

DOI: 10.19783/j.cnki.pspc.240153

基于混合特征选择和 IOMA-CNN 的变压器故障诊断

闵永智, 令世文, 王果

(兰州交通大学自动化与电气工程学院, 甘肃 兰州 730070)

摘要: 为解决变压器油中溶解气体故障特征种类不足和诊断模型准确率较低的问题, 提出一种混合特征选择方法。并利用改进光学显微镜优化算法(improved optical microscope algorithm, IOMA)优化卷积神经网络(convolutional neural networks, CNN), 实现变压器故障诊断。首先, 基于相关比值法构建 30 维变压器故障候选特征集, 采用混合特征选择方法, 通过两次特征选择确定输入集的特征维数。其次, 引入 Tent 混沌映射、自适应 t 分布变异与动态选择策略改进光学显微镜优化算法(optical microscope algorithm, OMA), 提升其寻优性能。然后, 利用 IOMA 算法对 CNN 模型的学习率、卷积核大小和数量等超参数进行优化。最后, 构建 IOMA-CNN 变压器故障诊断模型并通过算例分析对其性能进行评估。实验表明, 所提方法故障诊断准确率达到 98.5%。与常规特征选择方法相比, 利用混合特征选择方法所选择的输入特征进行故障诊断能够有效提升诊断准确率。相较于其他优化诊断模型, IOMA-CNN 具有更高的准确率和更好的稳定性。

关键词: 变压器; 故障诊断; 混合特征选择; 光学显微镜优化算法; 卷积神经网络

Transformer fault diagnosis based on hybrid feature selection and IOMA-CNN

MIN Yongzhi, LING Shiwen, WANG Guo

(School of Automation and Electrical Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: There are problems of insufficient types of dissolved gas fault features in transformer oil and a low accuracy of diagnosis. Thus a hybrid feature selection method is proposed. The improved optical microscope algorithm (IOMA) is used to optimize convolutional neural networks (CNN) to realize transformer fault diagnosis. First, a 30 dimensional transformer fault candidate feature set is constructed based on the correlation ratio method, and the hybrid feature selection method is used to determine the feature dimension of the input set through two feature selections. Secondly, a Tent chaotic mapping, adaptive t-distribution mutation and dynamic selection strategy are introduced to improve the optical microscope algorithm (OMA) and enhance its optimization performance. Then, the learning rate, the size and number of convolution kernels of the CNN model are optimized using the IOMA algorithm. Finally, the IOMA-CNN transformer fault diagnosis model is constructed and its performance is evaluated by numerical example analysis. Experiments show that the fault diagnosis accuracy of the proposed method is 98.5%. Compared with the conventional feature selection method, the fault diagnosis accuracy can be effectively improved by using the input features selected by the hybrid feature selection method. Compared with other optimized diagnosis models, IOMA-CNN has higher accuracy and better stability.

This work is supported by the National Natural Science Foundation of China (No. 62066024).

Key words: transformer; fault diagnosis; hybrid feature selection; optical microscope optimization algorithm; convolutional neural network

0 引言

电力变压器作为电力系统的核心设备, 对其进行高效、准确的故障诊断有助于及时预警, 制定相应的措施, 合理地进行检修工作, 促进电力系统的

安全稳定运行^[1-2]。

油中溶解气体检测技术(dissolved gases analysis, DGA)是油浸式变压器最有效的诊断方法之一, 在潜伏性故障的诊断和预警中发挥重要的作用^[3-4]。目前, 基于 DGA 的故障诊断方法主要分为传统方法和机器学习方法。传统方法有 Doernerburg 比值法、Rogers 比值法、大卫三角法^[5-7]等, 该类方法由于特

基金项目: 国家自然科学基金项目资助(62066024)

征变量少导致诊断精度低, 逐渐被近年来兴起的机器学习方法所取代。机器学习方法在变压器故障诊断领域取得了良好的效果, 其中较具代表性的有神经网络^[8]、支持向量机^[9-11](support vector machine, SVM)、决策树^[12]和极限学习机^[13](extreme learning machine, ELM)等。但 SVM 本质上是一个二分类器, 对于变压器故障诊断的多分类问题, 其效率较低; 决策树方法容易出现过拟合, 在处理特征关联性比较强的数据时表现不是太好; ELM 可控性能差, 容易出现过拟合的问题。卷积神经网络(convolutional neural networks, CNN)^[14-15]作为一种备受欢迎的变压器故障诊断模型, 具有较强的特征提取能力, 但变压器实际工作中故障情况较少, 这也导致故障数据的特征值较少, 如何通过改进并应用 CNN 来适应变压器 DGA 数据、提高故障诊断准确率成为亟待解决的工程技术难题。

在使用机器学习方法进行变压器故障诊断中, 充足的训练样本是模型完全发挥性能的前提, 当单一使用油中溶解气体浓度作为输入特征时, 往往会影响机器学习模型的精度。目前, 针对特征选择的处理问题, 相关研究大多采用过滤式、封装式、嵌入式三种方法。其中较具代表性的有方差分析^[16-17](analysis of variance, ANOVA)、Pearson 相关系数^[18-19]、随机森林^[20-21]和群智能优化算法^[22]等。上述算法的应用在一定程度上实现了特征样本的多样化, 但都存在一定的缺陷。ANOVA 和 Pearson 相关系数方法作为过滤式方法, 特征选择效率高但所得特征子集冗余度较高; 封装式方法选择的特征子集精度高但计算成本较高; 群智能优化算法其性能受初始参数选择的影响。

针对以上问题, 本文提出了一种基于混合特征选择和 IOMA-CNN 的变压器故障诊断方法。首先使用轻量梯度提升算法(light gradient boosting machine, LightGBM)和极致梯度提升算法(eXtreme gradient boosting, XGBoost)进行第一次特征选择, 并通过客观赋权法结合逼近理想解法(criteria importance though intercriteria correlation-technique for order preference by similarity to an ideal solution, CRITIC-TOPSIS)得到特征候选集的综合特征评分, 再通过 CNN 模型进行第二次特征选择确定输入的特征维数; 然后利用改进光学显微镜优化算法(improved optical microscope algorithm, IOMA)对 CNN 的超参数进行优化; 最后, 将混合特征选择方法所选择的输入特征作为 IOMA-CNN 模型的输入进行故障诊断, 并与不同输入特征以及不同诊断模型进行对比, 验证了本文方

法的有效性。

1 基于混合方法的变压器故障特征选择

变压器的内部故障可分为过热故障和放电故障。其中, 过热故障包括高、中、低温过热, 放电故障包括高能放电、局部放电和低能放电, 分析变压器油中溶解气体是诊断变压器故障类型的重要手段。考虑到故障样本的均衡性以及多样性, 需要对故障样本进行数据处理和特征选择。

1.1 数据样本处理

变压器发生故障时, 绝缘油会与固体绝缘材料发生裂解并产生油中溶解气体, 主要包括 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2 这 5 种气体。为了保证深度学习模型可以更加准确地反映气体特征与故障类型之间的联系, 在参考传统比值法和 5 种特征气体浓度的基础上, 本文增加了 25 种变压器故障候选特征, 建立了能够反映变压器运行状态的 30 维气体浓度、比值数据特征集, 具体如表 1 所示, 其中 $X_1 = H_2 + CH_4 + C_2H_4 + C_2H_6 + C_2H_2$, $X_2 = CH_4 + C_2H_4 + C_2H_6 + C_2H_2$, $X_3 = C_2H_4 + C_2H_6 + C_2H_2$ 。

表 1 故障特征候选集

Table 1 Fault feature candidate set

特征编号	指标	特征编号	指标
1	H_2	16	H_2/X_1
2	CH_4	17	CH_4/X_1
3	C_2H_4	18	C_2H_4/X_1
4	C_2H_6	19	C_2H_6/X_1
5	C_2H_2	20	C_2H_2/X_1
6	CH_4/H_2	21	H_2/X_2
7	CH_4/C_2H_4	22	CH_4/X_2
8	CH_4/C_2H_6	23	C_2H_4/X_2
9	C_2H_2/CH_4	24	C_2H_6/X_2
10	C_2H_4/H_2	25	C_2H_2/X_2
11	C_2H_4/C_2H_6	26	H_2/X_3
12	C_2H_2/C_2H_4	27	CH_4/X_3
13	C_2H_6/H_2	28	C_2H_4/X_3
14	C_2H_2/C_2H_6	29	C_2H_6/X_3
15	C_2H_2/H_2	30	C_2H_2/X_3

1.2 特征变量选择

增加的气体特征丰富了特征样本, 但也增加了特征间的冗余性, 降低了诊断模型的计算速率, 为了提高故障诊断的准确率和运算效率, 本文提出了一种混合特征选择方法进行特征选择, 混合特征选择具体步骤如下所述。

1) 根据故障数据通过相关比值方法提取并构建参数特征体系, 建立故障特征候选集, 并使用 smote 过采样方法对特征数据集进行预处理;

2) 通过 LightGBM 和 XGBoost 算法对训练集进行训练, 得到每个特征的重要性评估结果构建重要性评估矩阵;

3) 对初选特征子集进行第一次特征选择, 使用 min-max 标准化方法对重要性评估结果进行处理并通过 CRITIC-TOPSIS 法确定特征系数, 根据重要性评估矩阵, 将两种算法得到的各个特征的特征重要性评分进行加权求和, 得到初选特征子集的综合特征评价矩阵;

4) 对初选特征子集进行第二次特征选择, 结合第一次特征选择的结果将特征综合重要性评分按照降序排序, 基于相同的训练集和测试集, 按照逐维增加的方式每次增加一种特征组成特征候选子集, 并以基础 CNN 模型的测试集准确率为目标函数, 将其输入 CNN 故障诊断模型中进行诊断, 最后, 选取最大目标值对应的候选子集维数作为最终输入的特征维数。

根据故障候选特征集构建特征重要性评估矩阵, 如式(1)所示。

$$C = \begin{bmatrix} F_1^1 & F_1^2 & \dots & F_1^m \\ F_2^1 & F_2^2 & \dots & F_2^m \\ \vdots & \vdots & \dots & \vdots \\ F_n^1 & F_n^2 & \dots & F_n^m \end{bmatrix} \quad (1)$$

式中: F^m 为通过不同特征选择算法计算得到的特征重要性评分; n 为样本特征维数。

将特征重要性评估矩阵作为初选特征子集, 通过 min-max 标准化方法对重要性评估结果进行处理, 并通过 CRITIC-TOPSIS 确定特征系数, 如式(2)所示。

$$S = \begin{bmatrix} S_1 \\ S_2 \\ \vdots \\ S_m \end{bmatrix} \quad (2)$$

式中, S_m 为不同特征选择算法的特征系数。而 CRITIC-TOPSIS 是一种评价指标客观赋权方法, 该方法在对指标进行权重计算时围绕两个方面进行: 对比度和矛盾性。不同指标的对比度由标准差来表示。

$$\sigma_q = \sqrt{\frac{\sum_{i=1}^n (F_i^q - \bar{F}_i^q)^2}{n-1}} \quad (3)$$

式中: σ_q 表示指标 q 的对比度; F_i^q 为指标 q 的第 i 维特征重要性评分; \bar{F}_i^q 为指标 q 的 n 维特征重要性评分的平均值。矛盾性反映的是不同指标之间的相关程度, 数值越小, 则呈现显著正相关性。设指标 q 与其余指标矛盾性大小为 f_q , 其表达式为

$$f_q = \sum_{i=1}^n (1 - r_i^q) \quad (4)$$

式中, r_i^q 表示指标 i 与指标 q 之间的相关系数, 在此使用的是 Pearson 线性相关系数。特征系数 S_q 的计算公式为

$$S_q = \frac{\sigma_q f_q}{\sum_{q=1}^m \sigma_q f_q} \quad (5)$$

综合特征评价矩阵 X 为

$$X = CS = \begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_n \end{bmatrix} \quad (6)$$

式中, X_n 表示第 n 个特征的综合特征评分。

2 基于 IOMA 优化 CNN

由于 CNN 网络需设置学习率、卷积核大小与数量、全连接层神经元数量等超参数, 其对 CNN 的准确性和收敛速度有重要影响, 因此需对这些参数进行寻优。

2.1 光学显微镜优化算法

光学显微镜算法^[23](optical microscope algorithm, OMA)是 2023 年提出的一种新型智能优化算法, 具有鲁棒性好、易于实现且使用较少控制参数的特点, 该算法从光学显微镜观察物体的过程中得到灵感, 来对问题进行寻优。

光学显微镜优化算法首先会随机初始化种群在解空间中的位置, 种群初始化公式如式(7)所示。

$$x_{ij} = R \times (u_j - l_j) + l_j \quad (7)$$

$$i = 1, 2, 3, \dots, N; j = 1, 2, 3, \dots, D$$

式中: x_{ij} 表示个体 i 的第 j 维变量; N 表示种群大小; l_j 为问题变量的最小值(下界); u_j 为问题变量的最大值(上界); R 表示[0,1]之间的随机数; D 为问题变量的数量(维度)。

在调试物镜阶段, 通过式(8)进行位置更新。

$$x_i^t = x_i^t + m^r * 1.40 * x_{beat}^t \quad (8)$$

式中: t 表示当前迭代次数; x_{beat}^t 为第 t 代种群的最优个体; x_i^t 为第 i 个个体的位置; x_i^t 则表示物镜调试后第 i 个个体的位置; m^r 表示变量取值在[0,1]之间的随机向量。得到 x_i^t 后, 就要进行一次贪婪选择, 以便后续进行目镜放大:

$$\begin{cases} x_i^t = x_i^t, & \text{if } f(x_i^t) \leq f(x_i^t) \\ x_i^t = x_i^t, & \text{else} \end{cases} \quad (9)$$

在调试目镜阶段，种群个体的位置更新公式如式(10)所示。

$$\mathbf{x}_i^2 = \mathbf{x}_i^1 + \mathbf{m}^r * 0.55 * \mathbf{S}_{\text{scope}} \quad (10)$$

式中： \mathbf{x}_i^2 表示目镜调试后第 i 个个体的位置； \mathbf{x}_i^1 是由式(9)得到的； $\mathbf{S}_{\text{scope}}$ 表示搜索范围，如式(11)所示。

$$\mathbf{S}_{\text{scope}} = \begin{cases} \mathbf{x}_i^1 - \mathbf{x}_k^1, & \text{if } f(\mathbf{x}_i^1) \leq f(\mathbf{x}_k^1) \\ \mathbf{x}_k^1 - \mathbf{x}_i^1, & \text{else} \end{cases} \quad (11)$$

式中， k 是从种群中随机选择的一个个体，且 $k \neq i$ 。

得到 \mathbf{x}_i^2 后，再进行一次贪婪选择，就得到了进入下一代种群的个体，综上所述，选择最优观察效果的公式为

$$\begin{cases} \mathbf{x}_i^{t+1} = \mathbf{x}_i^2, & \text{if } f(\mathbf{x}_i^2) \leq f(\mathbf{x}_i^1) \\ f(\mathbf{x}_i^2) = \mathbf{x}_i^1, & \text{else} \end{cases} \quad (12)$$

OMA 算法由于种群初始位置随机，可能会使种群多样性降低，从而导致全局搜索能力较差和收敛效率降低的问题，同时 OMA 算法存在后期易陷入局部最优解的问题。针对以上问题引入 Tent 混沌映射解决种群初始化问题，并引入自适应 t 分布提高算法的寻优能力。

2.2 改进光学显微镜优化算法

1) Tent 混沌映射

由于 Tent 映射可生成均匀分布于[0,1]的初始值，具有更好的遍历性、均匀性^[24]，因此利用 Tent 映射生成[0, 1]均匀随机变量 y ，数学表达式为

$$y_{t+1} = \begin{cases} \frac{y_t}{R}, & 0 \leq y_t \leq R \\ \frac{1-y_t}{1-R}, & R < y_t \leq 1 \end{cases} \quad (13)$$

式中， t 表示当前迭代次数。再将其变换到个体解空间，增加初始种群多样性，个体初始解的数学表

达式为

$$X_I = l + y \cdot (u - l), I = 1, 2, 3, \dots, N \quad (14)$$

式中： X_I 表示 CNN 第 I 组超参数的信息； u 、 l 分别表示各超参数的上限、下限。

2) 自适应 t 分布变异与动态选择策略

自适应 t 分布变异结合柯西变异和高斯变异的优点，能提升算法的全局搜索能力和局部开发能力，并通过自适应参数 ω 平衡这两种能力^[25]。

$$\mathbf{X}_i^{t+1} = \mathbf{X}_i^t + \mathbf{X}_i^t \times \omega \times T(t) \quad (15)$$

式中： \mathbf{X}_i^{t+1} 为扰动后显微镜的位置； \mathbf{X}_i^t 为显微镜 i 第 t 次迭代时的位置； $T(t)$ 为自由度参数，为迭代次数 t 的 t 分布。而随着迭代次数的增加，t 分布逐渐向高斯分布靠拢，有利于增强算法的收敛速度。自适应 t 分布变异算子的引入，虽然能够很大程度上提升算法的寻优性能，但是若无差别地对每次迭代中的所有个体使用，一方面会增加算法的计算时间，另一方面不利于发挥原算法本身的特点。因此，本文采用动态选择概率策略来调节自适应 t 分布变异算子的使用。动态选择概率策略具体公式为

$$p = \omega_1 - \omega_2 \times (t_{\text{max}} - t) / t_{\text{max}} \quad (16)$$

式中： t_{max} 为最大迭代次数； ω_1 决定了动态选择概率的上限； ω_2 决定了动态选择概率的变化幅度。

2.3 IOMA-CNN 方法

IOMA 求解 CNN 网络结构超参数过程如图 1 所示。采用变压器故障诊断准确率最高作为 IOMA 的适应度函数，数学表达式为

$$F_{\text{max}} = \left(\frac{s}{S} \right)_{\text{max}} \quad (17)$$

式中： F_{max} 表示故障诊断的最大准确率； s 指的是诊断结果等于真实故障类型的样本数； S 指的是样本总数。

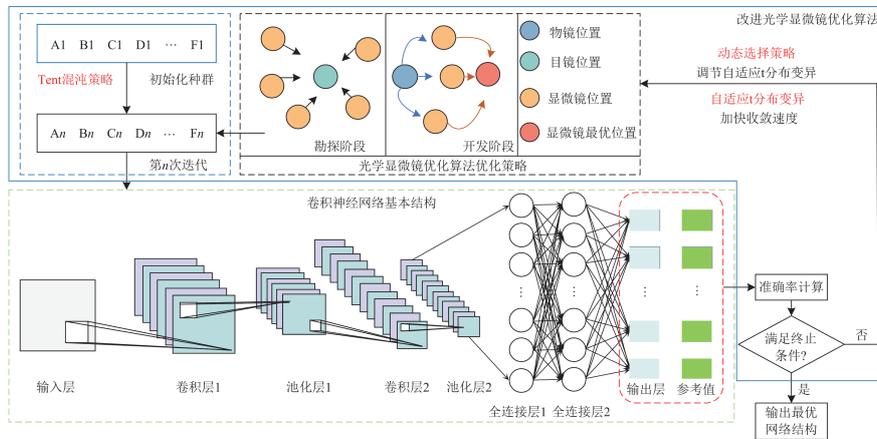


图 1 IOMA 求解 CNN 最佳网络结构过程图

Fig. 1 Process diagram of IOMA solving CNN optimal network structure

3 基于混合特征选择和 IOMA-CNN 的变压器故障诊断模型

基于混合特征选择和 IOMA-CNN 的变压器故障诊断模型结构如图 2 所示, 主要工作包括特征选择、参数寻优和模型测试与评价 3 个步骤。

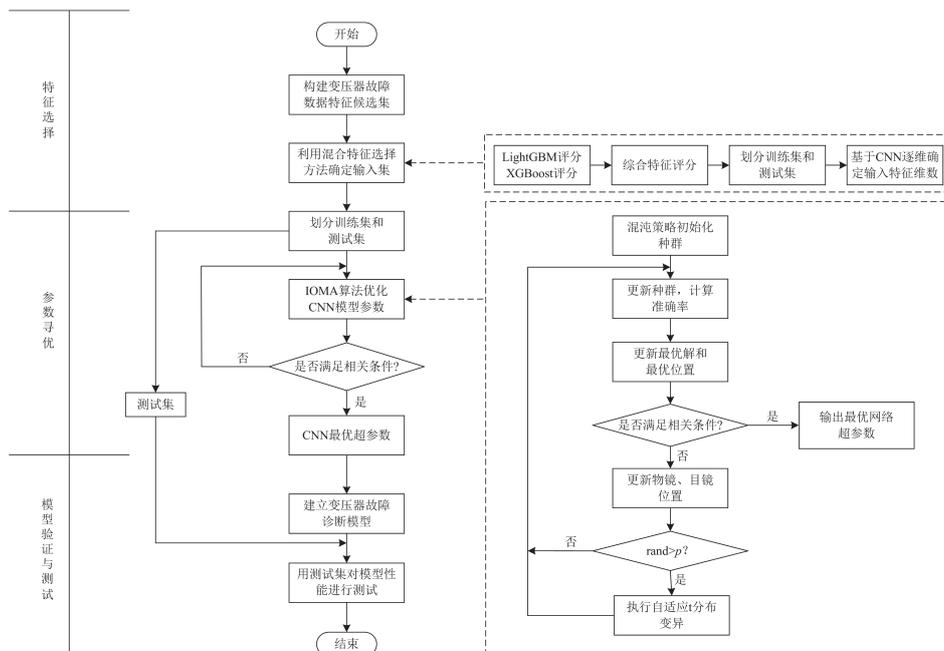


图 2 变压器故障诊断模型结构

Fig. 2 Structure of transformer fault diagnosis model

表 2 故障样本分布及编码

Table 2 Fault sample distribution and coding

故障类型	故障编码	样本数目
正常	1	167
低温过热	2	167
中温过热	3	164
高温过热	4	154
低能放电	5	162
局部放电	6	122
电弧放电	7	149

根据第 1 节所介绍方法, 首先通过 LightGBM 和 XGBoost 算法计算全部特征变量的重要性, 结果如表 3 所示, 重要性评分越大, 特征与故障类型之间的相关性就越强; 然后将两种重要性评估结果进行 min-max 归一化处理, 并通过 CRITIC-TOPSIS 方法加权求得全部特征变量的综合特征重要性评分, 并按照降序排列, 结果如图 3 所示; 最后, 按照 7:3 的比例划分训练集和测试集, 按照逐维诊断的方式每次增加一个特征变量组成候选子集, 并以 CNN 的测试集准确率为目标, 将其输入 CNN 故障

4 算例分析

4.1 特征选择

利用提出的变压器故障诊断方法, 对 IEC TC 10 数据库^[26]、文献[27-28]及西北某电科院统计得到的油浸式变压器监测历史故障共计 1085 组数据进行分析, 样本分布及编码如表 2 所示。

诊断模型中进行诊断, 选取最大目标值对应的候选子集维数作为最终的特征维数。

表 3 故障候选特征集重要性评分

Table 3 Importance score of fault candidate feature set

特征编号	LightGBM 重要性评分	XGBoost 重要性评分	特征编号	LightGBM 重要性评分	XGBoost 重要性评分
1	215	0.049	16	191	0.010
2	126	0.005	17	88	0.008
3	121	0.028	18	91	0.014
4	123	0.018	19	159	0.028
5	128	0.010	20	52	0.003
6	132	0.024	21	18	0.001
7	113	0.005	22	83	0.041
8	114	0.029	23	96	0.007
9	48	0.015	24	86	0.025
10	103	0.015	25	50	0.148
11	81	0.030	26	92	0.014
12	122	0.053	27	14	0.001
13	129	0.124	28	120	0.125
14	125	0.083	29	78	0.052
15	49	0.025	30	52	0.007

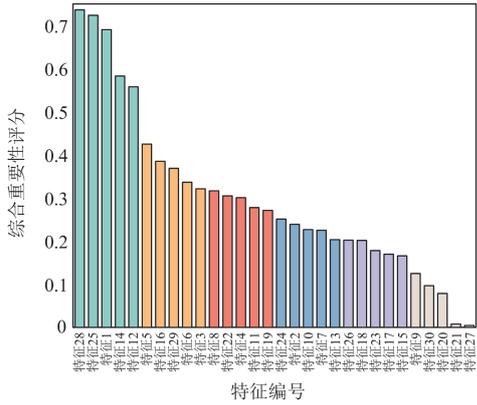


图3 特征变量重要性结果

Fig. 3 Characteristic variable importance results

如图4所示,当特征维数 n 为7或8时,测试集准确率达到最大值(94.7%),考虑到模型诊断效率,本文选取 $n=7$ 时所对应的候选子集作为最终的征兆子集。

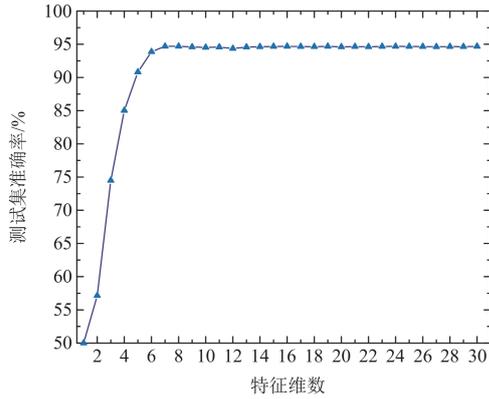


图4 基于不同特征维数的故障诊断模型准确率
Fig. 4 Accuracy of fault diagnosis model based on different feature dimensions

4.2 本文方法有效性分析

将混合特征选择方法筛选得到的7维特征数据集作为模型的输入,并将输入集以7:3的比例划分为训练集与测试集。

为评估所提方法有效性,以准确率 $\eta_{accuracy}$ 、查准率 $\eta_{precision}$ 、查全率 η_{recall} 、Kappa系数为指标,上述指标越高表示模型的诊断性能越好。

$$\begin{cases} \eta_{accuracy} = \frac{S}{S} \\ \eta_{precision} = \frac{s_T}{s_p} \\ \eta_{recall} = \frac{s_T}{s_R} \end{cases} \quad (18)$$

式中: s_T 表示对某故障类型诊断结果正确的样本数; s_p 表示预测为该故障类型的样本总数; s_R 表示该故障类型总样本数。

所提方法的变压器故障混淆矩阵如图5所示,诊断结果如图6所示,评价指标结果如表4所示。

将混合特征方法筛选得到的特征作为 IOMA-CNN 诊断模型的输入特征,图5、图6及表4分别展示了 IOMA-CNN 模型仿真结果的混淆矩阵、诊断结果及评价指标。分析图5和表4可知,本文方法准确率达到98.5%,整体Kappa系数为0.98;其中低温过热类型的查准率最低为95.6%,中温过热、高温过热、低能放电和局部放电4种故障的查准率最高为100%;低能放电的查全率最低为93.0%,正常、低温过热、中温过热、高温过热和电弧放电5种故障的查全率最高可达到100%,而且查全率及

测试集混淆矩阵

	1	2	3	4	5	6	7	
1	58 17.8%	0 0.0%	0 0.0%	0 0.0%	1 0.3%	0 0.0%	0 0.0%	98.3% 1.7%
2	0 0.0%	43 13.2%	0 0.0%	0 0.0%	0 0.0%	2 0.6%	0 0.0%	95.6% 4.4%
3	0 0.0%	0 0.0%	43 13.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
4	0 0.0%	0 0.0%	0 0.0%	48 14.8%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%
5	0 0.0%	0 0.0%	0 0.0%	0 0.0%	40 12.3%	0 0.0%	0 0.0%	100% 0.0%
6	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	35 10.8%	0 0.0%	100% 0.0%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.6%	0 0.0%	53 16.3%	96.4% 3.6%
	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	93.0% 7.0%	94.6% 5.4%	100% 0.0%	98.5% 1.5%
	1	2	3	4	5	6	7	

实际故障类别

预测故障类别

图5 变压器故障诊断结果混淆矩阵

Fig. 5 Confusion matrix of transformer fault diagnosis results

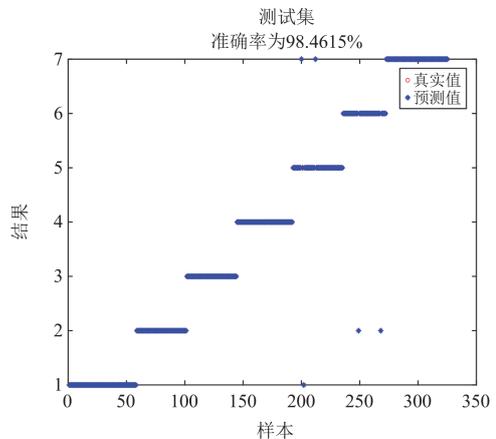


图6 变压器故障诊断结果

Fig. 6 Transformer fault diagnosis results

表 4 LightGBM-ICOA-CNN 方法的评价指标结果

Table 4 Evaluation index results of LightGBM-ICOA-CNN method

故障类型	评价指标			
	Kappa 系数	准确率/%	查准率/%	查全率/%
正常			98.3	100
低温过热			95.6	100
中温过热			100	100
高温过热	0.98	98.5	100	100
低能放电			100	93.0
局部放电			100	94.6
电弧放电			96.4	100

查准率在 7 种故障类型上的分布区间较为稳定, 均高于 93%, 表明 IOMA-CNN 诊断模型具有良好的诊断性能。

4.3 混合特征选择方法可行性分析

为验证混合特征选择方法的有效性, 将 5 种 DGA 气体浓度作为 CNN 模型、SVM 模型和 BP(back propagation, BP)模型的输入特征进行比较。此外, 为验证文中所提方法的优越性, 同样选用 7 维特征变量, 将随机森林(random forest, RF)、LightGBM、XGBoost 和 Pearson 相关系数 4 种特征选择方法所选的输入特征作为对比组。不同输入特征选择方法的诊断结果如图 7 所示。

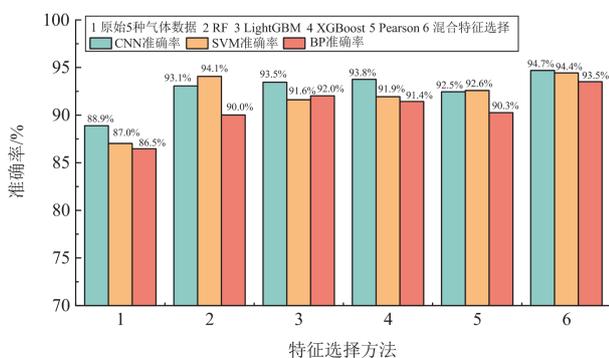


图 7 不同特征选择方法诊断结果对比

Fig. 7 Comparison of diagnostic results of different feature selection methods

分析图 7 可知, 本文所提出的混合特征选择方法在 3 种故障诊断模型中的测试集准确率分别为 94.7%、94.4%、93.5%, 相较于 5 种 DGA 气体浓度作为输入特征的诊断准确率有较大的提升, 与常见的特征选择方法 RF、LightGBM、XGBoost 和 Pearson 相关系数相比, 本文所提方法同样具有更高的准确率。结果表明, 本文提出的混合特征选择方法所选特征能显著提升模型的诊断准确率, 验证了所提方

法的有效性和优越性。

4.4 不同诊断方法性能对比

为了进一步验证 IOMA-CNN 方法的有效性, 在混合特征选择方法的基础上, 将 IOMA-CNN 与随机森林、门控循环单元(gated recurrent unit, GRU)、CNN 3 种模型进行了对比, 并添加了 GWO-CNN、PSO-CNN、OMA-CNN 3 种优化 CNN 模型作为对照组。所有优化算法的初始种群数设置为 30, 最大迭代次数设置为 25。不同模型的诊断结果如表 5 所示。

表 5 不同诊断模型诊断结果

Table 5 Diagnostic results of different diagnostic models

模型名称	准确率/%	Kappa 系数
RF	92.5	0.91
GRU	90.9	0.90
CNN	94.7	0.93
GWO-CNN	95.7	0.95
PSO-CNN	96.3	0.95
OMA-CNN	96.8	0.95
IOMA-CNN	98.5	0.98

分析表 5 可知, 当输入特征同为混合特征选择方法得到的 7 维特征变量时, 本文所提 IOMA-CNN 变压器故障诊断方法的诊断准确率为 98.5%, Kappa 系数为 0.98, 在 3 种诊断模型中均最优, 此外, PSO-CNN 诊断准确率为 96.3%, OMA-CNN 诊断准确率为 96.8%, 由此可知改进后的 IOMA 算法能够有效提升模型的故障诊断准确率, 验证了本文所提改进策略的有效性。

5 结论

为提高基于深度学习的变压器故障诊断精度, 本文提出了一种基于混合特征选择和 IOMA-CNN 的变压器故障诊断方法, 通过算例验证了方法的性能, 得到如下结论。

1) 相较于其他混合特征选择方法, 本文提出的混合特征选择方法故障诊断准确率更高, 通过混合特征选择筛选得到的特征变量, 相比于基础特征变量(5 种 DGA 气体)、RF、LightGBM、XGBoost 和 Pearson 相关系数等特征选择方法, 在 CNN、SVM、BP 故障诊断模型中的诊断准确率分别提高了 0.9%~5.8%、0.3%~7.4%、1.5%~7.0%。

2) 相较于其他智能优化算法, 本文针对 OMA 的改进策略能够有效平衡算法的全局探索与局部开发能力, 避免其陷入早熟。经过 IOMA 优化后的 CNN 模型故障诊断准确率达到 98.5%, 相比于随机森林、GRU 和基础 CNN 模型诊断准确率提高了

3.8%~7.6%，相比于 GWO-CNN、PSO-CNN 和 OMA-CNN 这 3 种利用不同算法优化 CNN 模型诊断准确率提高了 1.7%~2.8%。

3) 本文提出的混合特征选择方法能够保留对故障诊断最有利的特征，减少冗余特征，有效提升诊断模型的诊断性能；所提 IOMA-CNN 变压器故障诊断方法，故障诊断准确率高、性能稳定、泛化性强，具有一定的实际意义。如何在样本数据不平衡的情况下平衡数据集以及对 CNN 的结构进行优化，需要进一步深入研究。

参考文献

- [1] 林凡勤, 李明明, 郭红. 变压器故障诊断技术综述[J]. 计算机与现代化, 2022(3): 116-126.
LIN Fanqin, LI Mingming, GUO Hong. Review on fault diagnosis technology of transformer[J]. Computer and Modernization, 2022(3): 116-126.
- [2] 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.
- [3] 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.
- [4] 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.
- [5] IRUNGU G K, AKUMU A O, MUNDA J L. A new fault diagnostic technique in oil-filled electrical equipment: the dual of Duval triangle[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2016, 23(6): 3405-3410.
- [6] TAHA I B M, HOBALLAH A, GHONEIM S S M. Optimal ratio limits of rogers' four-ratios and IEC 60599 code methods using particle swarm optimization fuzzy-logic approach[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2020, 27(1): 222-230.
- [7] 张卫华, 苑津莎, 张铁峰, 等. 应用 B 样条理论改进的变压器三比值故障诊断方法[J]. 中国电机工程学报, 2014, 34(24): 4129-4136.
ZHANG Weihua, YUAN Jinsha, ZHANG Tiefeng, et al. An improved three-ratio method for transformer fault diagnosis using B-spline theory[J]. Proceedings of the CSEE, 2014, 34(24): 4129-4136.
- [8] 曲岳晗, 赵洪山, 马利波, 等. 多深度神经网络综合的电力变压器故障识别方法[J]. 中国电机工程学报, 2021, 41(23): 8223-8231.
QU Yuehan, ZHAO Hongshan, MA Libo, et al. Multi-depth neural network synthesis method for power transformer fault identification[J]. Proceedings of the CSEE, 2021, 41(23): 8223-8231.
- [9] 臧春艳, 曾军, 李鹏, 等. 一种基于 SVM 算法的电力变压器机械故障智能诊断模型[J]. 高压电器, 2023, 59(12): 216-222, 229.
ZANG Chunyan, ZENG Jun, LI Peng, et al. Intelligent diagnosis model of mechanical fault for power transformer based on SVM algorithm[J]. High Voltage Apparatus, 2023, 59(12): 216-222, 229.
- [10] ZHANG G, LUO J, HE L, et al. Fault diagnosis of oil-immersed transformer based on TSNE and IBASA-SVM[J]. Recent Patents on Mechanical Engineering, 2022, 15(5): 504-514.
- [11] 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 Zhibin. 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.
- [12] 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.
- [13] 刘建锋, 刘梦琪, 董倩雯, 等. 基于改进 VMD 去噪和优化 ELM 方法的变压器早期故障诊断[J]. 电力科学与技术学报, 2023, 38(6): 55-66.
LIU Jianfeng, LIU Mengqi, DONG Qianwen, et al. Transformer early fault diagnosis based on improved VMD denoising and optimized ELM method[J]. Journal of Electric Power Science and Technology, 2023, 38(6): 55-66.
- [14] 李平, 胡根铭. 基于数据增强型一维改进卷积神经网络的变压器故障诊断方法[J]. 电网技术, 2023, 47(7): 2957-2967.
LI Ping, HU Genming. Transformer fault diagnosis based on data enhanced one-dimensional improved convolutional neural network[J]. Power System Technology, 2023, 47(7): 2957-2967.

- [15] 杨威, 蒲彩霞, 杨坤, 等. 基于 CNN-GRU 组合神经网络的变压器短期故障预测方法[J]. 电力系统保护与控制, 2022, 50(6): 107-116.
YANG Wei, PU Caixia, YANG Kun, et al. Short-term fault prediction method for a transformers based on a CNN-GRU combined neural network[J]. Power System Protection and Control, 2022, 50(6): 107-116.
- [16] 卢发兴, 姚鸿鹤, 史浩然. 基于方差分析变量约减的指令制导回路误差分配方法[J]. 系统工程与电子技术, 2020, 42(5): 1131-1138.
LU Faxing, YAO Honghe, SHI Haoran. Error allocation method of instruction guidance loop based on variance analysis variable reduction[J]. Systems Engineering and Electronic, 2020, 42(5): 1131-1138.
- [17] SHABBIR K S N, LIANG X, CHAKRABARTI S. An ANOVA-based fault diagnosis approach for variable frequency drive-fed induction motors[J]. IEEE Transactions on Energy Conversion, 2021, 36(1): 500-512.
- [18] 柴同, 袁逸萍, 马军岩, 等. 基于 K-CNN 和 N-GRU 的风电机组发电机状态预测[J]. 机械强度, 2023, 45(5): 1043-1049.
CHAI Tong, YUAN Yiping, MA Junyan, et al. State prediction of wind turbine generator based on K-CNN and N-GRU[J]. Journal of Mechanical Strength, 2023, 45(5): 1043-1049.
- [19] 高淑萍, 李晓芳, 宋国兵, 等. 基于 Pearson 相关系数与广义 S 变换的低压直流微电网的故障选线方法[J]. 电力系统保护与控制, 2023, 51(15): 120-129.
GAO Shuping, LI Xiaofang, SONG Guobing, et al. Fault line selection method of a low-voltage DC microgrid based on the Pearson correlation coefficient generalized S-transform[J]. Power System Protection and Control, 2023, 51(15): 120-129.
- [20] 丁学辉, 许海林, 罗颖婷, 等. 基于随机森林特征优选与 MAEPSO-ELM 算法的变压器 DGA 故障诊断[J]. 电力科学与技术学报, 2022, 37(2): 181-187.
DING Xuehui, XU Hailin, LUO Yingting, et al. Transformer DGA fault diagnosis based on random forest feature optimization and MAEPSO-ELM algorithm[J]. Journal of Electric Power Science and Technology, 2022, 37(2): 181-187.
- [21] 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.
- [22] 叶育林, 刘森, 黄松, 等. 基于 GJO 特征量优选的 AO-RF 的变压器故障诊断模型[J/OL]. 高压电器: 1-10[2024-03-08]. <http://kns.cnki.net/kcms/detail/61.1127.tm.20221026.1630.002.html>.
YE Yulin, LIU Sen, HUANG Song, et al. Transformer fault diagnosis model based on GJO feature optimization and AO-RF[J/OL]. High Voltage Apparatus: 1-10[2024-03-08]. <http://kns.cnki.net/kcms/detail/61.1127.tm.20221026.1630.002.html>.
- [23] CHENG M, SHOLEH M N. Optical microscope algorithm: a new metaheuristic inspired by microscope magnification for solving engineering optimization problems[J]. Knowledge-Based Systems, 2023: 110939.
- [24] 商立群, 李洪波, 侯亚东, 等. 基于特征选择和优化极限学习机的短期电力负荷预测[J]. 西安交通大学学报, 2022, 56(4): 165-175.
SHANG Liqun, LI Hongbo, HOU Yadong, et al. Short-term power load forecasting based on feature selection and optimized extreme learning machine[J]. Journal of Xi'an Jiaotong University, 2022, 56(4): 165-175.
- [25] SWATHI B, PRAKASH S M, KRISHNA T B. A chaotic whale optimization algorithm (CWOA) based multiobjective conjoint spectrum utilization in a cognitive radio (CR) network[J]. International Journal of Communication Systems, 2023, 36(18): 1-17.
- [26] DUVAL M, DEPABLO A. Interpretation of gas-in-oil analysis using new IEC publication 60599 and IEC TC 10 databases[J]. IEEE Electrical Insulation Magazine, 2001, 17(2): 31-41.
- [27] ENWEN L, LINONG W, SONG B. Fault diagnosis of power transformers with membership degree[J]. IEEE Access, 2019, 7: 28791-28798.
- [28] 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.
YIN Jinliang. Study on oil-immersed power transformers fault diagnosis based on relevance vector machines[D]. Beijing: North China Electric Power University, 2013.

收稿日期: 2024-01-24; 修回日期: 2024-04-29

作者简介:

闵永智(1975—), 男, 通信作者, 博士, 教授, 博导, 研究方向为人工智能测试、图像识别和电气化铁路多源接入; E-mail: minyongzhi@mail.lzjtu.cn

令世文(2000—), 男, 硕士研究生, 研究方向为变压器故障诊断. E-mail: 1602936663@qq.com

(编辑 魏小丽)