

基于数据扩充和故障特征优化的 SCNGO-SVM-AdaBoost 变压器故障诊断技术

姚翔曦^{1,2}, 张英^{1,2}, 张国治³, 刘君², 王明伟²

(1. 贵州大学电气工程学院, 贵阳 550025; 2. 贵州电网有限责任公司电力科学研究院, 贵阳 550025; 3. 新能源及电网装备安全监测湖北省工程研究中心(湖北工业大学), 武汉 430068)

摘要: 针对传统油中溶解气体分析(dissolved gas analysis, DGA)在油浸变压器故障诊断过程中不能够有效地利用故障信息, 以及变压器故障样本类型不平衡致使模型诊断结果较差的情况, 提出了基于数据扩充和故障特征优化的 SCNGO-SVM-AdaBoost 变压器故障诊断技术。首先, 针对不平衡样本数据集利用安全级别合成少数过采样技术(safe-level synthetic minority over-sampling technique, safe-level SMOTE)对原始的变压器故障样本集进行了数据扩充, 然后利用核主成分分析(kernel principal component analysis, K-PCA)算法对比值化后的油色谱数据进行故障特征优化提取。其次在北方苍鹰优化算法(northern goshawk optimization, NGO)中融合了正余弦和折射反向学习策略, 利用测试函数验证该算法的稳定性和利用 SCNGO 优化算法提高其寻优能力。最后通过实际的未扩充样本诊断和其他方法诊断进行对比分析, 结果证明该方法能够有效地提高变压器故障诊断的性能。

关键词: 油浸式变压器故障诊断; 数据扩充; 特征优选; 支持向量机; SCNGO 优化算法; AdaBoost 算法

SCNGO-SVM-AdaBoost Transformer Fault Diagnosis Technology Based on Data Augmentation and Fault Feature Optimization

YAO Xiangxi^{1,2}, ZHANG Ying^{1,2}, ZHANG Guozhi³, LIU Jun², WANG Mingwei²

(1. Institute of Electrical Engineering, Guizhou University, Guiyang 550025, China; 2. Electrical Power Research Institute of Guizhou Power Grid Co., Ltd., Guiyang 550025, China; 3. Hubei Engineering Research Center for Safety Monitoring of New Energy and Power Grid Equipment, Hubei University of Technology, Wuhan 430068, China)

Abstract: The traditional dissolved gas analysis (DGA) in oil-immersed transformer fault diagnosis is unable to effectively utilize fault information, and the imbalance of fault sample types results in poor diagnostic model performance. To address this, a transformer fault diagnosis technique based on data augmentation and fault feature optimization, named SCNGO-SVM-AdaBoost, is proposed. Firstly, to handle the imbalanced sample dataset, the safe-level synthetic minority over-sampling technique (safe-level SMOTE) is used for data augmentation of the original transformer fault sample set. Then, kernel principal component analysis (K-PCA) is employed to optimize and extract fault features from the ratio-based oil chromatographic data. Secondly, the northern Goshawk optimization (NGO) algorithm is enhanced by integrating positive and negative cosine and refraction reverse learning strategies. The stability of this algorithm is verified using test functions and optimization capability is improved by the diagnostic algorithm. Through a comparative analysis of actual fault diagnosis using the original samples and other methods, the results show that this approach can effectively improve the performance of transformer fault diagnosis.

Key words: oil immersed transformer fault diagnosis; data augmentation; feature selection; support vector machine; SCNGO algorithm; AdaBoost algorithm

0 引言

变压器在发电、配电、输电等环节中都占据着十分重要的作用和地位,是保证电力系统稳定运行的核心枢纽^[1]。在运行年限、人为操作或者环境等因素的影响下,变压器会出现各种各样的故障情况,不仅可能导致大规模的停电和设备损坏,甚至严重情况还可能引发事故和造成人员伤亡^[2-3]。因此,准确、快速、及时地发现变压器的故障具有十分重要的意义^[4]。

当油浸式变压器内部出现某些故障时,故障部位在热量、电场力作用下,会导致变压器油和箱内绝缘材料裂解,从而产生与故障类型相关的特征气体并逐渐溶解在油中。其主要气体成分包括:甲烷(CH_4)、氢气(H_2)、乙炔(C_2H_2)、乙烯(C_2H_4)、乙烷(C_2H_6)以及一氧化碳(CO)、二氧化碳(CO_2)等^[5-6]。目前,业界对于油浸式变压器运行状态和潜在故障的判断常常采用的是油中溶解气体分析(dissolved gas analysis, DGA)及其衍生数理统计下的IEC三比值法^[7]、罗杰斯四比值^[8]、大卫三角形法^[9]等。这些方法虽然简单,但是需要人工参与判断,并且其故障类型的界限区分太过于绝对,有一定的局限性^[10]。近年来人工智能技术的快速发展为变压器故障诊断带来了新的机遇和变革。文献[11]采用了改进的深层一维卷积神经网络和融合分类模块利用油色谱数据对变压器进行故障诊断;文献[12]将深度学习与贝叶斯方法结合,构建基于概率分布权重单元的贝叶斯神经网络进行变压器故障诊断。然而神经网络或者深度学习都需要大量的故障样本做支撑,变压器故障只是小概率事件,且故障数据本身存在不平衡的特点,使得故障分类精度降低^[13-14]。支持向量机(support vector machine, SVM)本身具有良好的泛化性和鲁棒性,可以针对样本量情况较少的多类故障样本进行分类,但其诊断效果受到惩罚因子和核参数的影响,会导致诊断结果不佳^[15]。

鉴于此,本文引入了改良的北方苍鹰算法对SVM进行优化。相较于其他启发式算法,该算法具有更加稳定的寻优能力,能够避免陷入局部最优,有利于提高模型诊断的准确率。针对变压器故障数据呈长尾分布^[16]和故障类别的不均衡性问题,本文使用安全级别合成少数过采样技术(safe-level

SMOTE)对原始的变压器故障样本集进行了数据扩充,提升样本的均衡性,然后利用核主成分分析(kernel principal component analysis, K-PCA)对比值化后的油色谱数据进行气体数据故障特征优化提取,从而减小数据长尾分布的影响。最后将SCNGO-SVM引入集成算法的多个弱分类器的寻优过程中,利用AdaBoost集成学习为模型框架对原始模型进行强化,提高故障诊断模型的分类的准确率。

1 理论基础

1.1 安全级别合成少数过采样技术

安全级别合成少数过采样技术(safe-level SMOTE)是以合成少数过采样技术(synthetic minority over-sampling technique, SMOTE)为基础改进的数据平衡化扩充算法。safe-level SMOTE利用二次样本过滤的思想,根据少数类样本的安全级别(safe-level)来合成新的数据点,以确保生成的合成数据不会与邻近样本过于接近,从而维护了数据集的类别平衡^[17]。相较传统SMOTE对无信息和噪声样本进行过采样出现的过度泛化问题, safe-level SMOTE可以有效抑制新合成样本与多数类重叠的可能性^[18]。其算法原理如图1所示。




图1 safe-level SMOTE算法原理图

Fig. 1 Schematic of the safe-level SMOTE algorithm

该算法具体的实现步骤如下所示。

1) 计算数据集所有样本间的欧式距离。对于每个样本,通过找到与该样本最邻近的 k 个近邻样本,共同构成此样本的最近邻域。

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

式中: $d(x, y)$ 为样本 x 和样本 y 之间的欧式距离;

x_i, y_i 分别为两个样本中第 i 个特征量的值; z 为样本集存在的 z 维特征空间。

2) 对于多类标签量数据集的扩充, 将待扩充的类别(需要生成合成样本的类别)作为少数类样本, 而其他所有类别作为多数类样本, 随机选择一个待扩充的少数类样本, 并在其最临近域中随机选择两个样本 p 和 n , 并分别选择这两个样本的安全等级。

$$S_L(p) = k - N_M(p) \quad (2)$$

$$S_L(n) = k - N_M(n) \quad (3)$$

式中: $S_L(p)$ 和 $S_L(n)$ 分别为该少数类样本以及最靠近该少数类样本的少数类样本的安全等级; $N_M(p)$ 和 $N_M(n)$ 分别为最临近样本中不属于该样本的数量。

3) 根据少数类样本的安全等级, 可以计算出需要扩充点样本的安全等级比率 R_{SL} 。

$$R_{SL} = \frac{S_L(p)}{S_L(n)} \quad (4)$$

根据安全等级比率的所在区间可以通过 safe-level SMOTE 合成少数实例规则(如表 1 所示)进而确认“间隙”(gap)所在区域。

4) 通过计算出的样本 p 与样本 n 之间的欧氏距离, 并按照规则查找合成间隙区间。然后再按照式(5)进行计算。

$$s_i = p_i + (g_{ap} \times d_{iff}) \quad (5)$$

式中: s_i 为合成新的少数类样本位置; p_i 为样本 p 的位置; d_{iff} 为少数类样本 p 与最邻近少数类样本 n 之间的欧氏距离; g_{ap} 为满足合成少数实例规则合成间隙区间内随机生成的数。

1.2 核主成分分析

核主成分分析(K-PCA)是基于主成分分析(principal component analysis, PCA)上的改进的故障特征提取算法。该算法可以将原始的故障样本通过非线性映射函数映射到高维空间后再利用主成分分析进行故障特征的优选和提取^[19]。与 PCA 的线

性映射相比, K-PCA 具有较强的非线性信息挖掘能力, 便于非线性数据的降维, 更加适合于实际工程的要求^[20]。其基本原理如下所示。

1) 假设有一个低维的非线性数据集, 可以写成如式(6)所示的矩阵形式。

$$\mathbf{X} = \begin{pmatrix} x_{11} & \cdots & x_{1n} \\ \vdots & \ddots & \vdots \\ x_{m1} & \cdots & x_{mn} \end{pmatrix} \quad (6)$$

式中: 矩阵 $\mathbf{X}$ 表示数据集有 n 个样本; m 为每个样本数据的特征维数。

2) 将原始样本数据利用高斯径向核函数(式 7)映射到高维空间。

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{2\sigma^2}\right) \quad (7)$$

式中: K 为高斯径向核函数; $\|\mathbf{x}_i - \mathbf{x}_j\|$ 为样本点 $\mathbf{x}_i$ 和 $\mathbf{x}_j$ 之间的欧氏距离; σ 为高斯核函数的一个参数, 控制了高斯函数的宽度。

在高维空间内, 非线性的数据将转化为线性可分数据。

$$\varphi(\mathbf{X}) = [\varphi(\mathbf{x}^1), \cdots, \varphi(\mathbf{x}^n)] \quad (8)$$

式中: $\mathbf{x}^n$ 为第 n 个样本所有特征组成的特征向量; $\varphi(\mathbf{x}^n)$ 为通过非线性映射得到的该样本的特征向量; $\varphi(\mathbf{X})$ 为所有样本映射到高维空间后的数据矩阵。

找到线性数据的协方差矩阵:

$$\varphi(\mathbf{X})\varphi(\mathbf{X})^T \mathbf{w}_i = \lambda_i \mathbf{w}_i \quad (9)$$

式中: $\mathbf{w}_i$ 为映射到高维空间后协方差矩阵的第 i 个特征值 λ_i 的特征向量; λ_i 为协方差矩阵的特征值。

又因为空间矢量 $\mathbf{w}_i$ 可以用 $\varphi(\mathbf{X})$ 线性计算表示:

$$\mathbf{w}_i = \varphi(\mathbf{X})\boldsymbol{\alpha} \quad (10)$$

将式(9)代入式(10)并消去 $\mathbf{w}_i$ 有:

$$\varphi(\mathbf{X})\varphi(\mathbf{X})^T \varphi(\mathbf{X})\boldsymbol{\alpha} = \lambda_i \varphi(\mathbf{X})\boldsymbol{\alpha} \quad (11)$$

表 1 safe-level SMOTE 合成少数实例规则

Tab. 1 Rule of synthesis minority instance in safe-level SMOTE

情况	R_{SL}	SL	合成间隙区间	描述
1	$=\infty$	0 $\neq 0$	不生成少数类样本 $g_{ap} = 0$	p 和 n 样本都是噪声, 因此不合成数据。 n 样本是噪声; 合成数据应该尽可能靠近 p 样本, 通过复制生成数据。
2	$=1$		$0 \leq g_{ap} \leq 1$	p 样本和 n 样本安全等级相同, 合成数据在两个样本的连线上生成。
3	>1		$0 \leq g_{ap} \leq 1/R_{SL}$	p 样本比 n 样本更加安全。合成样本位置将处于 $[0, R_{SL}]$ 生成更接近 p 的位置。
4	<1		$(1 - R_{SL}) \leq g_{ap} \leq 1$	n 样本比 p 样本更加安全。合成样本位置将处于 $[1 - R_{SL}, 1]$ 生成更接近 n 的位置。

式中: α 为 $\varphi(X)\varphi(X)^T$ 的特征向量。

3) 考虑到隐函数不能直接用方程式求解。为了获得特定的结果, 使用了K-PCA的关键参数核函数, 如式(12)所示。

$$K = \varphi(X)^T \varphi(X) \quad (12)$$

由此可得:

$$K\alpha = \lambda_i \alpha \quad (13)$$

通过上述过程得到的核矩阵的特征值, 可以得到每个特征值的主成分贡献率, 当总贡献率达到预定值时, 可以按降序排列主成分的数量, 从而实现数据降维的目的。

1.3 SCNGO算法

1.3.1 NGO算法

NGO算法是一种模仿北方苍鹰狩猎和捕食过程以逼近达到全局最优的新式启发式优化算法。其过程主要分为猎物识别攻击以及猎物逃亡追击两大阶段, 其原理如下所示^[21]。

1) 猎物识别攻击阶段

北方苍鹰在搜索空间中随机选择一个猎物, 然后快速攻击它, 猎物在搜索空间中的随机性增加了NGO算法的探索能力^[22]。这一阶段对搜索空间进行了全局搜索并确定了初始的最优区域。其数学模型如式(14)~(16)所示。

$$P_i = X_k \quad (i = 1, 2, \dots, N, k = 1, 2, \dots, i-1, i+1, \dots, N) \quad (14)$$

$$x_{i,j}^{\text{new}, P1} = \begin{cases} x_{i,j} + r(p_{i,j} - Jx_{i,j}), & F_{P_i} < F \\ x_{i,j} + r(x_{i,j} - p_{i,j}), & F_{P_i} \geq F \end{cases} \quad (15)$$

$$X_i = \begin{cases} X_i^{\text{new}, P1}, & F_i^{\text{new}, P1} < F_i \\ X_i, & F_i^{\text{new}, P1} > F_i \end{cases} \quad (16)$$

式中: P_i 为第 i 只北方苍鹰的猎物位置; F_{P_i} 为其目标函数值; k 为区间 $[1, N]$ 中的随机自然数; $X_i^{\text{new}, P1}$ 为第 i 只北方苍鹰提出的解的新状态, $x_{i,j}^{\text{new}, P1}$ 为其第 j 维, P1 代表第一个阶段; $p_{i,j}$ 为第 j 维的位置; $x_{i,j}$ 为第 j 维的状态; $F_i^{\text{new}, P1}$ 为其基于 NGO 第一阶段的目标函数值; r 为区间 $[0, 1]$ 中的随机数; J 为一个随机数, 可以是 1 或者 2。

2) 猎物受到攻击后会试图逃跑, 北方苍鹰将继续追赶猎物并获猎。对这种行为的模拟增加了算法对搜索空间的局部搜索的开发能力。其具体的数学建模表达式如式(17)~(19)所示。

$$x_{i,j}^{\text{new}, P2} = x_{i,j} + R(2r - 1)x_{i,j} \quad (17)$$

$$R = 0.02 \left(1 - \frac{t}{T} \right) \quad (18)$$

$$X_i = \begin{cases} X_i^{\text{new}, P2}, & F_i^{\text{new}, P2} < F_i \\ X_i, & F_i^{\text{new}, P2} > F_i \end{cases} \quad (19)$$

式中: t 为迭代计数器; T 为最大迭代数量; $X_i^{\text{new}, P2}$ 为第 i 只北方苍鹰提出的解决方案的新状态; $x_{i,j}^{\text{new}, P2}$ 为其第 j 个维度; P2 代表第二个阶段; $F_i^{\text{new}, P2}$ 为其基于 NGO 第二阶段的目标函数值; R 为一个随迭代次数改变的比例因子, 随着迭代次数的增加该因子的值会逐渐减小。

1.3.2 NGO算法的改进

1) 利用透镜折射反向学习策略^[23]对北方苍鹰个体初始化过程进行优化, 通过计算目标的方向解来扩大原来的搜索范围。其基本原理如下所示^[24]。

如图2所示, X 轴上的解的搜索区间为 $[m, n]$, Y 轴表示法线, 在 X 轴上方有一束光 L , 通过 X 轴所在平面进行折射得到光线 L' 。 α 和 β 分别为光线的入射角和折射角, 光线交点设置为区间 $[m, n]$ 中点。由折射光线的几何关系以及折射率的基本概念可得式(20)。




图2 透镜折射原理示意图

Fig. 2 Schematic diagram of the principle of lens refraction

$$v = \sin \alpha / \sin \beta = \frac{l'((m+n)/2 - x)}{l(x' - (m+n)/2)} \quad (20)$$

式中: m 和 n 分别为搜索空间里面的最大值和最小值; v 为折射率; l 和 x 分别对应入射点到 Y 轴和 X 轴的投影大小; l' 和 x' 分别对应折射点到 Y 轴和 X 轴的投影大小。

令 $k = l/l'$, 代入式(20)经过变换可以得到:

$$x' = \frac{m+n}{2} + \frac{m+n}{2kv} - \frac{x}{kv} \quad (21)$$

对于多维的情况 $v = 1$ 有:

$$x'_{i,j} = \frac{m_j + n_j}{2} + \frac{m_j + n_j}{2k} - \frac{x_{i,j}}{k} \quad (22)$$

式中: $x_{i,j}$ 为第 i 个种群个体在第 j 维上的位置; $x'_{i,j}$ 为 $x_{i,j}$ 的折射反向解; m_j 和 n_j 分别为在第 j 维搜索空间上的最小值和最大值。

2) 利用正余弦算法 (sine-cosine algorithm, SCA) 中的正余弦震荡变化的特性公式对原始的 NGO 狩猎的第一阶段的位置更新进行替代。针对原始的正余弦算法中呈线性递减性质的步长搜索因子并不适用于 NGO 个体位置更新的情况, 采用式 (23) 新的非线性步长搜索因子 $r'^{[25-26]}$ 进行改良。

$$r' = a \times \left(1 - \left(\frac{t}{T_{\text{itermax}}} \right)^{\eta} \right)^{1/\eta} \quad (23)$$

式中: r' 为非线性步长搜索因子; η 为调节系数 ($\eta > 1$), 本文中 η 的值大小设置为 1.2; a 为常数, 文中设置大小为 1, T_{itermax} 为最大迭代次数的值。

3) 引入式 (24) 非线性的权重因子 ω 去改良个体位置对于个体信息的依赖度。修改后的 NGO 第一阶段 (猎物识别探索阶段) 的个体位置更新如式 (25) 所示。

$$\omega = \frac{e^{\frac{t}{T_{\text{itermax}}}} - 1}{e - 1} \quad (24)$$

$$X_{i,j}^{t+1} = \begin{cases} \omega \cdot X'_{i,j} + r'_1 \cdot \sin r_2 \cdot |r_3 \cdot X_{\text{best}} - X'_{i,j}|, & r_4 < 0.5 \\ \omega \cdot X'_{i,j} + r'_1 \cdot \cos r_2 \cdot |r_3 \cdot X_{\text{best}} - X'_{i,j}|, & r_4 \geq 0.5 \end{cases} \quad (25)$$

式中: 参数 r'_1 指示下一个位置的区域 (或移动方向); 参数 r_2 决定了迭代过程中朝着或是远离最优解所移动的距离, 其值大小为 $[0, 2\pi]$ 之间的随机数; 参数 r_3 为关于最优解的对距离产生影响所赋的一个随机权重系数, 其值大小为 $[0, 2]$ 之间的随机数; 参数 r_4 控制正余弦函数迭代方程的切换, 其值的大小为 $[0, 1]$ 之间的随机数; X_{best} 为当前迭代次数下算法搜索到的最优位置; $X'_{i,j}$ 和 $X_{i,j}^{t+1}$ 分别为迭代次数为第 t 次和第 $t+1$ 次时个体 i 在第 j 维上的位置。

1.3.3 AdaBoost 算法

AdaBoost 主要原理是通过同时对同一训练集施加不同的样本权重, 再代入多个弱分类器, 并将诊断结果进行加权合成一个强分类器。其中, 各个弱分类器的样本权重由前一个弱学习器的诊断结果决定。算法具体步骤如下所示^[27]。

1) 设置弱分类器初始化权重为:

$$D_1 = (q_{11}, q_{12}, \dots, q_{1N}) = \left(\frac{1}{N}, \frac{1}{N}, \dots, \frac{1}{N} \right) \quad (26)$$

式中: q_{1N} 为第 N 个样本的初始化权重; N 为参与弱分类器的训练的样本数量。

2) 设置迭代次数 $m = 1, 2, \dots, M$, M 为集成算法的最大迭代次数。根据具有权重分布 D_m 的训练集训练出弱分类器 h_m , 并计算出弱分类器的误差率。

$$e_m = \sum_{i=1}^N q_{mi} I(h_m(x_i) \neq y_i) \quad (27)$$

式中: e_m 为第 m 次迭代时弱分类器的误差率; $I(h_m(x_i) \neq y_i)$ 为指示函数, 用于检查该弱分类器是否错误的分类了样本 x_i , 当满足 $h_m(x_i) \neq y_i$ 的条件时 $I(h_m(x_i) \neq y_i) = 1$, 否则其值为 0; $h_m(x_i)$ 为弱分类器对样本 x_i 的预测结果; y_i 为该样本对应的实际标签; q_{mi} 为第 m 次迭代时第 i 个样本权重大小。

3) 计算弱分类器系数和更新训练集权重。

$$c_m = \frac{1}{2} \ln \frac{1 - e_m}{e_m} \quad (28)$$

$$D_{m+1} = \frac{D_m}{Z_m} \exp(-c_m y_i h_m(x_i)) \quad (29)$$

式中: c_m 为弱分类器系数; D_{m+1} 为迭代更新的训练集权重; Z_m 为规范化因子, 计算方法如式 (30) 所示。

$$Z_m = \sum_{i=1}^N D_m \exp(-c_m y_i h_m(x_i)) \quad (30)$$

4) 重复以上步骤, 直至达到最大的迭代次数, 最后根据弱分类器系数加权弱分类器合成强分类器 $G(x)$ 。

$$G(x) = \text{sign} \left(\sum_{m=1}^M c_m h_m(x) \right) \quad (31)$$

2 变压器故障样本数据扩充和故障特征优化的 SCNGO-SVM-AdaBoost 变压器故障诊断模型实现过程

2.1 变压器故障样本数据扩充

本文数据来源于 IEC TC 10 故障数据^[28]和西南某电网公司的生产运行数据以及往年公开发表的文献^[29-30], 总共收集了 350 组数据, 包含了故障变压器绝缘油中溶解的各类气体 (甲烷 (CH_4)、氢气 (H_2)、乙炔 (C_2H_2)、乙烯 (C_2H_4)、乙烷 (C_2H_6))。根据 DLT 722—2014 变压器油中溶解气体分析和判

断导则^[31],可以将变压器的故障类型分为低能放电、高能放电、局部放电、低温过热、中温过热、高温过热、正常这7种情况(按以上顺序设置1—7的标签编码对应故障类型)。利用安全级别合成少数过采样技术对原始样本数据进行平衡化的数据扩充,其具体情况如表2所示。

表2 故障样本及扩充后的数据扩充情况

Tab. 2 Fault sample and expanded data expansion

故障类型	编码情况	样本情况	扩充后的样本情况
低能放电	1	41	151
高能放电	2	69	137
局部放电	3	39	150
低温过热	4	34	149
中温过热	5	48	161
高温过热	6	77	149
正常	7	42	152

部分故障样本的油中溶解气体含量具体情况如表3所示。

表3 部分故障样本的油中溶解气体含量

Tab. 3 Dissolved gas content in the oil of some faulty samples

$\mu\text{L/L}$					
H_2	CH_4	C_2H_6	C_2H_4	C_2H_2	故障类型
22.5	8.5	1.2	7.3	8.4	低能放电
78	28	13	29	110	低能放电
549.1	121.2	25.4	31.9	190.5	低能放电
43.74	17.02	2.1	26.22	10.92	高能放电
150	21.5	1.8	22	33	高能放电
1 678	652.9	80.7	1 005.9	419.1	高能放电
189.93	8.74	1.25	0.04	0.04	局部放电
73	12.3	3.33	27.1	47.9	局部放电
2437	115.5	22.6	3.2	0.2	局部放电
5.07	26.26	3.17	2.77	0.21	低温过热
56	78	18	173	0	低温过热
247.7	148.7	78.7	192.7	0.9	低温过热
231.1	919.6	669.1	1 499.6	5.61	中温过热
150	11.6	50.6	29	0.56	中温过热
23.51	61.33	45.21	98.03	1.01	中温过热
157.2	718.13	727.56	2 434.3	153.36	高温过热
147	766	506	2078	3.1	高温过热
807.55	955.76	518.53	2 286.7	65.86	高温过热
39.81	24.5	18.37	11.4	6.53	正常
14.67	3.68	10.54	2.71	0.2	正常

2.2 变压器故障特征降维及优选

为尽可能地利用到油中溶解气体的故障信息,本文参考传统气体比值(三比值、四比值)方法以及从其他文献中所选取的气体比值征兆(见表4)进行变压器故障特征降维及优选。为避免气体浓度为0 $\mu\text{L/L}$ 时做分母时比值无法以数值形式显示,将所有气体浓度为0 $\mu\text{L/L}$ 的气体浓度修改为 $1 \times 10^{-16} \mu\text{L/L}$ 。

表4 气体浓度比值编码规则

Tab. 4 Gas concentration ratio coding rules

编号	气体浓度比值	编号	气体浓度比值
X1	CH_4/H_2	X11	$\text{H}_2/(\text{TH}+\text{H}_2)$
X2	$\text{C}_2\text{H}_4/\text{CH}_4$	X12	CH_4/TH
X3	$\text{C}_2\text{H}_2/\text{H}_2$	X13	$\text{C}_2\text{H}_2/\text{TH}$
X4	$\text{C}_2\text{H}_2/\text{CH}_4$	X14	$\text{C}_2\text{H}_4/\text{TH}$
X5	$\text{C}_2\text{H}_4/\text{C}_2\text{H}_2$	X15	$\text{C}_2\text{H}_6/\text{TH}$
X6	$\text{C}_2\text{H}_6/\text{C}_2\text{H}_2$	X16	$(\text{CH}_4+\text{C}_2\text{H}_4)/\text{TH}$
X7	$\text{C}_2\text{H}_4/\text{H}_2$	X17	$\text{CH}_4/\text{CH}_4+\text{C}_2\text{H}_2+\text{C}_2\text{H}_4$
X8	$\text{C}_2\text{H}_6/\text{H}_2$	X18	$\text{C}_2\text{H}_2/\text{CH}_4+\text{C}_2\text{H}_2+\text{C}_2\text{H}_4$
X9	$\text{C}_2\text{H}_6/\text{CH}_4$	X19	$\text{C}_2\text{H}_4/\text{CH}_4+\text{C}_2\text{H}_2+\text{C}_2\text{H}_4$
X10	$\text{C}_2\text{H}_6/\text{C}_2\text{H}_4$	X20	H_2/TH

将上述20种气体浓度的比值作为初始的特征量并做如式(32)的归一化处理,设置K-PCA的核函数选取高斯径向核函数,代入K-PCA中进行特征降维处理。经过处理后的贡献度、累积贡献度、特征值大小与所降维的主成分之间的关系如图3所示。

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (32)$$

式中: x 为该特征的原始值, x' 为 x 经过最大-最小归一化处理后的特征值; $x_{\max}$ 和 $x_{\min}$ 分别为该特征所具有的最大值和最小值。

由图3可知,所选主成分特征维度为8和9的时候,其累积贡献度为0.952 48和0.961 32,其值均大于0.95。此时,该主特征维度下特征值大小已经降至较低水平,因此主成分的特征维度选取为8或9。这样可以最大限度的利用变压器故障特征中的有效信息,避免了冗余信息对后续故障模型精准确度的影响。

为避免训练集特征标签样本因选取的不均匀而影响后续模型的结果验证和性能评估,将安全级别合成少数过采样技术扩充后的数据进行比值归一化




图3 K-PCA运行结果

Fig. 3 K-PCA operation results

处理后,代入K-PCA进行数据降维,并按照每种故障类别下训练集和测试集7:3对样本进行随机划分。这样在保证各样本标签数量均匀的情况下又保证了单个故障标签量内部分布的随机性,方便下一步的SCNGO-SVM-AdaBoost故障模型的诊断和性能评估。

2.3 SCNGO-SVM-AdaBoost诊断模型

为验证SCNGO优化算法相较于其他启发式算法以及未改良自身算法的优越性,本文选择Schwefel 2.22函数,如式(33)所示^[32],对该启发式寻优算法与目前阶段常用的启发式优化算法(蜣螂优化算法(dung beetle optimization algorithm, DBO)、麻雀优化算法(sparrow search algorithm, SSA)、灰狼优化算法(grey wolf optimizer, GWO)以及北方苍鹰优化算法)进行寻优能力的对比。

$$F = \sum_{i=1}^{D_m} x_i + \prod_{i=1}^{\frac{1}{2}} x_i \quad (33)$$

式中: F 为测试函数; D_m 为测试函数的空间维度。

该测试函数具有良好的非凸性、多模态性和高维度性同时还引入了不连续噪声,更加符合变压器故障数据的特点。将测试函数的上下限分别取为 ± 32 ,维度设置为30,迭代次数为1 000次,利用上述的优化算法进行寻优。各个优化算法的寻优情况如图4—5和表5所示。

可知SCNGO算法相较于DBO算法有着相似的寻优能力,但是SCNGO的迭代次数更少,其寻优速度更快且耗费的时间更少。同时SCNGO相较于除DBO以外的其他3种算法其寻优能力明显更强,




图4 SCNGO算法参数空间分布

Fig. 4 Parameter space of SCNGO algorithm




图5 5种优化算法的寻优过程迭代曲线

Fig. 5 Iterative curves of optimization process for 5 optimization algorithms

表5 5种优化算法的寻优结果比较

Tab. 5 Comparison of the optimization results of 5 optimization algorithms

优化算法	最佳寻优值	迭代次数
SCNGO	4.4409×10^{-16}	42
NGO	3.9968×10^{-15}	176
DBO	4.4409×10^{-16}	106
SSA	2.013 3	821
GWO	1.1102×10^{-14}	330

寻优速度明显更快,说明了SCNGO算法在整体寻优能力上的优越性。

目前,支持向量机(SVM)进行变压器故障诊断的方法被广泛研究和应用。SVM是一种监督学习算法,具有良好的分类性能和泛化能力,但SVM核函数参数 g 和惩罚因子 c 对故障诊断效果的影响极为显著,若用人工确定,并不能保证每次SVM诊断的精确性^[33]。本文以测试集的分类预测错误率作为目标适应度函数,通过SCNGO算法对SVM的参数 g 和 c 进行了迭代30次的寻优,SCNGO的主

要设置参数如表 6 所示。

将利用 SCNGO 优化的 SVM 参数引入到集成算法的多个弱分类器的寻优过程中, 以 AdaBoost 集成学习模型为框架对诊断算法进行进一步的自适应

增强, 以减少训练集中所携带样本信息较差的样本对诊断模型的影响, 从而进一步的提升变压器故障诊断模型的故障分类效果。整个基于数据扩充和故障特征优化的 SCNGO-SVM-AdaBoost 变压器故障诊断模型具体的流程图 6 所示。

表 6 SCNGO 寻优参数设置

Tab. 6 SCNGO optimization parameter setting	
主要参数	取值(范围)
优化参数个数	2
种群数量	20
c 参数的上下限	[0.000 1, 500]
g 参数的上下限	[0.000 1, 500]

3 模型诊断结果及性能对比评估

3.1 模型诊断结果

当主成分特征维度为 8 时, 利用训练集进行训练并且对测试集进行诊断, 得到的结果如图 7—8 所示。




图 6 基于数据扩充和故障特征优化的 SCNGO-SVM-AdaBoost 变压器故障诊断模型流程图

Fig. 6 SCNGO-SVM-AdaBoost transformer fault diagnosis model flow chart based on data expansion and fault feature optimization




图7 SCNGO-SVM-AdaBoost模型测试集预测结果对比

Fig. 7 Comparison of prediction results of SCNGO-SVM-AdaBoost model test set




图8 SCNGO-SVM-AdaBoost 模型测试集混淆矩阵

Fig. 8 SCNGO-SVM-AdaBoost model test set confusion matrix

为进一步说明该模型对于变压器故障诊断的优劣,对于诊断结果引入了准确率(accuracy),精确率(precision),召回率(recall),F1_score和kappa系数进行了进一步的描述。结果如表7所示。

表7 诊断模型各项评估系数

Tab. 7 Evaluation coefficients of diagnostic model

各项指标	准确率	精确率	召回率	F1_score值	kappa系数
实际值	0.968 3	0.936 2	0.977 8	0.956 5	0.963 0

F1_score作为精确率和召回率的调和平均数,通常被用作一个综合指标去衡量诊断模型的综合性能。F1_score考虑了精确率和召回率两个指标,能够综合评估模型在正类别和负类别上的性能,当F1_Score较大时,意味着模型在保持高精确率的同时,也能够保持较高的召回率,能够更好地适应不同的诊断场景。以上的各项评估系数都大于0.9且

接近于1,且混淆矩阵总体呈现对角线分布。说明该故障诊断分类模型对于变压器的各类故障分类清晰,能够对针对变压器的各种类型的故障做出准确判断。

单次变压器故障诊断模型的性能的评估具有偶然性和随机性。为了进一步说明该诊断模型的优点,本文将该模型与其他模型进行多个方面的对比评估。下面模型的准确率和F1_score均为训练集和测试集样本按照7:3随机划分并连续运行10次所得到的平均值结果。

3.2 不同特征选取方式的对比分析

为了验证K-PCA对于变压器故障信息特征信息保留的有效性。本文采用了20维全特征、三比值法选取特征、罗杰斯四比值法选取特征以及K-PCA主成分的特征维度选取分别为8和9时的降维特征,这5种特征选取方式进行对比验证。诊断模型均选用本文的诊断模型,实验结果如表8所示。

表8 不同特征选取方式的对比分析

Tab. 8 Comparative analysis of different feature selection methods

特征选取方式	准确率	F1_score值
20维全特征	0.789 9	0.906 6
三比值编码	0.808 5	0.862 8
四比值编码	0.921 3	0.896 6
KPCA(9维)	0.950 5	0.922 9
KPCA(8维)	0.957 8	0.935 1

以单独的三比值或者四比值编码的比值代入诊断模型的虽然具有一定的分类诊断效果,但诊断结果不如经K-PCA处理后的结果。而全特征选取方式由于本身包含过多的冗余信息,使得模型变得更复杂,也不能使得诊断模型更加精准。K-PCA可以有效的降低冗余信息对于诊断模型的影响,在累积贡献度和特征值相接近的情况下,主成分特征维度选取8时,其模型诊断性能更具有优势。

3.3 不同平衡化采样数据扩充方法的对比分析

为验证本文提出方法在数据平衡化扩充方面的优越性。分别利用SMOTE、边界合成少数类过采样技术(borderline synthetic minority over-sampling technique, Borderline-SMOTE)、自适应合成采样

(synthetic minority over-sampling technique, ADASYN)和 safe-level SMOTE 数据平衡化扩充算法对数据进行处理后, 再代入特征降维并利用本文诊断模型进行诊断。其具体的实验结果如表 9 所示。

表 9 不同平衡化采样数据扩充方法的对比分析
Tab. 9 Comparative analysis of different balanced sampling data expansion methods

采样方法	准确率	F1_score 值
SMOTE	0. 948 0	0. 920 6
Borderline-SMOTE	0. 945 2	0. 913 2
ADASYN	0. 934 9	0. 907 8
Safe-Level SMOTE	0. 957 8	0. 935 1

在相同的诊断模型下, 经过安全级别合成少数过采样技术扩充后的数据集其准确率和 F1_score 的值都有所提高。因为相较于原始的方法, safe-level SMOTE 算法除考虑自身少数类样本以外, 还考虑到了周围的非自身类别的多数类样本。这使得扩充后的数据更加合理和平衡化, 有利于提高后续模型诊断的准确度。

3.4 不同机器学习诊断模型的对比分析

为验证本文所提模型变压器故障诊断模型相较于其他机器学习诊断模型的优越性。本文选取了常用的 SVM、极限学习机(extreme learning machine, ELM)、反向传播神经网络(back propagation neural network, BPNN)以及 SVM-AdaBoost 诊断模型与本文所提模型进行了纵向对比(上述模型均通过数据平衡化扩充和特征降维), 具体的实验结果如表 10 所示。

本文的方法相较于其他模型的诊断的精确度和调和平均数都有明显的提升, 且 AdaBoost 模型对于原始模型具有增强的作用。

表 10 不同机器学习诊断模型的对比分析
Tab. 10 Comparative analysis with machine learning diagnostic model

诊断方法	准确率	F1_score 值
SVM	0. 807 6	0. 804 7
ELM	0. 862 5	0. 836 5
BPNN	0. 883 5	0. 873 4
SVM-AdaBoost	0. 884 7	0. 873 4
SCNGO-SVM	0. 948 6	0. 916 9
SCNGO-SVM-AdaBoost	0. 957 8	0. 935 1

3.5 不同优化算法的对比分析

为说明本文的优化算法相较于其他方法的优越性。本文将第 2 节中的 SSA 算法、GWO 算法和原始的 NGO 算法替换本文的优化算法模型, 进行纵向的对比分析, 结果如表 11 所示。

表 11 不同优化算法的对比分析
Tab. 11 Comparative analysis of different optimization algorithms

诊断模型	准确率	F1_score 值
GWO-SVM-AdaBoost	0. 941 6	0. 904 5
SSA-SVM-AdaBoost	0. 946 0	0. 920 2
NGO-SVM-AdaBoost	0. 948 3	0. 902 2
SCNGO-SVM-AdaBoost	0. 957 8	0. 935 1

在后续诊断方法相同的情况下, 本文中的改进的北方苍鹰优化算法具有更高的准确率和 F1_score, 再一次验证和说明了本文方法相较于其他优化算法的优越性。

4 结论

本文提出了基于数据扩充和故障特征优化的 SCNGO-SVM-AdaBoost 变压器故障诊断模型, 通过实验对比分析, 得到了如下的结论。

- 1) 通过安全级别合成少数过采样技术(Safe-Level SMOTE)对原始的变压器故障样本集进行数据扩充可以有效地解决原始所得部分数据类型不平衡问题, 能够有效提高故障诊断模型的精度。
- 2) 通过核主成分分析(K-PCA)对 20 组特征征兆进行降维处理可以有效地降低冗余信息对于变压器故障诊断模型的影响。相较于直接将传统的三比值或者四比值的比值代入诊断模型, 诊断精度更高, 更加具有适用性。
- 3) 本文提出的 SCNGO 算法相较于同类型的启发式优化算法具有更佳的寻优能力和探索开发能力, 同时 AdaBoost 模型可以对原始的诊断模型进行加强, 从而提高故障诊断的精确率。
- 4) 本文提出了基于数据扩充和故障特征优化的 SCNGO-SVM-AdaBoost 变压器故障诊断模型可以根据油色谱数据对不同性质的变压器故障类型作出准确判断, 可以用以指导解决实际的工程问题。

参考文献

- [1] 白星振, 臧元, 葛磊蛟, 等. 变压器故障诊断用油中溶解气体征兆优选方法[J]. 高电压技术, 2023, 49(9): 3873 – 3886.
BAI Xingzhen, ZANG Yuan, GE Leijiao, et al. Selection method of feature derived from dissolved gas in oil for transformers fault diagnosis [J]. High Voltage Engineering, 2023, 49(9): 3873 – 3886.
- [2] 龚泽威一, 饶桐, 王钢, 等. 基于改进粒子群优化XGBoost的变压器故障诊断方法[J]. 高压电器, 2023, 59(8): 61 – 69.
GONG Zewei-yi, RAO Tong, WANG Gang, et al. Fault diagnosis method of transformer based on Improved particle swarm optimization XGBoost [J]. High Voltage Apparatus, 2023, 59(8): 61 – 69.
- [3] 徐龙舞, 张英, 张倩, 等. 基于正交实验法改进的蝠鲼算法优化BP在变压器故障诊断上的研究[J]. 南方电网技术, 2022, 16(7): 46 – 54.
XU Longwu, ZHANG Ying, ZHANG Qian, et al. Orthogonal experiment method based improved MRFO algorithm to optimize BP in transformer fault diagnosis [J]. Southern Power System Technology, 2022, 16(7): 46 – 54.
- [4] 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.
WANG Yuhong, WANG Zhizhong, FU Hua, et al. Research on transformer fault diagnosis based on the improved multi-strategy sparrow algorithm and BiLSTM [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 87 – 97.
- [5] 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 LogitBoost-decision tree [J]. Power System Protection and Control, 2023, 51(7): 63 – 72.
- [6] 张英, 赵世钦, 余鹏程. 充油(气)电力设备故障分析和诊断[M]. 贵阳: 贵州大学出版社, 2015.
- [7] GOUDA O E, EL-HOSHY S H, EL-TAMALY H H. Proposed three ratios technique for the interpretation of mineral oil transformers based dissolved gas analysis [J]. IET Generation, Transmission & Distribution, 2018, 12(11): 2650 – 2661.
- [8] DUAYWAH T G. Refining DGA methods of IEC code and Rogers four ratios for transformer fault diagnosis [C]// IEEE Power and Energy Society General Meeting (PESGM), July 17 – 21, 2016, Boston, MA, USA. New York: IEEE, 2016: 135 – 145.
- [9] BARBOSA T M, FERREIRA J G, FINOCCHIO M A F, et al. Development of an application based on the Duval triangle method[J]. IEEE Latin America Transactions, 2017, 15(8): 1439 – 1446.
- [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.
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.
- [11] 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.
- [12] 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.
- [13] 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-EPSCA, 2023, 35(9): 137 – 144.
- [14] 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.
- [15] 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 class imbalance [J]. Electric Power, 2023, 56(10): 133 – 144.
- [16] 段中兴, 周孟, 宋婕菲, 等. 基于ISFLA-SVM的变压器故障诊断[J]. 高压电器, 2023, 59(1): 126 – 133.
DUAN Zhongxing, ZHOU Meng, SONG Jiefei, et al. Fault diagnosis of transformer based on ISFLA-SVM [J]. High Voltage Apparatus, 2023, 59(1): 126 – 133.
- [17] 李云娣, 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.
- [18] BUNKHUMPORNPAT C, SINAPIROMSARAN K, LURSINSAP C. Safe-level-smote: safe-level-synthetic minority over-sampling technique for handling the class imbalanced problem[C]//Advances in Knowledge Discovery and Data Mining: 13th Pacific-Asia Conference, April 27 – 30, 2009, Bangkok, Thailand. Berlin: Springer, 2009: 475 – 482.
- [19] DAUD S N S S, SUDIRMAN R, SHING T W. Safe-level SMOTE method for handling the class imbalanced problem in electroencephalography dataset of adult anxious state [J]. Biomedical Signal Processing and Control, 2023(83): 104649.
- [20] 武文栋, 施保华, 郑传良, 等. 基于KPCA-ISSA-KELM的光伏阵列故障诊断方法[J]. 智慧电力, 2022, 50(11): 69 – 76.
WU Wendong, SHI Baohua, ZHENG Chuanliang, et al. Fault diagnosis method of PV array based on KPCA-ISSA-KELM [J]. Smart Power, 2022, 50(11): 69 – 76.
- [21] LI Y, ZHANG Y, GUO Z, et al. Fault diagnosis of aero-engine lubrication system based on KPCA-ABC-SVM [C]// 2023 Prognostics and Health Management Conference (PHM), June 5 – 7, 2023, Montreal, Canada. New York: IEEE, 2023: 6 – 11.
- [22] DEGHANI M, HUBÁLOVSKÝ Š, TROJOVSKÝ P. Northern goshawk optimization: a new swarm-based algorithm for solving optimization problems[J]. IEEE Access, 2021(9): 162059 – 162080.
- [23] 王孔贤, 邵英, 王黎明. 基于NGO-VMD-DE的单相接地故障

- 信号特征提取[J]. 电子测量技术, 2023, 46(4): 60–68.
- WANG Kongxian, SHAO Ying, WANG Liming. Feature extraction of single-phase grounding fault signal based on NGO-VMD-DE [J]. Electronic Measurement Technology, 2023, 46(4): 60–68.
- [23] WU D, RAO H, WEN C, et al. Modified sand cat swarm optimization algorithm for solving constrained engineering optimization problems[J]. Mathematics, 2022, 10(22): 4350. 1–4350.10.
- [24] 王宗山, 丁洪伟, 王杰, 等. 基于正交设计的折射反向学习樽海鞘群算法[J]. 哈尔滨工业大学学报, 2022, 54(11): 122–136.
- WANG Zongshan, DING Hongwei, WANG Jie, et al. Salp swarm algorithm based on orthogonal refracted opposition-based learning [J]. Journal of Harbin Institute of Technology, 2022, 54(11): 122–136.
- [25] 李爱莲, 全凌翔, 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.
- [26] 张晶, 贺媛媛. 融合正余弦优化与跳距优化的DV-Hop定位算法[J]. 计算机工程与科学, 2022, 44(4): 645–653.
- ZHANG Jing, HE Yuanyuan. A DV-Hop positioning algorithm combining sine and cosine optimization and hop distance optimization [J]. Computer Engineering & Science, 2022, 44(4): 645–653.
- [27] 尚秋峰, 黄达, 孔彪. 基于VMD与AdaBoost-SCN的海缆振动信号识别方法[J]. 振动与冲击, 2023, 42(19): 231–239.
- SHANG Qiufeng, HUANG Da, GONG Biao. Submarine cable vibration signal identification method based on VMD and AdaBoost-SCN [J]. Journal of Vibration and Shock, 2023, 42(19): 231–239.
- [28] KIM S, PARK J, KIM W, et al. Learning from even a weak teacher: Bridging rule-based Duval method and a deep neural network for power transformer fault diagnosis[J]. International Journal of Electrical Power & Energy Systems, 2022(136): 107619.
- [29] NANFAK A, EKE S, MEGHNEFI F, et al. Hybrid DGA method for power transformer faults diagnosis based on evolutionary k-means clustering and dissolved gas subsets analysis [J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2023, 23(12): 231–245.
- [30] 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]. 保定: 华北电力大学, 2013.
- [31] 电力行业电力变压器标准化技术委员会. 变压器油中溶解气体分析和判断导则: DL/T 722—2014. 北京: 中国电力出版社, 2014.
- [32] 刘亮, 何庆. 基于改进蝗虫优化算法的特征选择方法[J]. 南京大学学报(自然科学版), 2020, 56(1): 41–50.
- LIU Liang, HE Qing. An feature selection method based on improved grasshopper optimization algorithm [J]. Journal of Nanjing University (Natural Science), 2020, 56(1): 41–50.
- [33] CHAUHAN V K, DAHIYA K, SHARMA A. Problem formulations and solvers in linear SVM: a review[J]. Artificial Intelligence Review, 2019, 52(2): 803–855.

收稿日期: 2024-01-02; 网络首发日期: 2024-06-26

作者简介:

姚翔曦(1999), 男, 硕士研究生, 研究方向为电力设备故障诊断, 865992497@qq.com;

张英(1977), 女, 通信作者, 高级工程师(教授级), 博士, 研究方向为电气设备绝缘监测及故障诊断、电工材料;

张国治(1990), 男, 副教授, 博士, 研究方向为电力设备绝缘状态新型监测技术及电力设备状态评估及故障诊断。

广 告

南方电网公司电网仿真重点实验室……………封二
南方电网科技创新中心……………封三
清洁能源……………A1(扉页)

积成电子股份有限公司……………A2
碳中和……………A3
北京四方继保自动化股份有限公司……………A4(目录前)