Cable Terminals Based on MIC and IAOA-DBN

LIAN Hongsong¹, YANG Jingyu², LI Changyun²

(1. Electric Power Research Institute, State Grid Fujian Electric Power Co., Ltd., Fuzhou 350007, China;

2. College of Electrical Engineering and Automation, Shandong University of Science and Technology, Qingdao 266590, China)

Abstract: The reliable operation of high-voltage oil-filled cable terminals is a prerequisite for the stable operation of cable lines, but the traditional diagnosis model for oil-filled cable terminal faults has problems such as low efficiency and poor reliability. In order to accurately judge oil-filled cable terminal faults, this paper proposes a fault diagnosis method for oil filled cable terminals based on the maximum mutual information coefficient (MIC) and the improved Archimedes optimization algorithm (IAOA) to optimize the deep trust network (DBN). Firstly, the MIC theory is used to reduce the dimensionality of the dissolved gas concentration in the silicone oil filling agent for cable terminals and perform feature extraction. Secondly, the optimal feature quantity is taken as the input of the DBN network model, and in view of the difficulty in selecting the hyperparameter of the DBN network, the IAOA is proposed to optimize the hyperparameter of the DBN network model. It is easy for the AOA algorithm to fall into local optimization and weak search ability, thus a variety of improvement strategies are introduced to optimize the optimization performance of the AOA method and improve the optimization ability of the AOA. Finally, the feasibility of the model was verified by constructing experimental platform for simulation of oil filled cable terminal faults, collecting fault sample data of oil filled cable terminals, and creating category sample labels. The example verification shows that the oil filled cable fault diagnosis method proposed in this paper can be adopted to effectively complete fault diagnosis, with an accuracy of 98.33% in the test set. Compared with traditional fault diagnosis models, the proposed method has good stability and high recognition accuracy, which can provide a theoretical basis for guaranteeing the reliable operation of high-voltage oil filled cable terminals.

Key words: oil filled cable terminal; fault diagnosis; maximal information coefficient; improved Archimedes optimization algorithm; deep belief network

0 引言

输电线路中的高压充油电缆终端对电能输送起着关键作用，且常以硅油作为绝缘填充剂。电缆充油终端用硅油易受到水分及电、机械和热等应力的综合作用使得其绝缘强度降低，从而使电缆终端成为电缆线路的绝缘薄弱环节^[1-2]。充油电缆终端的运行过程中，其填充剂硅油会产生 H₂、CH₄、C₂H₆、C₂H₂、C₂H₄、CO、CO₂ 等气体^[3-4]。这些气体的种类、含量大小以及不同气体间含量的比例关系将是判断高压充油电缆终端故障类型的关键。

当充油电缆终端内部温度过高或者存在局部/火花放电现象时，硅油会发生裂解，使得硅油中溶解气体的含量与种类迅速发生改变^[5-6]。例如硅油内部发生高能放电现象时，H₂ 和 C₂H₂ 的含量会迅速增多，此时，二者的相关系数较大；硅油高温过热时，CH₄ 和 C₂H₄ 含量升高，二者的相关系数较大。油中溶解气体分析(dissolved gas analysis, DGA)准则可为充油电缆终端的故障诊断提供理论支撑^[7-8]，进而为保障电缆终端可靠运行提供一定理论基础与技术支撑。

目前，DGA 法广泛用于评估油浸式电力设备中的故障^[9]，比如 IEC 三比值法^[10]、Rogers 比值法^[11]、大卫三角形^[12]等方法。不可否认，传统 DGA 方法在工程应用中发挥了重要作用，但这些方法由于采用线性分类，一定程度上会降低故障类型识别的准确性。另一方面，人工智能技术的快速发展，亦使油浸式电力设备的故障诊断方法趋于智能化。神经网络^[13-14]、模糊理论算法^[15-16]、支持向量机(support vector machine, SVM)^[17]、分类回归树^[18]等方法已应用于电力设备故障识别中。这些方法相较于传统方法有了较大进步，但仍存在一些不足之处。神经网络在一定程度上可以完成非线性映射，在故障分类时比线性函数更精确，但在处理大样本数据时收敛速度慢，且对新数据的泛化性能较弱。模糊理论算法利用粗糙的模型理论，能较好解决多分类边界样本划分问题，但在选择隶属度函数与划分输出空间方面缺少一定的客观性。SVM 在小样本数据的训练上有突出优势，但对于大量 DGA 数据及多种故障分类的处理效率不高。以上方法普遍存在学习能力不足、处理效率较低、特征提取能力欠缺等问题。

随着大数据分析技术的发展及电力设备在线监测的普及，数据样本愈发庞大，IEC 三比值法、

Rogers 比值法和大卫三角形法等传统 DGA 方法难以提高故障辨识的准确度等要求，极大影响了诊断的结果。同时，充油电缆终端故障诊断的特征量是判断故障诊断类型的重要部分，因此，正确提取充油电缆终端故障诊断的关键特征量，有助于提高充油电缆终端故障诊断模型的准确性。尽管经典方法对于输入特征没有明确规定，但最大互信息系数(maximal information coefficient, MIC)作为信息论中一种十分便捷的信息度量方法^[19]，能快速计算出变量之间的相关性。因此，本文采用最大互信息策略进行特征提取。

2006 年由 Hinton 等人提出的优化深度置信网络(deep belief network, DBN)^[20-21]在数据处理与特征优选方面有较大的优势，并且在处理辨识问题等方面表现优异。因此，本文以充油电缆终端故障诊断为研究对象，以硅油中溶解气体浓度分析为出发点，提出了基于 MIC 特征优选与 DBN 相结合的充油电缆终端故障诊断方法；为解决 DBN 网络参数选取困难的问题，采用改进阿基米德算法(improved Archimedes optimization algorithm, IAOA)求解超参数，进一步得到 DBN 网络模型的最佳参数；最后建立了基于 MIC 与 IAOA-DBN 的充油电缆终端故障诊断模型，有效提高了充油电缆终端故障诊断的识别精度，对进一步提高高压充油电缆终端的使用寿命和运行安全性提供了技术支撑。

1 理论基础

1.1 最大互信息系数

互信息经常用来评估两个变量间的相关性，即在一个变量确定后，可知另一个变量的相关程度。互信息 $I(X;Y)$ 的计算式如下：

$$I(X;Y) = \iint_{X,Y} P(X,Y) \lg \frac{P(X,Y)}{P(X)P(Y)} \quad (1)$$

式中： $P(X,Y)$ 表示参数 X 、 Y 的联合密度分布函数； $P(X)$ 与 $P(Y)$ 分别为 X 、 Y 的边缘密度分布函数。

MIC 是 David N. Reshef 等人提出的理论，用于衡量两个变量间的相互依存关系。MIC 具有普适性和等价性，普适性是指在大多数情况下对多种函数关系都比较敏感，适用于线性、指数型等多种函数类型；等价性是指当加入相同噪声于不同函数关系类型中时，二者间的 MIC 值相近。本文采用 MIC 对充油电缆终端故障特征之间的相关性进行计算。

MIC 方法不仅具备互信息的优势，而且改善了

互信息的不足, 优于传统互信息方法, 它通过查找一种优异的离散化方式, 将样本之间的互信息值转化为某种衡量模式, 通过 MIC 指标判断相关性的强弱, 其取值区间在[0,1]。

MIC 的值 M_{ic} 的计算式为:

$$M_{ic}(X;Y) = \max_{n_X n_Y < B''} \frac{I(X;Y)}{\log_2 \min(n_X, n_Y)} \quad (2)$$

式中: n_X 与 n_Y 分别为进行散点图网格划分时各坐标轴的单元格数量; B'' 约为数据量的 0.6 次方。

1.2 深度置信网络

DBN 是一种能够较好地完成特征识别、数据分类以及生成数据的模型, 在机器学习领域得到广泛应用。DBN 网络结构由受限玻耳兹曼机(restricted Boltzmann machine, RBM)堆叠组成, 包括输入层、隐藏层以及输出层。在 DBN 模型中, 任意两个相邻层均可视为 RBM 结构, 输入层中的神经元数与输入数据维数相同, 用于从底层接收数据, 并将计算结果输入到隐藏层。DBN 网络模型如图 1 所示。

DBN 网络通过概率生成模型完成数据与类别之间的组合分布, 逐层训练并优化网络, 生成一个最大概率训练数据的网络结构, 挖掘数据之间的相关性, 实现分类和辨识的任务。同一层间的神经元彼此相互独立, 使网络具有良好的独立性, 使网络的计算能力得到改善, 进一步提高了网络的训练速度。

DBN 模型的训练过程可以概括为两个阶段: 无监督学习 CD 阶段以及有监督学习 BP 阶段。在无监督训练过程中, 前一个 RBM 的输出结果是下一个 RBM 的输入量, 每个 RBM 都要经历正向计算和反向重构两个过程, 经过不同批次的多次迭代, 最终得到每个 RBM 的最优参数。在反向微调过程中, RBM 提取原始数据特征, 然后利用顶层分类器进行分类, 最后通过 BP 算法结合类别信息对相关参数进行自上而下的微调, 求出最优解。

1.3 阿基米德优化算法

AOA 算法中, 群体个体是浸没对象, 在搜索过程中, 随机初始化物体的体积、密度、加速度参数以及每个对象的位置^[22-23]。在 AOA 迭代过程中, 不断计算种群的适应度, 直到满足迭代终止条件。在迭代过程中, 个体不断调整自身密度、体积与加速度参数, 让自身实现平衡。算法的详细流程如下所述。

初始化种群中所有个体的位置、体积、密度和加速度, 具体计算式如式(3)—(5)所示。

$$O_i = l_{bi} + r_{rand}(u_{bi} - l_{bi}), i=1,2,\dots,N \quad (3)$$

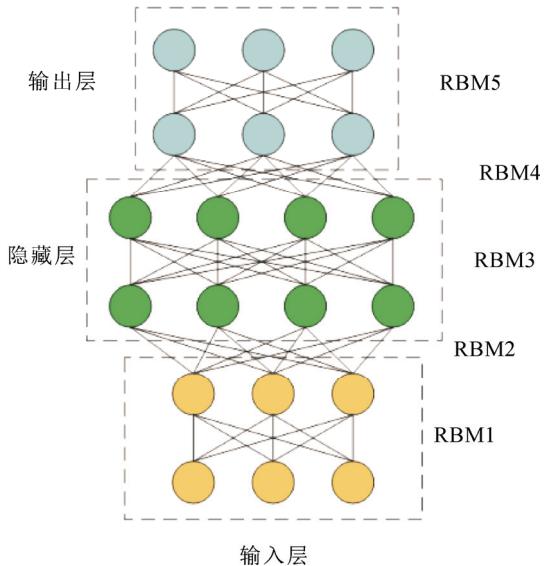


图 1 DBN 网络结构

Fig.1 DBN network structure

$$\begin{cases} d_{deni} = r_{rand} \\ v_{voli} = r_{rand} \end{cases} \quad (4)$$

$$a_{acci} = l_{bi} + r_{rand}(u_{bi} - l_{bi}) \quad (5)$$

式中: O_i 是第 i 个个体的位置; u_{bi} 、 l_{bi} 分别为搜索范围的上、下边界; r_{rand} 是[0,1]间的随机数, d_{deni} 、 v_{voli} 和 a_{acci} 分别为第 i 个个体的密度、体积和加速度。

个体 i 的适应度 f_{fiti} 可由式(6)计算, 其值越小, 个体越优。

$$f_{fiti} = f(x_i), i=1,2,\dots,N \quad (6)$$

个体 i 的体积和密度更新式如式(7)所示。

$$\begin{cases} d_{deni}^{\eta+1} = d_{deni}^{\eta} + r_{rand}(d_{denb}^{\eta} - d_{deni}^{\eta}), \\ v_{voli}^{\eta+1} = v_{voli}^{\eta} + r_{rand}(v_{volb}^{\eta} - v_{voli}^{\eta}) \end{cases}, \quad i=1,2,\dots,N \quad (7)$$

式中: η 表示当前迭代次数; d_{deni}^{η} 、 $d_{deni}^{\eta+1}$ 是第 η 与 $\eta+1$ 代第 i 个个体的密度; v_{voli}^{η} 、 $v_{voli}^{\eta+1}$ 是第 η 与 $\eta+1$ 代第 i 个个体的体积。

若液体中的物体发生碰撞, 则 AOA 为局部搜索阶段, 若未发生碰撞, 则 AOA 为全局搜索阶段, 设置转移因子(transfer factor, TF)范围在(0,1]之间, 计算式如下:

$$T_{tf} = \exp\left(\frac{\eta - \eta_{max}}{\eta_{max}}\right) \quad (8)$$

式中: η_{max} 表示最大迭代次数。

若 $T_{tf} \leq 0.5$, 则加速度更新计算式如下:

$$a_{acci}^{\eta+1} = \frac{d_{deni} + v_{volc} a_{acc}}{d_{deni}^{\eta+1} v_{voli}^{\eta+1}} \quad (9)$$

式中: 下标 c 为种群选的随机碰撞物体; d_{deni} 代表随机碰撞物体的密度; v_{volc} 代表随机碰撞物的体积;

a_{acc}^i 代表随机碰撞物体的加速度; $a_{\text{acci}}^{\eta+1}$ 是 $\eta+1$ 代第 i 个个体的加速度。

若 $T_{\text{tf}} > 0.5$, 则物体间无碰撞, 由式(10)更新加速度。

$$a_{\text{acci}}^{\eta+1} = \frac{d_{\text{denb}} + v_{\text{volb}} \cdot a_{\text{accb}}}{d_{\text{deni}}^{\eta+1} + v_{\text{voli}}^{\eta+1}} \quad (10)$$

采用式(11)对加速度进行归一化处理。

$$a_{\text{acci}-s}^{\eta+1} = u' \frac{a_{\text{acci}}^{\eta+1} - \min(a_{\text{acc}})}{\max(a_{\text{acc}}) - \min(a_{\text{acc}})} + l' \quad (11)$$

式中: $a_{\text{acci}-s}^{\eta+1}$ 是 $\eta+1$ 代第 i 个个体归一化的加速度; $\min(a_{\text{acc}})$ 、 $\max(a_{\text{acc}})$ 分别代表加速度矩阵中最小值和最大值; u' 和 l' 分别调整归一化范围。

若 $T_{\text{tf}} \leq 0.5$, 则属于勘探阶段, 各物体更新位置计算式如式(12)所示。

$$\mathbf{x}_i^{\eta+1} = \mathbf{x}_i^\eta + C'_1 r_{\text{rand}} a_{\text{acci}-s}^{\eta+1} d(\mathbf{x}_{\text{rand}} - \mathbf{x}_i^\eta) \quad (12)$$

式中: \mathbf{x}_i^η 和 $\mathbf{x}_i^{\eta+1}$ 分别为第 i 个个体在第 η 、 $\eta+1$ 次迭代的位置向量; C'_1 是常数, 本文取 2; x_{rand} 表示第 i 个随机个体在第 η 次迭代的位置向量; d 是密度因子。

若 $T_{\text{tf}} > 0.5$, 则属于局部探索阶段, 各物体按式(13)进行位置更新。

$$\mathbf{x}_i^{\eta+1} = \mathbf{x}_{\text{best}}^\eta + F C'_2 r_{\text{rand}} a_{\text{acci}-s}^{\eta+1} d(T \mathbf{x}_{\text{best}} - \mathbf{x}_i^\eta) \quad (13)$$

式中: C'_2 为常数, 本文取 6; x_{best} 为全局最优个体; T 定义为 $T = C'_3 T_{\text{tf}}$, C'_3 为常数, 本文取 2; F 代表改变运动方向的标志, 其定义如式(14)所示:

$$F = \begin{cases} +1, P \leq 0.5 \\ -1, P > 0.5 \end{cases} \quad (14)$$

式中: $P = 2r_{\text{rand}} - C'_4$, C'_4 为常数, 本文取 2。

密度递减因子计算式如下所示:

$$d^{\eta+1} = \exp\left(\frac{\eta_{\text{max}} - \eta}{\eta_{\text{max}}}\right) - \left(\frac{\eta}{\eta_{\text{max}}}\right) \quad (15)$$

1.4 多策略改进阿基米德优化算法

为进一步扩大算法的搜索空间, 本文采用混沌理论对种群进行初始化多样性处理, 从而改善算法的优化性能。优化原理可概括为: 采用映射原理构造混沌序列, 再转化到寻优变量空间中。因为 cos 混沌模型是一种多重映射折叠的混沌模型, 具有尺度多样性和随机性的特点, 所以本文首先采用 cos 混沌处理初始种群, 然后建立反向种群; 最后, 对比分析反向种群与 cos 混沌种群二者的适应度指标, 择优选择初始种群, 从而有助于寻找到最优解。cos 混沌映射计算式如式(16)所示。

$$\begin{cases} X'_{n+1} = \cos\left(\frac{2}{X'_n}\right), n = 0, 1, \dots, N \\ -1 \leq X'_n \leq 1, \quad X'_n \neq 0 \end{cases} \quad (16)$$

式中: X'_n 在 $(-1, 1)$ 之间, 初值不为 0, 将 cos 混沌序列映射到解空间, 得到 cos 混沌种群, 种群个体可由式(17)计算。

$$X'_{i+1,j} = \cos\left(\frac{2}{X'_{i,j}}\right) \quad (17)$$

式中, $X'_{i+1,j}$ 为第 $i+1$ 个 cos 混沌种群的第 j 维数值。

由 cos 混沌种群计算反向种群, 反向种群个体可由式(17)计算。

$$X_{ij}^* = x'_{\min j} + x'_{\max j} - X'_{ij} \quad (18)$$

式中: $[x'_{\min j}, x'_{\max j}]$ 为搜索范围边界。

标准 AOA 算法是依靠种群中随机个体计算种群位置, 缺少先验条件, 并且不能保证随机个体是更优的解, 导致算法的整体优化性能较差。为改善标准 AOA 算法的寻优性能, 本文引入算数交叉算子思想, 对应算式见式(19)。

$$X_{\text{new}}^{\eta+1} = \chi X_i^{\eta+1} + (1 - \chi)(X_{\text{best}} - X_i^{\eta+1}) \quad (19)$$

式中: χ 为 $(0, 1)$ 的随机数。

采用算数交叉算子策略后, 可以加快群体向全局最优范围靠近的速度, 在一定程度上, 有助于丰富种群多样性。将全局最佳个体与当前个体交叉处理, 有助于提高算法的全局寻优能力, 但不能保证新个体优于原始个体。因此, 采用以下策略不断更新最优解, 计算式如式(20)所示。

$$X_i^{\eta+1} = \begin{cases} X_w^{\eta+1}, f(X_i^{\eta+1}) \geq f(X_w^{\eta+1}) \\ X_i^{\eta+1}, f(X_i^{\eta+1}) < f(X_w^{\eta+1}) \end{cases} \quad (20)$$

标准 AOA 算法中的密度递减因子策略对算法的全局寻优搜索能力有一定的限制, 因此本文参考余弦函数思想理论, 在求解中引入余弦函数, 其求解式如式(21)所示。

$$d^{\eta+1} = d_1 - (d_1 - d_2) \cos\left(\frac{\pi}{\omega_d} \left(\frac{\eta}{\eta_{\text{max}}}\right)^2\right) \quad (21)$$

式中: ω_d 为控制曲线平滑系数; d_1 指迭代初时密度递减因子初始值; d_2 指迭代末时密度递减因子终止值。

1.5 算法性能测试

采用基准测试函数可以合理评判算法的有效性, 为了评价 IAOA 算法的有效性, 选取以下测试函数对 IAOA 算法进行性能测试。测试函数如下:

1) Sphere 函数, 表达式为:

$$F_{01}(x) = \sum_{i=1}^n x_i^2 \quad (22)$$

设置维度 30, 范围区间在[-100,100], 函数最小值为 0。

2) Schwefel2.22 函数, 表达式为:

$$F_{02}(x) = \sum_{i=1}^n |x_i| + \prod_{i=1}^n |x_i| \quad (23)$$

设置维度 30, 范围区间在[-10,10], 函数最小值为 0。

3) Schwefel1.2 函数, 表达式为:

$$F_{03}(x) = \sum_{i=1}^n \left(\sum_{j=1}^i x_j \right)^2 \quad (24)$$

设置维度 30, 范围区间在[-100,100], 函数最小值为 0。

4) Schwefel2.21 函数, 表达式为:

$$F_{04}(x) = \max_i \{|x_i|, 1 \leq i \leq D\} \quad (25)$$

设置维度 30, 范围区间在[-100,100], 函数最小值为 0。

5) Ackley 函数, 表达式为:

$$F_{05}(x) = -20 \exp(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} - \exp(\frac{1}{n} \sum_{i=1}^n \cos 2\pi x_i)) + 20 + e \quad (26)$$

设置维度 30, 范围区间在[-20,20], 函数最小值为 0。

6) Rastrigin 函数, 表达式为:

$$F_{06}(x) = \sum_{i=1}^n \left(x_i^2 - 10 \cos(2\pi x_i) + 10 \right) \quad (27)$$

设置维度 30, 范围区间在[-5,5], 函数最小值为 0。

为了验证本文所提的 IAOA 算法寻优性能, 本文对 IAOA 进行了性能测试, 将 AOA 算法与 IAOA 算法的种群规模均设置为 30, 迭代次数设置为 1000, 将 F_{01} ~ F_{06} 基准测试函数连续独立运行 20 次, 得到两者算法的均值、标准差、最差值与最优值作为衡量标准来验证算法性能。标准差越大, 说明算法鲁棒性能越弱, 最差值和最优值分别代表最差、最佳适应度值。算法的收敛结果如表 1 所示。

由表 1 知, 对比分析各测试函数的评价指标, IAOA 法求解结果中标准差和平均值相对最小, 说明 IAOA 算法在求解精度与稳定性方面要高于 AOA 算法, 尤其是对于测试函数 F_{06} 而言, 其指标已经达到了理论最优值。

2 基于 MIC 与 IAOA-DBN 电缆终端故障诊断模型

2.1 特征优选

当充油电缆终端处于不同电、热环境而产生不

同故障时, 硅油产生的特征气体的主次以及含量也不同。因此, 为能够较全面找到优选特征量, 初步采用的特征气体比值有以下 9 种: CH_4/H_2 、 $\text{C}_2\text{H}_4/\text{C}_2\text{H}_2$ 、 $\text{C}_2\text{H}_4/\text{C}_2\text{H}_6$ 、 $\text{C}_2\text{H}_2/(\text{C}_1+\text{C}_2)$ 、 $\text{H}_2/(\text{H}_2+\text{C}_1+\text{C}_2)$ 、 $\text{C}_2\text{H}_4/(\text{C}_1+\text{C}_2)$ 、 $\text{CH}_4/(\text{C}_1+\text{C}_2)$ 、 $\text{C}_2\text{H}_6/(\text{C}_1+\text{C}_2)$ 与 $(\text{CH}_4+\text{C}_2\text{H}_4)/(\text{C}_1+\text{C}_2)$ 。其中, $\text{C}_1=\text{CH}_4+\text{C}_2\text{H}_6$, $\text{C}_2=\text{C}_2\text{H}_4+\text{C}_2\text{H}_2$, 若使用所有特征气体比值作为特征输入, 则会由于特征维数过多而使诊断模型的结构复杂, 因此, 本文采用 MIC 对气体的特征比值进行约简, 上述 9 种特征量与故障类型之间的 MIC 值如表 2 所示。

以 MIC 指标 0.45 为参考, 筛选后的输入特征量可选用下述 6 种: CH_4/H_2 、 $\text{C}_2\text{H}_4/\text{C}_2\text{H}_2$ 、 $\text{C}_2\text{H}_4/\text{C}_2\text{H}_6$ 、 $\text{C}_2\text{H}_2/(\text{C}_1+\text{C}_2)$ 、 $\text{H}_2/(\text{H}_2+\text{C}_1+\text{C}_2)$ 。

2.2 IAOA-DBN 故障诊断模型

将优选特征量作为 DBN 诊断模型的输入, 并规范化处理。采用表 3 所示 one-hot 编码方式, 将充油电缆终端故障类型以编码方式按列向量排序, 构造类别特征矩阵。

表 1 函数寻优结果比较表

Table 1 Function optimization result comparison

测试函数	方法	最优值	最差值	平均值	标准差
F_{01}	AOA	1.13×10^{-6}	2.90×10^{-4}	4.99×10^{-5}	7.728×10^{-5}
	IAOA	2.74×10^{-7}	6.66×10^{-5}	4.28×10^{-6}	1.527×10^{-7}
F_{02}	AOA	6.77×10^{-4}	7.83×10^{-3}	2.65×10^{-3}	1.62×10^{-3}
	IAOA	6.58×10^{-4}	4.49×10^{-3}	2.49×10^{-3}	1.001×10^{-3}
F_{03}	AOA	5.783	110.361	42.926	28.176
	IAOA	5.89	2.18	13.57	4.920
F_{04}	AOA	1.391	5.302	2.451	1.056
	IAOA	1.086	4.553	2.72	1.013
F_{05}	AOA	0.000 17	1.157	0.060 0	0.258
	IAOA	0.000 088	0.888	0.008 8	0.202
F_{06}	AOA	14.596	32.327	21.957	5.034
	IAOA	0	0	0	0

表 2 MIC 系数值

Table 2 MIC coefficient value

特征序号	特征量	MIC
1	CH_4/H_2	0.487 2
2	$\text{C}_2\text{H}_4/\text{C}_2\text{H}_2$	0.638 6
3	$\text{C}_2\text{H}_4/(\text{C}_1+\text{C}_2)$	0.342 3
4	$\text{CH}_4/(\text{C}_1+\text{C}_2)$	0.281 2
5	$\text{C}_2\text{H}_4/\text{C}_2\text{H}_6$	0.482 3
6	$\text{C}_2\text{H}_2/(\text{C}_1+\text{C}_2)$	0.672 9
7	$\text{H}_2/(\text{H}_2+\text{C}_1+\text{C}_2)$	0.505 3
8	$\text{C}_2\text{H}_6/(\text{C}_1+\text{C}_2)$	0.434 9
9	$(\text{CH}_4+\text{C}_2\text{H}_4)/(\text{C}_1+\text{C}_2)$	0.335 8

表 3 充油式电缆终端故障类型编码

Table 3 Fault type code for oil filled cable terminals

编号	故障类型	编码
1	低能放电	100 000
2	高能放电	010 000
3	中低温过热	001 000
4	高温过热	000 100
5	正常	000 010
6	局部放电	000 001

2.3 IAOA-DBN 故障诊断流程

通过 IAOA 算法对 DBN 网络的隐层节点数、学习率因子以及反向微调次数等参数进行寻优, IAOA-DBN 充油电缆终端故障诊断流程见图 2。详细步骤如下:

第 1 步: 搭建充油电缆终端电、热故障实验平台, 获得多组故障数据集对应的气体组分及含量。

第 2 步: 确定输入 IAOA-DBN 充油电缆终端故障诊断模型的输入样本特征量, 对输出故障类型编码。

第 3 步: 将输入特征量归一化处理, 并划分训练集与测试集数据样本。

第 4 步: 设置 IAOA 算法相关参数、DBN 网络每层神经元的取值范围以及搜索范围。

第 5 步: 训练 DBN 网络, 将 DBN 网络诊断的错误率作为优化的目标函数值。

第 6 步: 根据适应度值确定搜索方向, 比较个体与群体最优解, 提升模型正确率。

第 7 步: 若满足迭代终止条件, 则得到 DBN 模型最佳参数值, 否则返回第 5 步。

第 8 步: 根据 IAOA 优化获得的最佳参数指标建立 DBN 网络模型。

第 9 步: 将测试集样本输入到训练好的网络中, 输出模型诊断结果。

优化后网络模型的最佳参数设置如表 4 所示。

3 实验与算例分析

分别搭建了充油电缆终端过热及放电故障实验平台, 通过气相色谱分析得到充油电缆终端不同故障类型下硅油中溶解气体浓度的特征气体含量, 进而验证 MIC 与 IAOA-DBN 充油电缆终端故障诊断模型的有效性。

3.1 充油电缆终端内部硅油过热实验平台

首先, 选用 PMX- 200 型运动黏度为 $100 \text{ mm}^2/\text{s}$

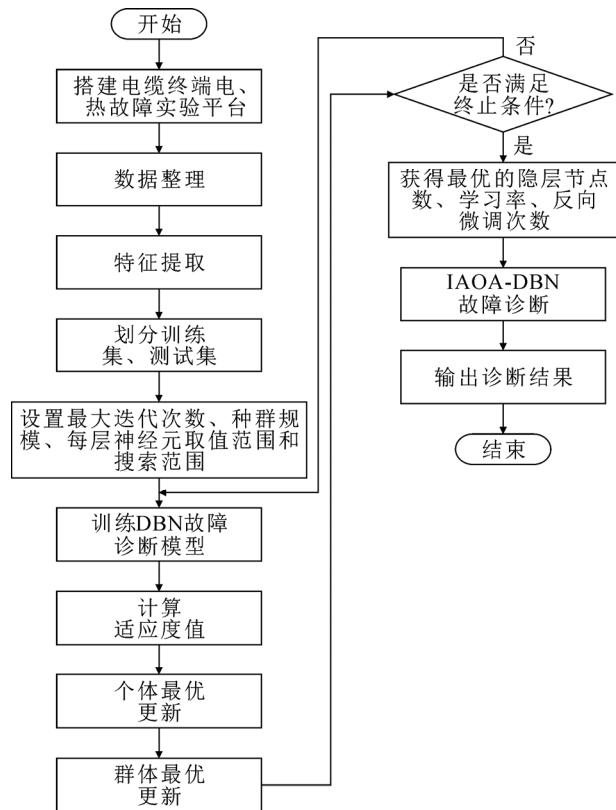


图 2 基于 IAOA-DBN 的充油电缆终端故障诊断流程图

Fig.2 Flow chart for fault diagnosis of oil filled cable terminals based on IAOA-DBN

表 4 参数设置及含义

Table 4 Parameter setting and meaning

参数名	参数含义	最佳参数值
numepochs	反向微调次数	100
batchsize	批尺寸	10
momentum	动量	0
alpha	学习率因子	0.1
dbn.size1	第 1 层神经元个数	19
dbn.size2	第 2 层神经元个数	19
dbn.size3	第 3 层神经元个数	19

的硅油为原材料, 将油杯置于电-热老化实验箱中, 依据《电缆终端绝缘油中溶解气体分析导则(报批稿)》设定正常情况(无故障)、中低温过热故障(120°C)、高温过热故障(180°C)进行过热老化实验。

其次, 圆柱形油杯为石英材质, 直径为 15 cm , 高度为 30 cm ; 黄铜针-板电极的板电极直径为 5 cm , 厚度为 0.5 cm ; 针电极尖部夹角为 30° 。实验箱为 WBL- 230NB 型干燥箱改造而成, 其控温范围为室温至 300°C , 温度误差为 $\pm 1^\circ\text{C}$ 。每一情况下的详细实验步骤如下:

取适量硅油(800 mL)样品进行脱气及干燥处

理; 取 2 组适量硅油(200 mL)分别于容积为 800 mL 的油杯内, 将其放于高温老化箱中进行热老化实验; 分别设置老化箱的温度和外加电压, 进行加速热老化实验; 设置热老化时间每隔 24 h 取样一次, 分别取两组不同老化温度下的硅油样品。

最后, 对老化后的油样进行气相色谱分析。实验中, 对硅油中溶解气体含量每个试样均测试 2 次, 取其平均值, 若几次平行测试结果分散性较大, 则对该项数据重新测试, 以获得多组可靠的中低温过热、高温过热条件下的硅油中溶解特征气体的含量。所用设备及型号为:

ZKPZD-5A 多功能脱气振荡仪, 50 °C 下以恒温定时振荡器方式(控温精确度±0.3 °C; 往复振荡频率(275 ± 3)次/min, 振幅(35 ± 3) mm, 振荡 20 min 后静止 10 min)进行脱气; 采用 GC-2020 型气相色谱仪(双柱分流系统, 氢火焰检测器、氧化锆检测器、镍触媒转化器, GDX-502 色谱分析柱和 5A 分子筛)进行气相色谱分析。

3.2 充油电缆终端放电实验平台

依据《电缆终端绝缘油中溶解气体分析导则(报批稿)》设定正常情况(无故障)、低能放电故障(间歇性火花放电)、高能放电故障(连续火花放电)及局部放电进行电老化实验。实验中采用针-板电极(设置间距 0.5 cm)来模拟极不均匀电场, 选用恒稳直流电压(HY-DC300 型直流试验装置)对充油电缆终端用硅油进行低能放电、局部放电以及高能放电实验。

实验中, 采用 1.0 kV/s 的升压速率, 缓慢加压至硅油中发生间歇性击穿(试样中产生火花放电)时停止升压(对应电压约为 25 kV), 连续 2 次击穿间隔约为 3~5 s。利用 HYJF-2013 型局部放电测量仪采集局部放电信号, 待放电 10 次时停止加压, 老化实验结束。

对不同放电环境的油样进行气相色谱分析, 得到多组低能放电故障、高能放电故障以及局部放电故障下的硅油中溶解特征气体含量。

3.3 对比结果分析

本文所用数据为 2021-03-01—2021-08-31 期间 184 d 共 368 组硅油的气相色谱数据, 监测周期为 12 h。本文从测量得到的多组充油电缆终端故障样本数据中随机选取 300 个样本, 每种故障类型平均选取 250 个样本, 再从每种类别中随机选取 80% 的样本作为训练集, 剩余 20% 的样本作为测试集。采用 IAOA-DBN 方法诊断充油电缆终端的故障, 并

将诊断结果与 DBN、广义回归神经网络(general regression neural network, GRNN)、SVM 3 种常规的分类方法进行对比分析。部分充油电缆终端故障数据与故障类型如表 5 所示。不同充油电缆终端故障诊断模型的结果如表 6 所示。

从表 6 的测试集结果可以看出 SVM 模型的诊断准确率为 73.33%, GRNN 模型的诊断准确率为 70%, DBN 模型的诊断准确率优于 SVM 和 GRNN 模型, 其准确率达到了 81.67%, AOA-DBN 模型的诊断准确率为 91.67%, 而本文所提出的 IAOA-DBN 模型的诊准确率为 98.33%, 明显优于传统方法, 可以满足工程中实际需求。

本文对测试集的故障诊断结果进行详细分析, 图 3 是 IAOA-DBN 充油电缆终端测试集样本故障诊断结果与真实结果的对比分析图。其中纵坐标 1、2、3、4、5 及其 6 分别代表低能放电故障、高能放电故障、中低温过热故障、高温过热故障、正常情况及局部放电故障的 6 种故障类型, 蓝色圆圈表示充油电缆终端样本的真实故障类别, 红色加号表示充油电缆终端样本的模型诊断类别, 二者重合则表示模型诊断正确, 反之, 模型诊断错误。

图 4 为 GRNN 模型的故障诊断结果。由图 4 可以看出 GRNN 模型除了对充油电缆终端高温过热故障全部诊断正确外, 其余 5 种类别故障均存在一

表 5 部分充油电缆终端故障类型样本数据

Table 5 Sample data of partial oil filled cable terminal fault types

H_2	体积分数/ 10^{-6}				故障类型
	CH_4	C_2H_6	C_2H_4	C_2H_2	
102.72	33.82	7.74	19.60	4.86	低能放电
312.21	48.71	15.19	118.97	132.06	高能放电
6.32	194.21	118.56	127.45	2.12	中低温过热
82.31	119.20	32.20	234.21	3.45	高温过热
3.21	1.25	0.54	0.65	0.78	正常
652.10	50.21	34.23	21.01	21.36	局部放电

表 6 各种充油电缆终端故障诊断方法的实验结果

Table 6 Experimental results of various fault diagnosis methods for oil-filled cable terminals

算法	训练集准确率/%	测试集准确率/%
SVM	76.25	73.33
GRNN	72.92	70.00
DBN	83.75	81.67
AOA-DBN	90.83	91.67
IAOA-DBN	99.58	98.33

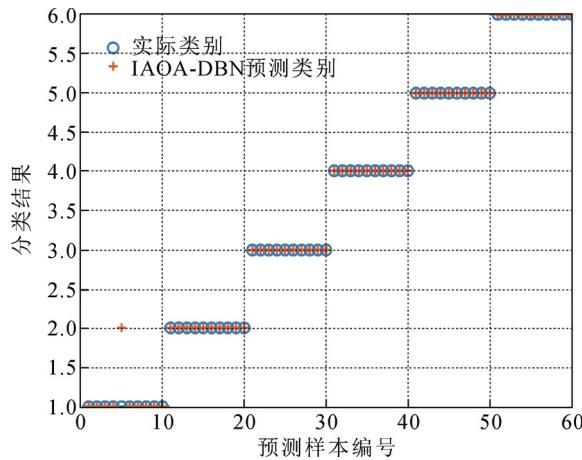


图3 IAOA-DBN 故障诊断结果

Fig.3 IAOA-DBN fault diagnosis results

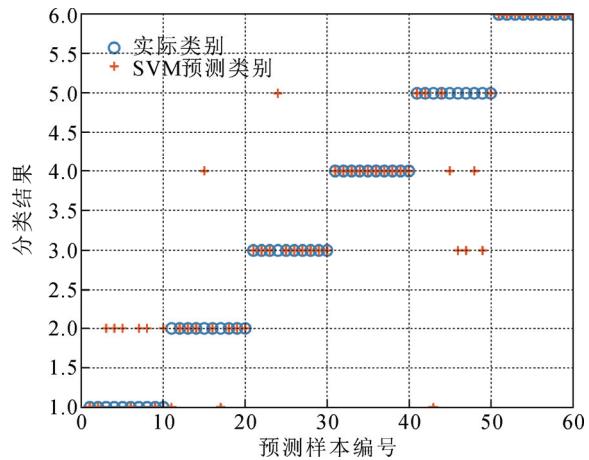


图5 SVM 故障诊断结果

Fig.5 SVM fault diagnosis results

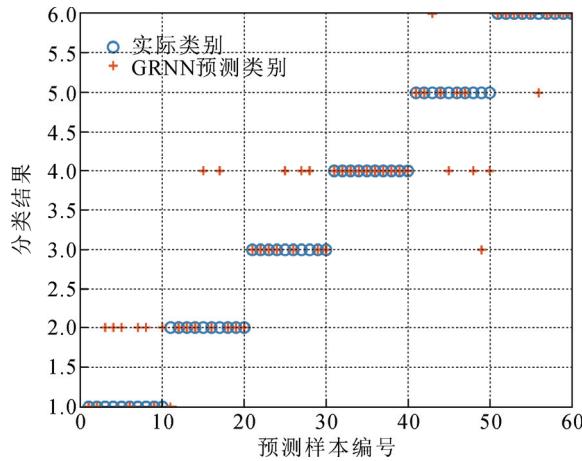


图4 GRNN 故障诊断结果

Fig.4 GRNN fault diagnosis results

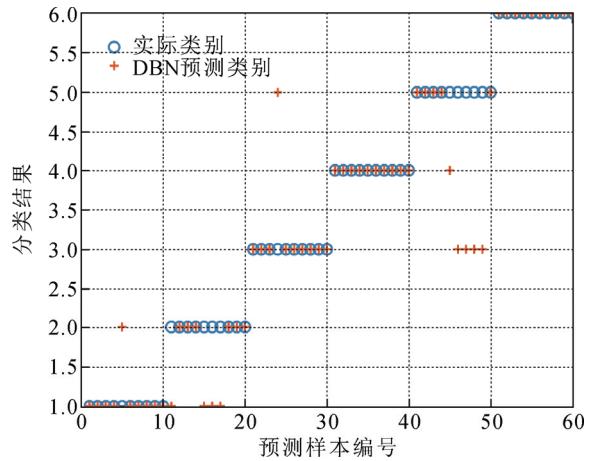


图6 DBN 故障诊断结果

Fig.6 DBN fault diagnosis results

定程度的诊断错误率，尤其是将低能放电故障诊断为高能放电故障。图5中展示了SVM充油电缆终端故障诊断的结果，SVM故障诊断结果中高温过热故障和局部放电故障均诊断正确，其余4种类别故障也存在一定程度的错误率，还是将低能放电故障误判为高能放电故障的数量较多。图6中展示了DBN充油电缆终端故障诊断模型的诊断结果，相比于SVM模型和GRNN模型，该模型表现出了较好的诊断结果，但依然存在个别样本的正常状态诊断成了中低温过热和高温过热故障。图7为AOA-DBN充油电缆终端故障诊断模型，其准确率相对于上述3种方法均有一定的提升。而本文提出的IAOA-DBN充油电缆终端故障诊断模型的结果，仅有个别低能放电故障误判为高能放电故障，明显优于上述几种充油电缆终端故障诊断模型的结果。

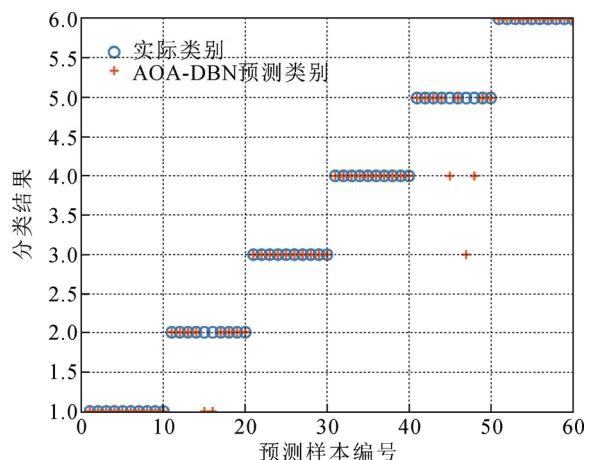


图7 AOA-DBN 故障诊断结果

Fig.7 AOA-DBN fault diagnosis results

基于上述对比结果分析，本文所提出的MIC与

IAOA-DBN 充油电缆终端故障诊断模型表现出优良的故障诊断正确率, 在有限充油电缆终端故障样本的情况下, 能够根据气相色谱分析得到的硅油中溶解特征气体数据样本, 实现准确可靠的充油电缆终端故障诊断。

4 结论

1) 传统的方法进行充油电缆终端故障诊断时, 准确率较低, 不能满足实时性等要求, 使用 MIC 理论来提取特征量, 可以提高充油电缆终端故障诊断模型的性能, 以保证模型的可靠性与诊断结果的准确性。

2) 针对 AOA 算法搜索能力存在的不足, 采用多策略改进 AOA 算法方法, 有助于提高 AOA 算法全局搜索和局部开发能力, 有效解决 DBN 模型参数选取困难的问题, 进一步提高了充油电缆终端故障诊断的准确率。

3) 通过模拟搭建充油电缆终端电、热故障实验平台, 收集了真实的充油电缆终端多重故障数据样本, 为基于 MIC 与 IAOA-DBN 的充油电缆终端故障诊断模型提供了数据支撑, 并且利用测试样本数据将本文方法的诊断结果与传统方法进行对比分析, 验证了诊断模型的可靠性。

此外, 本文所提出的方法不仅适用于处理多重故障状态下高压充油电缆终端的故障辨识问题, 而且在一定程度上对充油电缆终端的寿命评估提供了一定的参考价值, 有利于保障电缆终端的安全运行, 提供安全可靠的供电环境。

参考文献 References

- [1] 郭蕾, 曹伟东, 白龙雷, 等. 热氧老化 EPR 电缆绝缘局部放电特性及劣化机理[J]. 高电压技术, 2021, 47(1): 231-240.
GUO Lei, CAO Weidong, BAI Longlei, et al. Partial discharge characteristics and degradation mechanism of EPR cable insulation by thermo-oxygen aging[J]. High Voltage Engineering, 2021, 47(1): 231-240.
- [2] 王若丞, 贺云逸, 康洪玮, 等. 电缆接头绝缘用硅橡胶热老化及超声特性[J]. 高电压技术, 2021, 47(9): 3181-3188.
WANG Ruocheng, HE Yunyi, KANG Hongwei, et al. Thermal aging and ultrasonic characteristics of silicone rubber for cable joint insulation[J]. High Voltage Engineering, 2021, 47(9): 3181-3188.
- [3] 付朝霞. 220 kV 电缆终端硅油老化鉴定试验与分析[J]. 电力安全技术, 2013, 15(7): 27-29.
FU Zhaoxia. Aging identification test and analysis of silicone oil in 220 kV cable terminal[J]. Electric Safety Technology, 2013, 15(7): 27-29.
- [4] 李光茂, 乔胜亚, 朱晨, 等. 变压器油中溶解甲醇拉曼光谱检测定量分析方法[J]. 高电压技术, 2021, 47(6): 2007-2014.
LI Guangmao, QIAO Shengya, ZHU Chen, et al. Quantitative analysis method for Raman spectral detection of methanol dissolved in transformer oil[J]. High Voltage Engineering, 2021, 47(6): 2007-2014.
- [5] 刘展程, 王爽, 唐波. 基于 SSA-BiGRU-Attention 模型的变压器油中溶解气体含量预测[J]. 高电压技术, 2022, 48(8): 2972-2981.
LIU Zhancheng, WANG Shuang, TANG Bo. Prediction of dissolved gas content in transformer oil based on SSA-BiGRU-Attention model[J]. High Voltage Engineering, 2022, 48(8): 2972-2981.
- [6] 朱庆东, 朱文兵, 王浩哲, 等. 基于油中溶解气监测的变压器在线半监督故障诊断方法研究[J]. 电网技术, 2023, 47(3): 1031-1037.
ZHU Qingdong, ZHU Wenbin, WANG Haozhe, et al. Online semi-supervised fault diagnosis of transformer based on dissolved gas in oil[J]. Power System Technology, 2023, 47(3): 1031-1037.
- [7] 王健一, 李金忠, 凌愍, 等. 新版电力行业标准《变压器油中溶解气体分析判断导则》解读[J]. 变压器, 2014, 51(12): 49-53.
WANG Jianyi, LI Jinzhong, LING Min, et al. Interpretation of the new electricity industry standard guide to the analysis and the diagnosis of gases dissolved in transformer oil[J]. Transformer, 2014, 51(12): 49-53.
- [8] 张鹏, 齐波, 刘娟, 等. 电力变压器油中溶解气体数据的分布特征参数快速计算方法[J]. 中国电机工程学报, 2022, 42(5): 2001-2011.
ZHANG Peng, QI Bo, LIU Juan, et al. Fast calculation method for distribution characteristic parameters of dissolved gas data in power transformer oil[J]. Proceedings of the CSEE, 2022, 42(5): 2001-2011.
- [9] XIANG C M, HUANG Z Y, LI J, et al. Graphic approaches for faults diagnosis for camellia insulating liquid filled transformers based on dissolved gas analysis[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2018, 25(5): 1897-1903.
- [10] 张卫华, 苑津莎, 王杉, 等. 基于改良三比值法的变压器故障基本信度分配计算方法[J]. 电力系统保护与控制, 2015, 43(7): 115-121.
ZHANG Weihua, YUAN Jinsha, WANG Shan, et al. A calculation method for transformer fault basic probability assignment based on improved three-ratio method[J]. Power System Protection and Control, 2015, 43(7): 115-121.
- [11] KHANNA A, BISHT P. Rogers ratio test for fault diagnosis of transformer using dissolved gas analysis[J]. Materials Today: Proceedings, 2022, 71: 243-246.
- [12] SONI R, MEHTA B. Graphical examination of dissolved gas analysis by ratio methods and Duval triangle method to investigate internal faults of power transformer[J]. Materials Today: Proceedings, 2022, 62: 7098-7103.
- [13] PATEKAR K D, CHAUDHRY B. DGA analysis of transformer using artificial neural network to improve reliability in power transformers[C]//2019 IEEE 4th International Conference on Condition Assessment Techniques in Electrical Systems (CATCON). Chennai, India: IEEE, 2019: 1-5.
- [14] ZAN T, WANG H, WANG M, et al. Application of multi-dimension input convolutional neural network in fault diagnosis of rolling bearings[J]. Applied Sciences, 2019, 9(13): 2690.
- [15] XU A R, GU C L, LIU B L, et al. Research on fault diagnosis of microgrid based on variational sparse Bayesian fuzzy H-network[J]. International Journal of Low-Carbon Technologies, 2022, 17: 1-10.
- [16] 周健, 黄昕, 邹剑, 等. 变压器油中溶解气体故障诊断的改进模糊算法[J]. 广东电力, 2015, 28(3): 86-91.
ZHOU Jian, HUANG Xin, ZOU Jian, et al. Improved fuzzy algorithm for fault diagnosis on dissolved gas in transformer oil[J]. Guangdong Electric Power, 2015, 28(3): 86-91.

- [17] BENMAHAMED Y, KHERIF O, TEGUAR M, et al. Accuracy improvement of transformer faults diagnostic based on DGA data using SVM-BA classifier[J]. Energies, 2021, 14(10): 2970.
- [18] 黄新波, 李文君子, 宋桐, 等. 采用遗传算法优化装袋分类回归树组合算法的变压器故障诊断[J]. 高电压技术, 2016, 42(5): 1617-1623.
- HUANG Xinbo, LI Wenjunzi, SONG Tong, et al. Application of Bagging-CART algorithm optimized by genetic algorithm in transformer fault diagnosis[J]. High Voltage Engineering, 2016, 42(5): 1617-1623.
- [19] 张俐, 袁玉宇, 王枫. 基于最大相关信息系数的FCBF特征选择算法[J]. 北京邮电大学学报, 2018, 41(4): 86-90.
- ZHANG Li, YUAN Yuyu, WANG Cong. FCBF feature selection algorithm based on maximum information coefficient[J]. Journal of Beijing University of Posts and Telecommunications, 2018, 41(4): 86-90.
- [20] CHEN C, SHI J T, SHEN M Q, et al. Pseudo-label guided sparse deep belief network learning method for fault diagnosis of radar critical components[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 3510212.
- [21] 李锦键, 王兴贵, 杨维满, 等. 基于改进递归深度信念网络的CSP电站短期出力预测[J]. 太阳能学报, 2022, 43(7): 225-232.
- LI Jinjian, WANG Xinggui, YANG Weiman, et al. CSP station output power short-term forecast based on improved RNN-DBN[J]. Acta Energiae Solaris Sinica, 2022, 43(7): 225-232.
- [22] 罗仕杭, 何庆. 融合Sin混沌和分段权值的阿基米德优化算法[J]. 计算机工程与应用, 2022, 58(14): 63-72.
- LUO Shihang, HE Qing. Archimedes optimization algorithm combining Sin chaos and segmented weights[J]. Computer Engineering and Applications, 2022, 58(14): 63-72.
- [23] HASHIM F A, HUSSAIN K, HOUSSEIN E H, et al. Archimedes optimization algorithm: a new metaheuristic algorithm for solving optimization problems[J]. Applied Intelligence, 2021, 51(3): 1531-1551.



LIAN Hongsong
Professor



YANG Jingyu



LI Changyun
Ph.D.
Associate professor
Corresponding author

连鸿松

1973—, 男, 硕士, 教授级高工

主要从事高压电气设备状态监测与故障诊断方面的研究工作

E-mail: 13600819590@126.com

杨静雨

1998—, 男, 硕士生

研究方向为高电压与绝缘技术

E-mail: 1911418085@qq.com