

变压器健康状态实时预警方法及可解释性分析

廖才波¹, 蒋子豪¹, 杨金鑫¹, 邵剑², 王同磊², 李轩²

(1. 南昌大学能源与电气工程系, 南昌 330031; 2. 国网江苏省电力有限公司电力科学研究院, 南京 211103)

摘要: 传统变压器健康状态评估主要依赖行业导则和专家经验, 通常采用周期性的离线评估方式, 难以反映设备实时状态。基于数据驱动的评估模型虽适用于持续跟踪设备运行状态及其发展趋势, 但存在对原始样本要求高、可解释性不足等问题。因此, 该文提出了一种基于不平衡数据的可解释变压器健康状态预警方法。首先, 通过自适应综合过采样方法有效扩充少数类样本, 生成均衡化的样本集; 其次, 构建基于贝叶斯优化轻量梯度提升机的变压器健康状态预警模型, 实现对变压器健康状态的精准、高效预测; 最后, 引入沙普利值加性解释归因理论, 从全局与个体两个角度开展变压器健康状态预警影响因素分析, 有效量化了各状态参量对模型预测结果的影响度。研究表明, 该文方法对变压器健康状态的识别平均准确率为 98.46%, 可有效反映变压器特征参量与模型预测结果之间的动态联动过程, 为现场变压器的智能运维及差异化检修策略制定提供有效支撑。

关键词: 变压器; 健康预警; 轻量梯度提升机; 自适应综合过采样; 沙普利值; 可解释性

Real-time Warning Method and Interpretability Analysis of Transformer Health Condition

LIAO Caibo¹, JIANG Zihao¹, YANG Jinxin¹, SHAO Jian², WANG Tonglei², LI Xuan²

(1. Department of Energy and Electrical Engineering, Nanchang University, Nanchang 330031, China;

2. Electric Power Research Institute of State Grid Jiangsu Electric Power Co., Ltd., Nanjing 211103, China)

Abstract: Traditional transformer health condition assessment primarily relies on industry guidelines and expert experience, typically employing periodic offline evaluations, which makes it difficult to reflect the real-time status of the equipment. Data-driven assessment models, while suitable for continuous tracking of equipment operation and its development trends, face issues such as high demands on raw sample quality and insufficient interpretability. Hence, this paper proposes an interpretable transformer health condition early warning method based on imbalanced data. First, an adaptive synthetic oversampling method is employed to effectively augment the minority class samples, generating a balanced dataset. Subsequently, a transformer health condition early warning model based on Bayesian optimization and lightweight gradient boosting is constructed to achieve precise and efficient forecasting of the transformer's health status. Finally, the Shapley value additive explanation attribution theory is introduced to conduct an analysis of the factors influencing the early warning of transformer health status from both global and individual perspectives, effectively quantifying the impact of each state parameter on the model's predictive outcomes. The research indicates that the proposed method achieves an average accuracy rate of 98.46% in identifying the health status of transformers, effectively reflecting the dynamic interplay between transformer characteristic parameters and the model's predictive results. The results can provide effective support for the intelligent maintenance and the formulation of differentiated maintenance strategies for transformers in operation.

Key words: transformer; health warning; LightGBM; ADASYN; SHAP value; interpretability

0 引言

随着新型电力系统的提出与构建, 电网对电力设备的运行维护提出更高的要求。电力变压器作为重要的输变电设备, 担负电压转换和电能传输的关键作用, 直接关系到电网安全稳定运行^[1]。据统计,

截至 2023 年, 国内 220 kV 及以上变压器的数量约为 22 000 台, 但可用系数呈现下降趋势。因此, 提高电力变压器的健康状态实时追踪水平, 降低设备非计划停运的影响, 对保障电力系统安全稳定具有重要意义^[2-5]。

目前, 现场运维人员主要依据《油浸式变压器(电抗器)状态评价导则》^[6]等标准对变压器开展定期健康评估工作。该方法根据变压器及各组部件的在线监测、离线试验及运行维护等状态量信息, 采用

基金资助项目: 国家自然科学基金 (52367001)。

Project supported by National Natural Science Foundation of China (52367001).

扣分形式判断变压器当前的运行状态。尽管该方法涵盖了丰富的多维度特征量,且判断规则简单,但部分指标数据存在获取难度或工作量大、更新不及时、指标判定依赖专家经验等问题,难以满足掌握设备实时运行状态的现场管理需求。

近年来,人工智能技术逐步被应用于基于数据驱动的变压器健康状态预警和评估领域,如模糊理论^[7]、证据推理^[8]、支持向量机(support vector machine, SVM)^[9]、分类回归树(classification and regression tree, CART)^[10]、人工神经网络^[11]及轻量梯度提升机(light gradient boosting machine, Light GBM)^[12]等,并取得了一定的成果。文献[13]根据变压器状态评价体系的层次性及模糊不确定性,采用改进证据理论实现了变压器健康状态评估。文献[14]提出基于信息决策理论的变压器状态预警方法,通过构建信息决策表和提取状态决策规则,实现了不完整信息条件下对变压器异常状态的准确预警。文献[15]提出了一种基于频域介电谱法的变压器绝缘老化评估方法,结合多元回归分析与 SVM 模型构建特征参量数据库和老化状态分类模型,有效预测变压器健康状态。文献[16]通过构建多层感知机模型和马尔科夫链原理,实现了对变压器运行状态的有效评估和缺陷预测。相比于传统方法,上述评估方法在精度及效率方面均有大幅提升,但在现场应用时依然存在以下问题:1) 现有方法难以平衡状态量全面性与设备数据完整性、更新及时性等方面的问题,导致评估结果实用性不高。2) 异常运行状态主变数量相对较少,加之相关案例报告记录信息不全面,导致各状态类别样本数据不均衡^[17],制约了模型的泛化性能。3) 上述评估方法大多为“黑箱”模型,输入状态量与评估模型结果的关联性不如传统状态评价方法明确,同时难以量化个体样本评估结果的主要影响因素,极大程度限制了其在现场的推广应用^[18-19]。

针对以上问题,本文提出一种基于不平衡数据的可解释变压器健康状态预警方法,辅助在运主变健康状态的劣化识别和实时预警。考虑到变压器样本不均衡性,首先,采用自适应综合过采样(adaptive synthetic, ADASYN)技术扩充少数类样本,形成均衡样本集。其次,构建融合 LightGBM 和沙普利值加性解释(shapley additive explanations, SHAP)的变压器健康状态预警模型,并结合贝叶斯优化算法,实现对设备实时运行状态的准确、可靠跟踪,预警

设备状态发展趋势。最后,结合现场案例,定性和定量分析变压器状态量对模型预测结果的影响过程及边际贡献,并验证本文方法的有效性。

1 变压器健康预警指标选取与状态划分

1.1 健康预警指标选取

变压器绝缘系统的状态是影响变压器整体健康状态和服务寿命的决定性因素。在变压器的运行周期内,由绝缘油、纸组成的绝缘系统会承受电气、机械和热应力的联合作用,导致绝缘材料的加速裂解和老化除了绝缘系统本身受损,还可能进一步引发其他组件的损坏,从而影响变压器的整体性能和寿命。因此,本文参考《油浸式变压器绝缘老化判断导则》^[20-23]等文献,选用油中溶解气体分析和绝缘油试验关键参量作为评价指标,如表 1 所示。这些指标不仅能够全面反映设备内部的状态,揭示潜在的故障机制和性能退化趋势,而且允许以实时、非侵入式、低成本的方式获取特征信息,为实时追踪设备状态提供数据支撑。

1.2 健康等级划分

目前,国内外对于变压器健康状态等级的划分标准不一,涵盖 3~6 个健康等级的划分方式均有所应用^[24-25]。本文重点参考 IEC《电网资产战略管理》白皮书及相关文献^[26-27],将变压器的健康状态划分为健康、亚健康、注意、异常和严重 5 个等级。相比于状态评价导则中的 4 个等级,本文从设备运行维护措施优化角度出发,结合专家经验及现有导则进一步细分设备健康状态,并参考各健康等级设备的数量,修正注意、异常及严重状态的划分区间,实现兼顾设备管理需求及运维资源合理配置下的设备健康等级划分方式。各健康等级及其对应的状况描述如表 2 所示。

表 1 变压器健康预警指标

Table 1 Transformer health warning indicators

状态量	特征描述	状态量	特征描述
S ₁	H ₂ 体积分数	S ₁₀	C ₂ H ₆ 体积分数
S ₂	O ₂ 体积分数	S ₁₁	C ₂ H ₂ 体积分数
S ₃	N ₂ 体积分数	S ₁₂	总烃(TH)体积分数
S ₄	O ₂ 和 N ₂ 体积分数比值	S ₁₃	油中腐蚀性硫(DBDS)
S ₅	CH ₄ 体积分数	S ₁₄	油介质损耗因数(PF)
S ₆	CO 体积分数	S ₁₅	油击穿电压(BV)
S ₇	CO ₂ 体积分数	S ₁₆	油界面张力(IT)
S ₈	CO ₂ 和 CO 体积分数比值	S ₁₇	油中水分质量分数(WC)
S ₉	C ₂ H ₄ 体积分数		

表2 变压器健康状态等级及含义

健康等级	健康状况对应描述	差异化维护措施
健康	状况良好	开展日常巡视, 并适当延长检修周期
亚健康	轻微劣化	推送 I 级告警信息, 加强运行中监测, 维持固定周期设备检修
注意	明显劣化	推送 II 级告警信息, 重点监视运行, 并适时开展检修
异常	严重劣化或有明显缺陷	推送 III 级告警信息, 开展设备诊断工作, 尽快实施检修
严重	存在严重缺陷或故障	推送 IV 级告警信息, 退出运行, 开展设备检修或更换

2 模型算法及原理

2.1 ADASYN 数据均衡化算法

目前, 研究人员多从数据和算法两个层面应对样本不平衡。基于算法层面的方法易于增加模型复杂性和计算成本, 而数据层面的方法以易于理解和实现、通用性强等优势应用广泛。常见的数据层面方法有欠采样、过采样或二者结合的方法等^[28]。当前应用较广泛的包括合成少数类过采样技术 (synthetic minority over-sampling technique, SMOTE) 及其衍生的改进版本。与 SMOTE 相比, ADASYN 可动态合成样本或调整权重分配, 更加适应噪声、样本类别重叠等复杂情况^[29], 因此本文采用 ADASYN 算法实现变压器健康预警样本数据增强。主要计算过程如下。

1) 计算样本不平衡率 d 。在变压器健康预警原始数据集中, 亚健康状态样本为多数类样本, 样本总数为 H_{\max} ; 其他状态等级的样本为少数类, 样本总数为 H_{\min} 。

$$d = H_{\max} / H_{\min} \quad (1)$$

2) 若 d 低于确定的阈值 d_{th} (样本失衡比例最大容忍程度的预设阈值), 则 ADASYN 开始工作。计算少数类样本所需合成的样本总量 G 。

$$G = (H_{\max} - H_{\min}) \cdot c \quad (2)$$

式中: $c \in (0, 1]$ 表示样本集过采样后实现的平衡级别的参数; 当 $c=1$ 时, 过采样后就是一个完全平衡的样本集。

3) 计算比率 v_i 。通过计算所有少数类样本在 n 维空间中的欧氏距离, 确定其 K 近邻样本以及亚健康样本在 K 近邻样本中的占比。

$$v_i = \Delta i / K, \quad i = 1, 2, \dots, H_{\min} \quad (3)$$

式中: Δi 为 K 个近邻样本中亚健康样本的数量。

4) 对 v_i 进行标准化处理。

$$\rho_i = v_i / \sum_{i=1}^{H_{\min}} v_i \quad (4)$$

式中: ρ_i 为密度分布。

5) 确定亚健康样本外的任意样本 x_i 需要生成的样本数 g_i 。

$$g_i = \rho_i G \quad (5)$$

6) 对于每个少数类样本 x_i , 按以下步骤生成 g_i 个合成数据:

(1) 从数据 x_i 的 K 个最近邻中随机选择一个少数类样本 x_{ki} 。

(2) 按照式(6)合成少数类。

$$q_i = (x_{ki} - x_i) \cdot \alpha + x_i \quad (6)$$

式中: $(x_{ki} - x_i)$ 是 n 维空间中的差分向量; α 为 $[0, 1]$ 范围内的随机数。

2.2 LightGBM 基本原理

梯度提升决策树 (gradient boosting decision tree, GBDT) 是一种基于 boosting 集成学习思想的加法模型, 通过迭代优化 CART 残差和前向分布算法训练, 广泛应用于回归和分类问题^[30]。由于 GBDT 在计算每一维特征所有可能分割点的信息增益时, 都需遍历整个样本集, 当面对高维特征空间及大规模数据集时, 计算代价极大。为解决上述问题, 微软在 2017 年对 GBDT 进行创新性扩展, 推出了 LightGBM 这一先进高效的 boosting 框架模型, 通过四大优化算法, 增强了模型对噪声的鲁棒性, 同时具备精度高、训练速度快、能够处理大规模数据、内存占用率低, 且支持并行和 GPU 学习等优点^[31], 可有效满足现场对于构建高效、准确的变压器预警模型的需求。

1) 直方图加速

与基于特征预排序的算法不同, LightGBM 使用直方图算法降低寻找最佳分割值的计算成本。图 1 为直方图算法示意图, 其中, LightGBM 将输入连续 Float 数据离散为不同 Bin 数据, 遍历寻找最佳分割点。直方图算法不仅减少了内存的使用, 加快了模型的计算速度, 而且带来了一定的正则化效果, 可以使模型避免过拟合, 具有较好的泛化性。

2) 带深度限制的 Leaf-wise 生长策略

GBDT 等传统树模型采用按层生长 (level-wise) 的决策树生长方式, 如图 2(a) 所示, 大部分节点分裂的信息增益较低, 对模型分类性能的影响较小,

全部分裂不仅未能提升模型性能，反而降低训练效率。相比之下，LightGBM 采用带有深度限制的按叶生长(leaf-wise)的策略，如图 2(b)所示，每次选择信息增益最大的叶子进行分裂，相较于按层生长策略，不仅有效降低模型复杂度，提升训练效率，还能防止过拟合。

3) 样本与特征的高效处理策略

LightGBM 融合单边梯度采样(gradient-based one-side sampling, GOSS)和互斥特征捆绑(exclusive feature bundling, EFB)算法，降低模型样本和特征层面的复杂度。GOSS 侧重于保留对模型更新贡献较大的样本，辅以小梯度样本以丰富学习过程，维持精度的同时提升效率。EFB 算法通过特征捆绑降低特征维度，同时保持信息完整性，进一步加速模型训练。综合高效采样策略，LightGBM 在处理复杂数据时展现出卓越的性能和效率。

2.3 SHAP 归因理论

SHAP 是一种基于 Shapley 值的机器学习解释器，用于精确量化和直观展示特征对模型预测的贡献和相互作用^[32]。与局部可解释模型无关的解释(local interpretable model-agnostic explanations, LIME)^[33]、逐层相关性传播(layer-wise relevance propagation, LRP)^[34]等方法类似，它属于一种可加性特征归因方法。在合作博弈理论中，Shapley 值用于度量每位玩家对集体收益的边际贡献，通过计算所有玩家组合的收益平均差异，以确定个体在不同合作联盟中的贡献。Shapley 值遵循如下数学公式：

$$\varphi_i(v) = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(N-|S|-1)!}{N!} (v(S \cup \{i\}) - v(S)) \quad (7)$$

式中： N 表示玩家的总数； S 为 N 个玩家的一个子集； $|S|!$ 表示集合 S 所有元素排列的总数， $(N-|S|-1)!$ 表示除去 S 之外的所有元素排列的总数； $v(S)$ 为 S 个玩家的总收益值； $v(S \cup \{i\}) - v(S)$ 表示玩家 i 加入 S 时的边际贡献。

据此，Lundberg 和 Lee 提出了 SHAP 理论，用作机器学习模型解释的通用框架，将模型的预测输出视作合作博弈中的累积收益，其中模型输入特征映射为博弈参与者，特征的重要性则对应于参与者对博弈结果的边际收益贡献。因此，可将式(7)转化为式(8)。

$$\varphi_i = \sum_{T \subseteq F \setminus \{i\}} \frac{|T|!(|F|-|T|-1)!}{|F|!} (f_{T \cup \{i\}}(x_{T \cup \{i\}}) - f_T(x_T)) \quad (8)$$

式中： F 为所有特征量的集合； f 为学习模型； i 为

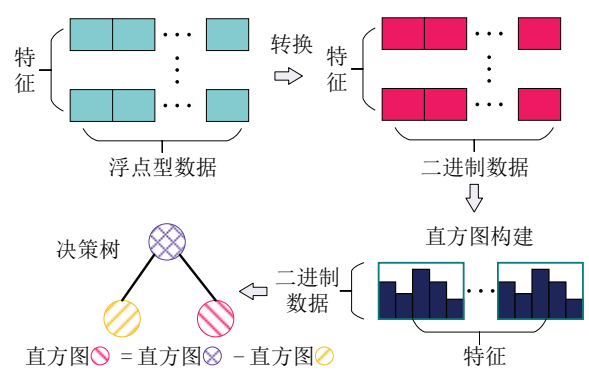


图1 直方图算法示意图

Fig.1 Histogram algorithm diagram

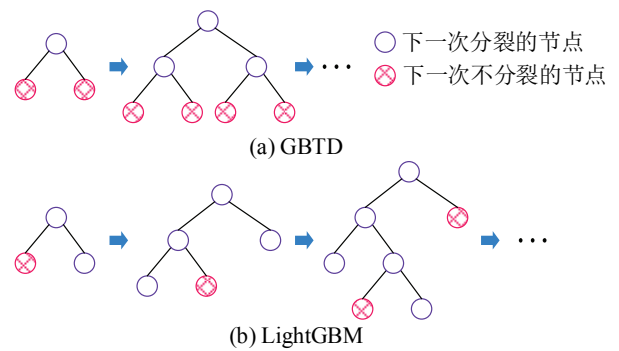


图2 leaf-wise 生长策略示意图

Fig.2 Diagram of leaf-wise growth strategy

特征量； φ_i 为特征 i 对于模型预测的贡献； x_T 表示输入特征集合 T 中的特征值； $f_{T \cup \{i\}}$ 为包含特征 i 训练的模型，而 f_T 是不包含特征 i 训练出的模型； $f_{T \cup \{i\}}(x_{T \cup \{i\}}) - f_T(x_T)$ 表示加入特征 i 与不加入特征 i 时模型预测结果的差异； $|F|!$ 和 $|T|!$ 表示所有集合 F 或 T 所有元素排列的总数； $(|F|-|T|-1)!$ 表示除去特征 i 和 T 之外的所有元素排列的总数。

基于 SHAP 理论可实现任意训练过的模型中输入特征对预测结果贡献的量化与解释。本文借助 SHAP 理论从全局与个体两个维度开展变压器健康预警影响因素分析^[35]。全局方面，依据每个特征的平均 SHAP 值来评估单个特征对模型的整体影响程度，以确定特征的重要度排序。此外，通过 SHAP 可视化特征自身数值与其 SHAP 值的分布关系，确定特征对预测结果的影响大小与方向。个体方面，使用 SHAP 值来解释特定样本特征对模型预测结果的详细贡献，基于样本特征贡献确定影响设备健康状态的关键因素，以指导现场维护策略制定。

2.4 模型应用流程

本文所提出的一种基于不平衡数据的可解释

变压器健康状态预警方法包括离线训练和在线预警两大板块。离线训练阶段涵盖变压器健康预警指标选取、原始数据集的均衡化处理、贝叶斯优化^[36]的 LightGBM 分类模型的构建与训练、模型性能评估和 SHAP 可解释性分析 5 个环节。在线预警阶段则涉及设备实时状态研判、告警信息推送和差异化维护措施制定等步骤。一种基于不平衡数据的可解释变压器健康状态预警方法如图 3 所示。

图 3 基于不平衡数据的可解释变压器健康状态预警方法应用的主要流程如下:

1) 构建变压器健康预警指标体系, 基于在线监测数据、离线实验等选取变压器健康预警指标, 为后续原始数据集构建提供基础支撑。

2) 均衡化原始样本集, 划分原始数据集并采用 ADASYN 过采样方法对少数类样本进行扩充, 实现训练样本集高度均衡。

3) 构建变压器健康预警模型, 基于均衡化样本集训练贝叶斯优化的 LightGBM 分类模型, 通过构建的强分类器, 实现变压器运行状况的精准识别。

4) 选取全局准确率、全局精确率、异常样本召回率、严重样本召回率、预测时间等指标进行模型评价, 采用 SHAP 归因理论, 从全局和个体两个角度评估特征对结果的贡献。

5) 输入设备实时预警数据, 预测设备实时状态并确定影响设备状态的关键影响因素, 基于设备实时告警信息推送结果给出差异化维护措施。

3 试验结果与分析

3.1 变压器样本数据预处理

本文从文献[37]和某地市电网公司中共收集 648 条变压器样本数据, 以 80%和 20%比例划分变压器样本集, 开展变压器健康预警模型训练及测试。变压器样本集数据分布如表 3 所示。

由表 3 可知, 变压器样本集中亚健康状态 269 例, 占样本总量的 41.5%, 而严重状态样本仅 33 例, 占比 5.1%, 样本不平衡率最高达 8.15, 表明该变压器样本集存在严重的数据不均衡问题。对此, 本文采用 ADASYN 算法对变压器原始样本集进行数据增强, 并设置其参数为: $d=0.75$, $K=5$, $c=1$ 。结果表明, 经 ADASYN 算法进行过采样后, 变压器训练集样本数量由 518 条扩充为 1 075 条, 严重状态样本数量为 215 条, 各变压器健康状态等级样本数量均处于平衡状态。

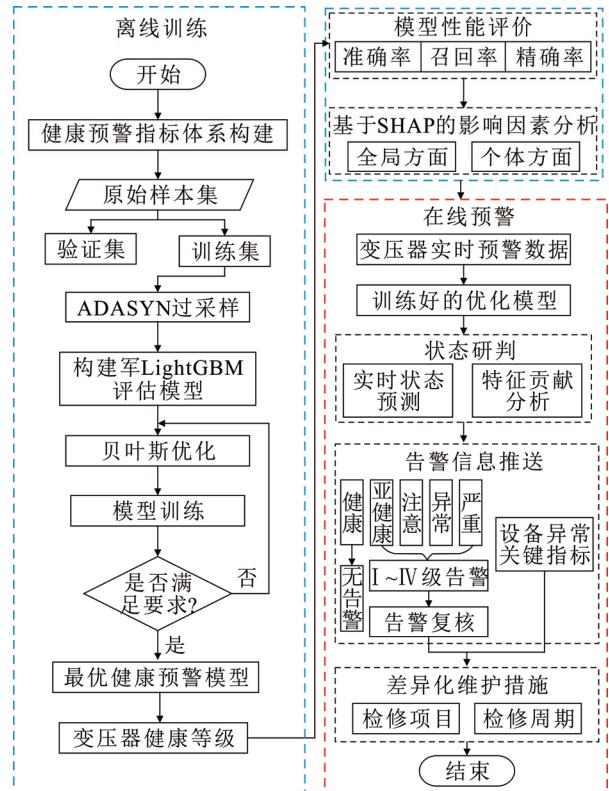


图 3 模型应用流程图

Fig.3 Model application flowchart

表 3 样本数据分布

Table 3 Sample data distribution

健康等级	样本数量	训练样本	测试样本	不平衡率
健康	155	124	31	1.74
亚健康	269	215	54	—
注意	85	68	17	3.16
异常	106	85	21	2.54
严重	33	26	7	8.15
样本总数	648	518	130	—

为减小变压器状态量之间的量纲及数值差异性, 从而提升预警模型的训练效果及预测精度, 本文对输入状态量值进行归一化处理, 计算式为:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (9)$$

式中: x_{\max} 和 x_{\min} 分别为输入状态量的最大值和最小值; x' 为数据归一化后的输入值。

3.2 健康预警结果分析

在构建基于 LightGBM 的变压器健康预警模型时, 由于集成算法结构复杂、参数类型繁多, 其预测性能取决于合适的超参数设置。对此, 本文选取表 4 中 LightGBM 模型的关键超参数进行调节。

基于变压器均衡样本集, 在 LightGBM 模型预训练结束后, 分别采用随机搜索(random search,

RS)、粒子群优化(particle swarm optimization, PSO)、贝叶斯优化(Bayesian optimization, BO)等算法对其超参数进行寻优, 结果如图 4 所示。

结果表明, 在对 LightGBM 模型参数寻优时, 由于 RS 算法采取随机跳转策略, 缺乏方向性及学习能力, 导致整体寻优效率较低。PSO 算法通过不断更新粒子的速度和位置来寻找最优解, 以提升参数寻优的效率。但在高维空间中, 粒子的搜索容易受到限制, 可能会陷入局部最优解。BO 算法由于采取主动选择前序采样策略, 其寻优速度较 RS 和 PSO 算法分别提升 3.84 和 2.36 倍。同时, 经 BO 算法优化后的 LightGBM 模型的平均准确率为 98.46%, 表明 BO 算法具有出色的寻优效果。

BO 算法优化后 LightGBM 模型的树的最大深度为 9, 叶子节点数为 322, 树数量为 168, 学习率为 0.19, 叶子节点最小样本数为 10, 其他参数保持默认值。图 5 为基于 BO-LightGBM 变压器健康预警模型在 130 组测试集样本的预测结果。为直观分析预警模型对各健康等级样本的识别情况, 在混淆矩阵图中增加精确率和召回率, 分别对应最下方一行和最右侧一列。

由图 5 可知, LightGBM 模型对各变压器健康等级的预测精确率均达到 90%以上, 表明模型在预测不同健康等级均具有较高的分类精度。LightGBM 模型对测试样本的预测结果沿混淆矩阵对角分布, 异常、严重状态样本的召回率均为 100%, 其全局准确率达到 98.46%。同时, 仅有 2 个样本的分类结果错误, 且均发生在注意与异常状态之间, 对变压器检修决策影响较小。

为验证本文过采样方法的有效性, 选取变压器原始样本集(D_1)、SMOTE 处理后的样本集(D_2)、Borderline SMOTE 过采样的数据集(D_3)及 ADASYN 处理后样本集(D_4)作为数据基础, 分别对 LightGBM 模型进行训练和优化。由于处于异常和严重状态下的变压器发生故障的可能性更大, 影响设备运行的可靠性及稳定性。因此本文选取异常召回率、严重召回率及全局准确率作为模型评价指标, 结果如表 5 所示。

结果表明, 由于不平衡样本的影响, LightGBM 模型在变压器原始样本集的全局准确率仅为 84.62%, 且对严重状态的识别率较低。采用 SMOTE 过采样方法处理的变压器样本集, 一定程度解决了变压器样本不平衡问题, 但严重状态的召回率不足

表 4 LightGBM 超参数优化结果

Table 4 Optimization results of LightGBM hyperparameters

超参数名称	超参数描述	默认值	调参范围
max_depth	树的深度	5	(5,12)
num_leaves	叶子节点个数	31	(15,512)
n_estimators	树的数量	100	(10,200)
min_child_sample	叶子最小样本数	20	(5,100)
learning_rate	学习率	0.1	(0.01,0.3)

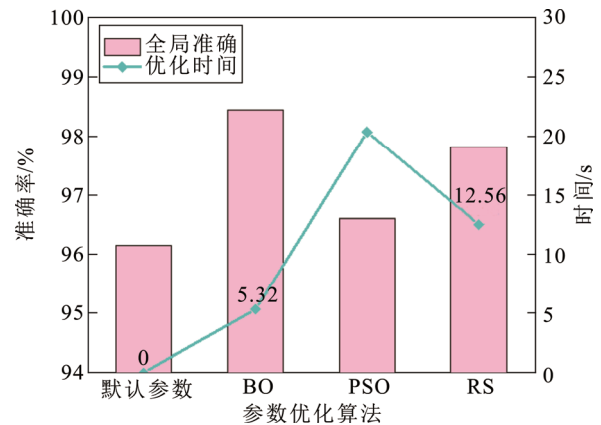


图 4 优化算法结果分析

Fig.4 Analysis of optimization algorithm results

准确率98.46%, 错误率1.54%

真实结果	预测结果					精确率	召回率
	健康	亚健康	注意	异常	严重		
健康	31 23.85%	0 0%	0 0%	0 0%	0 0%	100%	0%
亚健康	0 0%	54 41.54%	0 0%	0 0%	0 0%	100%	0%
注意	0 0%	0 0%	15 11.54%	2 1.54%	0 0%	88.24%	11.76%
异常	0 0%	0 0%	0 0%	21 16.15%	0 0%	100%	0%
严重	0 0%	0 0%	0 0%	0 0%	7 5.38%	100%	0%
		100% 0%	100% 0%	100% 0%	91.30% 8.70%	100% 0%	98.46% 1.54%

图 5 混淆矩阵

Fig.5 Confusion matrix

表 5 采样方法对比分析

Table 5 Comparative analysis of sampling methods

数据集	全局准确率/%	异常召回率/%	严重召回率/%
D_1	84.62	80.95	71.43
D_2	96.92	90.47	85.71
D_3	96.92	95.24	100.00
D_4	99.23	100.00	100.00

90%, 原因为 SMOTE 方法基于样本之间的距离合成样本, 无法有效处理样本重叠问题。Borderline SMOTE 提升了 SMOTE 处理噪声、异常值以及样本重叠的能力, 相较于 SMOTE 其异常、严重召回率都有一定提升, 但其对于非线性决策边界的问题处理能力仍然不足, 而 ADASYN 算法则充分考虑了样本密度的分布情况, 其异常和严重召回率均为 100%, 表明该方法能更好地处理决策边界下的样本不平衡问题, 有效提升少数类样本的预测精度。

此外, 本文开展了线性判别分析(linear discriminant analysis, LDA)、CART、随机森林(random forest, RF)、极端梯度提升(extreme gradient boosting, XGBoost)等机器学习算法与本文预警方法的对比分析。在经贝叶斯优化及多次重复训练后, 不同算法的结果如图 6 所示。

研究表明, LDA 模型的全局预测准确率不如其他非线性算法模型, 且容易在异常和严重状态等级间出现误判, 表明变压器状态量与健康等级存在一定的非线性关系。此外, RF、XGBoost 和 LightGBM 等集成算法模型的预测效果也要优于单模型 CART 算法。最后, LightGBM 模型的全局准确率为 98.46%, 高于其他 4 种分类模型, 且对异常和严重状态具有较好的识别能力。同时, 由于 LightGBM 模型在梯度提升树的基础上采用更高效的分裂策略, 其预测效率优于 XGBoost 模型。因此, 本文方法具有较好的预测效率及准确性, 能够满足现场变压器实时预警需求。

3.3 模型可解释性分析

本文在 LightGBM 预警模型训练过程中, 引入基于 SHAP 的可解释性框架, 以获取变压器健康状态的关键影响因素。依据各状态量 SHAP 值, 可实现影响模型输出结果的特征重要度排序, 从全局角度得到最重要的 6 个状态量, 并详细分析它们对预测结果的影响过程, 如图 7 所示。

图 7 中, 每个点都包含了相应样本的特征信息。纵坐标表示特征量, 重要度从上到下逐渐降低, 横坐标代表特征 SHAP 值。样本各特征值的相对大小通过颜色的深浅来表示, 特征值越大颜色越深, 特征值越小颜色越浅, 详细说明参照图 7 右侧的图例。

由图 7 可知, 在所有状态量中, C₂H₂、H₂、C₂H₆、油介质损耗因数、C₂H₄ 和油中腐蚀性硫这 6 个状态量对模型预测结果影响最为显著。本文以 C₂H₂ 为例, 通过分析特征值与特征 SHAP 值之间的关联关

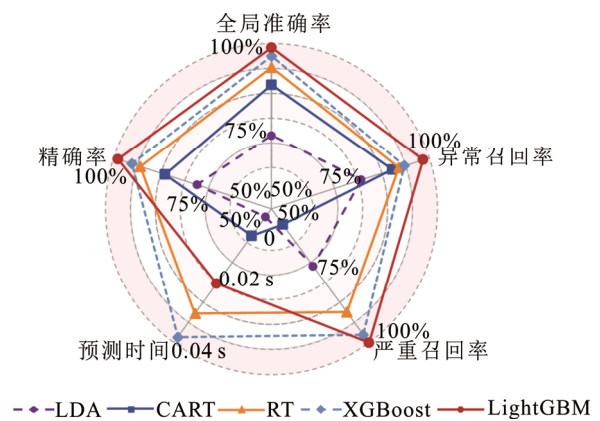


图 6 模型预测性能比较

Fig.6 Comparison of model prediction performance

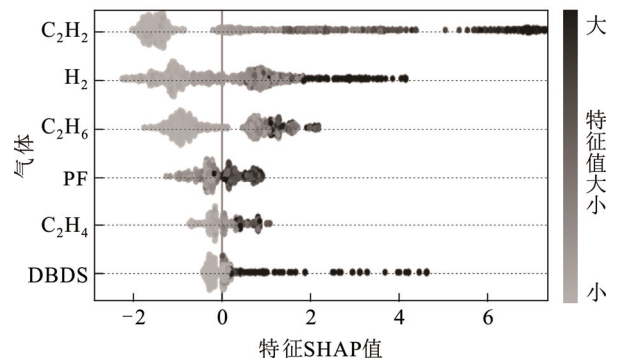


图 7 特征分析概要图

Fig.7 Feature analysis summary chart

系验证模型解释框架的有效性。当 C₂H₂ 的含量接近 0 时, SHAP 值为负, 变压器处于健康状态的可能性较高; 而随着 C₂H₂ 的含量增加时, SHAP 值大于 0, 变压器的运行状态也逐渐由健康状态向严重状态过渡。实际上, 当变压器内部出现少量 C₂H₂ 时, 但未超过《变压器油中溶解气体分析和判断导则》^[38] 规定的注意值, 变压器内部可能出现轻微故障迹象, 此时需加强设备状态监测, 并密切注意 C₂H₂ 的含量变化。当 C₂H₂ 含量超过注意值, 且产气速率不断增大, 通常表明变压器内部发生了严重的放电故障, 需要立即停电检修处理。结果表明, 该方法能够有效揭示 C₂H₂ 含量变化趋势对预测结果的影响及客观物理规律。同理, 基于 SHAP 的全局分析可开展其他变压器状态量对模型预测结果的解释性分析。图 8 为测试集中预测结果为严重状态的单样本 SHAP 特征贡献图。由图 8 可知, C₂H₂ 的体积分数为 4.60, 其对应的 SHAP 值为 5.74, 是 LightGBM 模型将该样本预测为严重状态的关键影响因素。同

时, H_2 的体积分数和油介质损耗因数的 SHAP 值均大于 0, 对模型预测严重状态起正向贡献作用。相反, 由于 C_2H_6 的体积分数仅为 3.20, 对应的 SHAP 值为-0.7, 一定程度降低了该样本预测为严重状态的可能性。综合各状态量的边际贡献, 模型最终输出的 SHAP 值为 2.90, 大于严重状态等级的基准值 -4.04, 因此可以确定该样本对应变压器内部存在严重缺陷, 且结果可信度较高。

4 实例分析

以某地区 500 kV 主变为例, 进一步验证本文方法的有效性。2016 年 11 月 8 日前, 该台主变所有试验及监测数据正常; 11 月 8 日, 主变油色谱在线监测装置提示 C_2H_2 体积分数为 0.33。随后, 立即增加油色谱的跟踪频次, 并密切关注该台主变的运行状态。11 月 21 日, 主变 C_2H_2 体积分数的离线检测结果为 2.35, 且油中水分质量分数及击穿电压的试验结果均显示异常。为防止缺陷进一步发展, 随即申请主变临时停运检查。结合该主变相关历史数据, 开展变压器的健康状态预警, 预警结果如图 9 所示。

由图 9 可知, 该主变在 11 月 8 日前, 一直维持健康状态运行, 直至 8 日当天状态发生突变, 由健康状态突变到注意状态, 模型立刻发出 II 级告警, 并推送重点监视运行, 适时开展检修的建议。11 月 21 日, 模型识别到该主变已劣化至异常状态, 发出 III 级告警, 并推送开展设备诊断工作, 尽快实施检修的建议。结合设备实际状态与预警过程可发现, 本文方法可及时、精确预警设备状态并追踪状态发展趋势。此外, 选取关键时间节点数据进一步分析设备健康状态突变原因, 对应数据如表 6 所示。

基于本文方法, 各时间节点预测结果及其对应状态量的特征贡献如图 10 所示。图中, l_i 表示对应状态量的 SHAP 值, 向右箭头色块表示该状态量对模型预测结果为正向贡献, 向左箭头色块表示负向贡献度。

由图 10(a)可知, 油界面张力、油中水分质量分数和氢气体积分数的试验结果均在规定的阈值范围内, 其对应的 SHAP 值为正, 促使预警模型的预测结果向健康状态移动。变压器健康状态的基准值为 -4.31, 而预警模型最终输出 SHAP 值为 4.73, 因此判定该主变在 5 月 25 日处于健康状态, 且可信度较高。图 10(b)中, 由于变压器内部出现少量乙炔, 并且油击穿电压为 48 kV, 低于阈值 50 kV, 均对 11

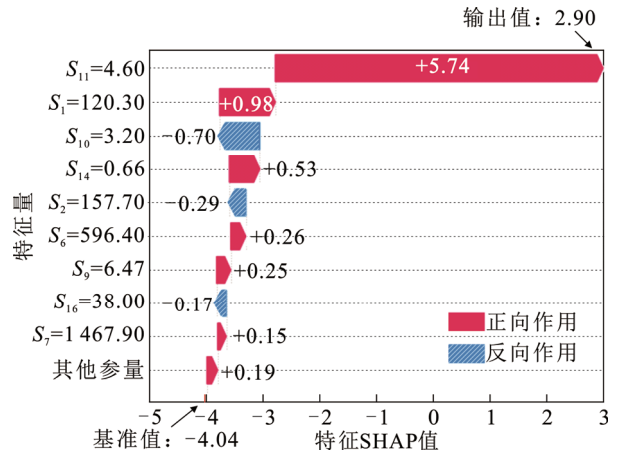


图 8 单样本 SHAP 特征贡献图

Fig.8 SHAP feature contribution diagram of a single sample

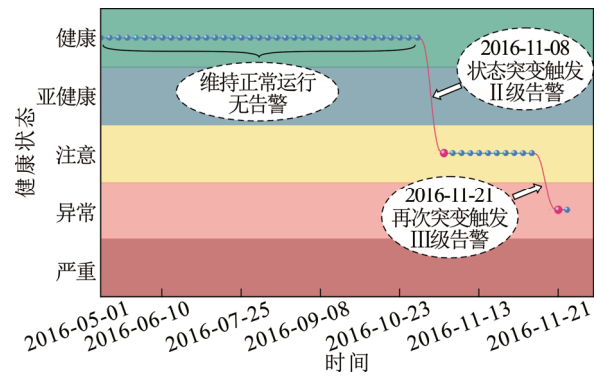


图 9 500 kV 主变健康状态实时预警过程

Fig.9 Real-time warning process of health status of 500 kV power transformer

表 6 500 kV 主变试验数据

Table 6 Test data of 500 kV transformer

特征量	取值		
	2016-05-25	2016-11-08	2016-11-21
$S_1/10^{-6}$	52.04	20.34	50.22
$S_2/10^{-6}$	68	102	92
$S_3/10^{-6}$	482	2 680	2420
$S_4/\%$	0.14	0.04	0.38
$S_5/10^{-6}$	6.30	3.44	4.87
$S_6/10^{-6}$	350.45	154.37	364.06
$S_7/10^{-6}$	897.92	631.19	1 491.96
$S_8/\%$	2.56	3.56	4.56
$S_9/10^{-6}$	0.64	0.35	0.78
$S_{10}/10^{-6}$	0.81	0.44	0.74
$S_{11}/10^{-6}$	0	0.33	2.35
$S_{12}/10^{-6}$	7.74	4.56	8.74
$S_{13}/10^{-6}$	0	0	0
$S_{14}/\%$	0.12	0.21	0.23
S_{15}/kV	52	48	45
$S_{16}/(N \cdot m^{-1})$	63	56	52
$S_{17}/(mg \cdot L^{-1})$	1	6	16

月 8 日样本的预测过程起正向贡献作用。而油中腐蚀性硫的 SHAP 值为-0.43, 对注意状态的预测结果起到负向贡献作用, 但影响较小。变压器注意状态的基准值为-3.42, 而预警模型输出的 SHAP 值为 2.87, 因此判定该样本处于注意状态。在图 10(c)中, 油中水分质量分数超标, 乙炔体积分数为 2.35, 同时油击穿电压进一步降低, 这 3 个状态量已成为推动预测结果向异常状态转变的重要影响因素。最终, 预警模型对 11 月 21 日样本输出的 SHAP 值为 -0.56, 大于异常状态的基准值-3.52, 表明该变压器已处于异常状态, 且内部缺陷仍在进一步恶化。

图 11 为该台主变停运后设备内部解体检查结果。可以看出, 该主变中性点套管尾部均压环出现脱落, 并滞留在绝缘平台上。同时, 中性点端部导线靠在均压环内螺纹边缘, 出现悬浮放电和绝缘烧损现象。

结合该台主变的健康状态预警过程, 本文方法可通过监测变压器状态量的变化有效预警设备内部真实的运行状态和发展趋势。同时, 基于 SHAP 的个体分析, 可以实现变压器健康状态预测结果和各状态量的关联关系, 并及时反映变压器内部缺陷原因, 辅助现场运维人员开展变压器运检工作。

5 结论

为实现变压器健康状态的实时预警及趋势预测, 推动设备健康管理降本增效, 本文提出了一种基于不平衡数据的可解释变压器健康状态预警方法, 结论如下:

- 1) 提出了一种基于 ADASYN 的变压器健康预警样本数据增强方法, 自适应生成少数类样本实现样本数据平衡分布, 提升了极不平衡样本下的变压器健康预警准确率。
- 2) 基于均衡变压器样本集, 构建了一种基于 LightGBM 的变压器健康预警模型, 并采用贝叶斯算法对模型进行优化, 其准确率可达 98.46%。同时, 模型预测效果优于 RF 和 XGBoost 等算法, 表明本文方法具有较好的预测效率及准确性。
- 3) 提出了一种基于 SHAP 归因理论的变压器健康状态预警结果的影响因素可解释框架, 从全局角度挖掘影响变压器健康状态的关键特征量及其重要度, 从个体角度解释模型对变压器健康状态预警决策的影响过程及程度, 有效提高状态预警结果的可信度, 可为现场运维人员制定变压器差异化检修策略提供参考依据。

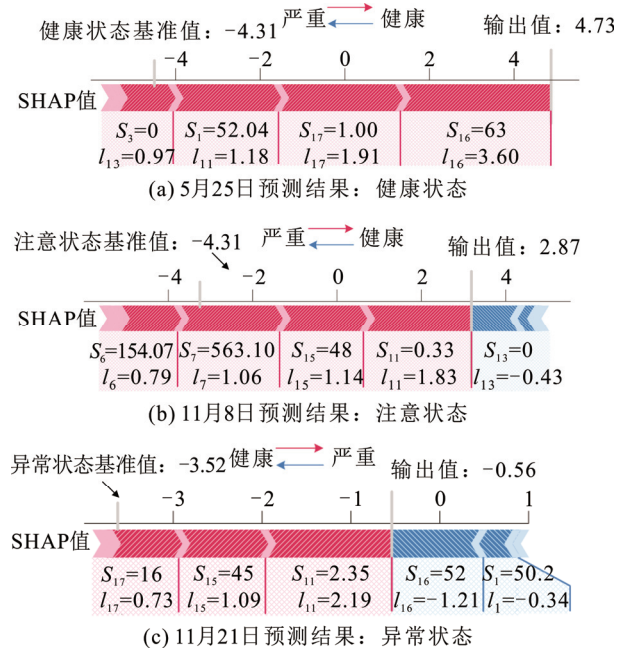


图 10 500 kV 主变预警结果特征贡献分析
Fig.10 Feature contribution analysis to early warning results for 500 kV transformer



(a) 均压环从套管尾部脱落 (b) 中性点端部导线绝缘烧损

图 11 500 kV 主变检查结果

Fig.11 Inspection results of 500 kV transformer

参考文献 References

- [1] 廖才波, 杨金鑫, 胡 雄, 等. 数据与经验混合驱动下的变压器故障分层诊断方法[J]. 高电压技术, 2023, 49(5): 1841-1850. LIAO Caibo, YANG Jinxin, HU Xiong, et al. Hierarchical diagnosis method for transformer faults driven by mixed data and experience[J]. High Voltage Engineering, 2023, 49(5): 1841-1850.
- [2] 齐 波, 冀 茂, 郑玉平, 等. 电力物联网技术在输变电设备状态评估中的应用现状与发展展望[J]. 高电压技术, 2022, 48(8): 3012-3031. QI Bo, JI Mao, ZHENG Yuping, et al. Application status and development prospect of power internet of things technology in condition assessment of power transmission and transformation equipment[J]. High Voltage Engineering, 2022, 48(8): 3012-3031.
- [3] JAHROMI A, PIERCY R, CRESS S, et al. An approach to power transformer asset management using health index[J]. IEEE Electrical Insulation Magazine, 2009, 25(2): 20-34.
- [4] 国家能源局, 中国电力企业联合会. 2022 年全国电力可靠性年度报告[R]. 北京: 国家能源局, 2023.

- National Energy Administration, China Electricity Council. National electric power reliability annual report 2022[R]. Beijing, China: National Energy Administration, 2023.
- [5] 李波, 张文乾, 刘维, 等. 基于熵权层次法的油浸式变压器绝缘状态评价[J]. 电力工程技术, 2023, 42(4): 223-230.
LI Bo, ZHANG Wenqian, LIU Wei, et al. Insulation condition evaluation of oil-immersed transformer based on entropy weight hierarchy method[J]. Electric Power Engineering Technology, 2023, 42(4): 223-230.
- [6] 国家能源局. 油浸式变压器(电抗器)状态评价导则: DL/T 1685—2017[S]. 北京: 中国电力出版社, 2017.
National Energy Administration. Guide for condition evaluation of oil-immersed power transformers (reactors): DL/T 1685—2017[S]. Beijing, China: China Electric Power Press, 2017.
- [7] 石宜金, 谭贵生, 赵波, 等. 基于模糊综合评估模型与信息融合的电力变压器状态评估方法[J]. 电力系统保护与控制, 2022, 50(21): 167-176.
SHI Yijin, TAN Guisheng, ZHAO Bo, et al. Condition assessment method for power transformers based on fuzzy comprehensive evaluation and information fusion[J]. Power System Protection and Control, 2022, 50(21): 167-176.
- [8] 张鹏, 齐波, 李文璞, 等. 考虑部位和性能的电力变压器差异化评价方法[J]. 中国电机工程学报, 2019, 39(20): 6138-6147.
ZHANG Peng, QI Bo, LI Wenpu, et al. A differentiated evaluation method of transformers considering the part and its performances[J]. Proceedings of the CSEE, 2019, 39(20): 6138-6147.
- [9] 崔家齐, 董海鹰, 李帅兵, 等. 基于图像特征识别的绝缘纸老化状态评估[J]. 高电压技术, 2022, 48(2): 636-643.
CUI Jiaqi, DONG Haiying, LI Shuaibing, et al. Aging state evaluation of insulating paper based on image feature recognition[J]. High Voltage Engineering, 2022, 48(2): 636-643.
- [10] 张国治, 陈康, 方荣行, 等. 基于DGA与鲸鱼算法优化LogitBoost-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.
- [11] 阮羚, 谢齐家, 高胜友, 等. 神经网络和信息融合技术在变压器状态评估中的应用[J]. 高电压技术, 2014, 40(3): 822-828.
RUAN Ling, XIE Qijia, GAO Shengyou, et al. Application of artificial neural network and information fusion technology in power transformer condition assessment[J]. High Voltage Engineering, 2014, 40(3): 822-828.
- [12] 李轩, 梅飞, 沙浩源, 等. 考虑样本不平衡的特高压换流阀状态评估及其影响因素分析[J]. 中国电机工程学报, 2022, 42(4): 1558-1568.
LI Xuan, MEI Fei, SHA Haoyuan, et al. State evaluation of UHVDC converter valve considering sample imbalance and its influencing factors analysis[J]. Proceedings of the CSEE, 2022, 42(4): 1558-1568.
- [13] 朱承治, 郭创新, 孙旻, 等. 基于改进证据推理的变压器状态评估研究[J]. 高电压技术, 2008, 34(11): 2332-2337.
ZHU Chengzhi, GUO Chuangxin, SUN Min, et al. Power transformer condition assessment based on improved evidential reasoning[J]. High Voltage Engineering, 2008, 34(11): 2332-2337.
- [14] 徐尧宇, 李元, 王怡静, 等. 信息缺失下变压器状态预警方法[J]. 高电压技术, 2020, 46(9): 3062-3069.
XU Yaoyu, LI Yuan, WANG Yijing, et al. Early-warning methods of transformer conditions under information deficiency[J]. High Voltage Engineering, 2020, 46(9): 3062-3069.
- [15] 范贤浩, 刘捷丰, 张懿议, 等. 融合频域介电谱及支持向量机的变压器油浸纸绝缘老化状态评估[J]. 电工技术学报, 2021, 36(10): 2161-2168.
FAN Xianhao, LIU Jiefeng, ZHANG Yiyi, et al. Aging evaluation of transformer oil-immersed insulation combining frequency domain spectroscopy and support vector machine[J]. Transactions of China Electrotechnical Society, 2021, 36(10): 2161-2168.
- [16] 贺馨仪, 董明, 刘文君, 等. 面向调控领域多源数据融合的电力变压器态势感知与预警方法研究[J]. 电工电能新技术, 2023, 42(4): 48-58.
HE Xinyi, DONG Ming, LIU Wenjun, et al. Research on power transformer situation awareness and warning method based on multi-source data fusion in power network dispatching field[J]. Advanced Technology of Electrical Engineering and Energy, 2023, 42(4): 48-58.
- [17] 蒲天骄, 韩笑. 新型电力系统中人工智能应用的关键技术[J]. 电力信息与通信技术, 2024, 22(1): 1-13.
PU Tianjiao, HAN Xiao. Research on key technologies in the application of artificial intelligence in new type power systems[J]. Electric Power Information and Communication Technology, 2024, 22(1): 1-13.
- [18] 刘云鹏, 许自强, 李刚, 等. 人工智能驱动的数据分析技术在电力变压器状态检修中的应用综述[J]. 高电压技术, 2019, 45(2): 337-348.
LIU Yunpeng, XU Ziqiang, LI Gang, et al. Review on applications of artificial intelligence driven data analysis technology in condition based maintenance of power transformers[J]. High Voltage Engineering, 2019, 45(2): 337-348.
- [19] 史佳琪, 马丽雅, 李晨晨, 等. 基于串行-并行集成学习的高峰负荷预测方法[J]. 中国电机工程学报, 2020, 40(14): 4463-4472.
SHI Jiaqi, MA Liya, LI Chenchen, et al. Daily peak load forecasting based on sequential-parallel ensemble learning[J]. Proceedings of the CSEE, 2020, 40(14): 4463-4472.
- [20] 国家能源局. 油浸式变压器绝缘老化判断导则: DL/T 984—2018[S]. 北京: 中国电力出版社, 2018.
National Energy Administration. Guide for the diagnosis of insulation aging in oil-immersed power transformer: DL/T 984—2018[S]. Beijing, China: China Electric Power Press, 2018.
- [21] LI C Y, YANG Y, XU G Q, et al. Insulating materials for realising carbon neutrality: opportunities, remaining issues and challenges[J]. High Voltage, 2022, 7(4): 610-632.
- [22] ZHANG Y Y, XU C Q, WEI W C, et al. Preparation and thermal-mechanical property evaluation of cellulose insulation paper with differing nano-SiC contents[J]. High Voltage, 2023, 8(3): 599-610.
- [23] TAN X M, GUO C, WANG K, et al. A novel two-stage dissolved gas analysis fault diagnosis system based semi-supervised learning[J]. High Voltage, 2022, 7(4): 676-691.
- [24] CIGRE. Working Group WG A2.49. Condition assessment of power transformers[R]. Paris, France: CIGRE, 2019.
- [25] AZMI A, JASNI J, AZIS N, et al. Evolution of transformer health index in the form of mathematical equation[J]. Renewable and Sustainable Energy Reviews, 2017, 76: 687-700.
- [26] 国际电工委员会(IEC). 电网资产战略管理[M]. 北京: 中国电力出版社, 2017.
International Electrotechnical Commission. Strategic asset management of power networks[M]. Beijing, China: China Electric Power Press, 2017.
- [27] ASHKEZARI A D, MA H, SAHA T K, et al. Application of fuzzy support vector machine for determining the health index of the insula-

- tion system of in-service power transformers[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2013, 20(3): 965-973.
- [28] 余松, 胡东, 唐超, 等. 基于TLR-ADASYN平衡化数据集的MSSA-SVM变压器故障诊断[J]. 高电压技术, 2021, 47(11): 3845-3853.
YU Song, HU Dong, TANG Chao, et al. MSSA-SVM transformer fault diagnosis method based on TLR-ADASYN balanced data set[J]. High Voltage Engineering, 2021, 47(11): 3845-3853.
- [29] 杨昊, 胡文秀, 张璐, 等. 基于ADASYN数据平衡化的PSO-BPNN变压器套管故障诊断[J]. 电力工程技术, 2024, 43(2): 170-178.
YANG Hao, HU Wenxiu, ZHANG Lu, et al. Fault diagnosis of transformer oil-paper bushings in PSO-BPNN algorithm based on ADASYN data balancing[J]. Electric Power Engineering Technology, 2024, 43(2): 170-178.
- [30] 陈纬楠, 胡志坚, 岳菁鹏, 等. 基于长短期记忆网络和LightGBM组合模型的短期负荷预测[J]. 电力系统自动化, 2021, 45(4): 91-97.
CHEN Weinan, HU Zhijian, YUE Jingpeng, et al. Short-term load prediction based on combined model of long short-term memory network and light gradient boosting machine[J]. Automation of Electric Power Systems, 2021, 45(4): 91-97.
- [31] 黄梓欣, 汪涛, 徐昂, 等. 基于临界超标样本扩充的数据驱动短路电流超标精准校验方法[J]. 电网技术, 2024, 48(6): 2564-2573.
HUANG Zixin, WANG Tao, XU Ang, et al. Data-driven accurate verification method for short-circuit current over-limited based on critical over-limited samples expansion[J]. Power System Technology, 2024, 48(6): 2564-2573.
- [32] LI L B, QIAO J D, YU G, et al. Interpretable tree-based ensemble model for predicting beach water quality[J]. Water Research, 2022, 211: 118078.
- [33] LIU W X, ZHAO J H, QIU J, et al. Interpretable hybrid experimental learning for trading behavior modeling in electricity market[J]. IEEE Transactions on Power Systems, 2023, 38(2): 1022-1032.
- [34] ZHOU D D, XU Q, ZHANG J C, et al. Interpretable sleep stage classification based on layer-wise relevance propagation[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 3511710.
- [35] 蒋莹莹, 田建艳, 姬政雄, 等. 可解释性验证的光伏出力实时纠偏概率预测模型[J]. 高电压技术, 2024, 50(9): 3944-3954.
JIANG Yingying, TIAN Jianyan, JI Zhengxiong, et al. Interpretability verification of real-time deviation correction probability prediction model of photovoltaic output[J]. High Voltage Engineering, 2024, 50(9): 3944-3954.
- [36] 邹智, 吴铁洲, 张晓星, 等. 基于贝叶斯优化CNN-BiGRU混合神经网络的短期负荷预测[J]. 高电压技术, 2022, 48(10): 3935-3945.
ZOU Zhi, WU Tiezhou, ZHANG Xiaoxing, et al. Short-term load forecast based on Bayesian optimized CNN-BiGRU hybrid neural networks[J]. High Voltage Engineering, 2022, 48(10): 3935-3945.
- [37] VELÁSQUEZ R M A, LARA J V M. Corrosive Sulphur effect in power and distribution transformers failures and treatments[J]. Engineering Failure Analysis, 2018, 92: 240-267.
- [38] 国家能源局. 变压器油中溶解气体分析和判断导则: DL/T 722—2014[S]. 北京: 中国电力出版社, 2015.
National Energy Administration. Guide to the analysis and the diagnosis of gases dissolved in transformer oil: DL/T 722—2014[S]. Beijing, China: China Electric Power Press, 2015.



LIAO Caibo

Ph.D.

Associate professor
Corresponding author

廖才波(通信作者)

1989—, 男, 博士, 副教授, 硕导

主要从事输变电设备多物理场仿真分析及状态评估方面的研究工作

E-mail: lcb1752@126.com



JIANG Zihao

蒋子豪

1998—, 男, 硕士生

主要从事输变电设备状态评估方面的研究工作

E-mail: 1981375284@qq.com

收稿日期 2024-05-16 修回日期 2024-12-25 编辑 卫李静