

DOI: 10.19783/j.cnki.pspc.240533

新型电力系统下基于物理信息 LSTM 网络的 电力变压器状态评估方法

林苑^{1,2}, 赵晋斌¹, 孙明琦², 闫音蓓³

(1. 上海电力大学, 上海 200090; 2. 国网上海市南供电公司, 上海 200030; 3. 国网上海市北供电公司, 上海 200072)

摘要: 新型电力系统下电网具有间歇性、波动性特征, 在此背景下电力变压器运行将面临多物理场耦合作用的复杂工况。针对传统的电力变压器状态评估模型存在无法有效挖掘缺陷和失效机理、无法有效利用多源异构数据的问题, 提出了一种基于物理信息长短期记忆(long short-term memory, LSTM)网络的电力变压器状态评估方法。融入模型-数据驱动思想, 为电力变压器在新型电力系统背景下的精细化管理和智能运维提供新的研究思路。首先, 分析电力变压器在电磁-流体-温度多物理场耦合下的物理模型, 建立变压器的状态评估先验知识函数。然后, 将该知识函数嵌入 LSTM 网络损失函数中, 惩罚违反物理先验知识的“黑箱”数据, 有效挖掘多物理场耦合复杂工况下电力变压器的演化规律, 通过 Softmax 分类器获取电力变压器健康指数和寿命预测模型。最后, 根据变压器实际运行情况验证所提算法的有效性, 实现对电力变压器关键性能及其相关性分析的综合状态评估。

关键词: 新型电力系统; 物理信息 LSTM 网络; 电力变压器; 状态评估

Power transformer condition assessment method based on physics-informed LSTM network in the context of new power systems

LIN Yuan^{1,2}, ZHAO Jinbin¹, SUN Mingqi², YAN Yinbei³

(1. Shanghai University of Electric Power, Shanghai 200090, China; 2. State Grid Shanghai Shinan Power Supply Company, Shanghai 200030, China; 3. State Grid Shanghai Shibe Power Supply Company, Shanghai 200072, China)

Abstract: In the context of new power systems, the grid exhibits intermittent and fluctuating characteristics, subjecting power transformers to complex working conditions involving multi-physical field coupling. To address the limitations of traditional power transformer condition assessment models, such as their inability to effectively uncover defect and failure mechanisms or to make full use of multi-source heterogeneous data, a power transformer condition assessment based on physics-informed LSTM network is proposed. The approach integrates model-driven and data-driven concepts, offering a new research direction for the refined management and intelligent operation and maintenance of power transformers under new power system conditions. First, the physical model of power transformers under electromagnetic-fluid-temperature multi-physics coupling is analyzed to establish a prior knowledge function for transformer condition assessment. Then, the knowledge function is embedded into the loss function of the LSTM network to penalize “black-box” data that violate physical prior knowledge. This enables effectively discovery of the evolution patterns of power transformers under complex coupled conditions. A Softmax classifier is used to obtain the health index and life prediction model of power transformers. Finally, the effectiveness of the proposed algorithm is verified based on the actual transformer operation data, achieving a comprehensive condition assessment of key performance indicators and their interrelationships.

This work is supported by the National Natural Science Foundation of China (No. 51777120).

Key words: new power systems; physics-informed LSTM network; power transformer; condition assessment

0 引言

以新能源为主的新型电力系统具有更强的随机

性、波动性和复杂性特征, 在此背景下电力设备的绝缘材料需经受叠加电场、温度场等多物理场耦合的复杂工况, 这对电力设备运行维护的精细化管理提出了更高的要求^[1]。电力变压器作为电力系统中的关键设备, 确保其运行状态健康稳定对于保障电

基金项目: 国家自然科学基金项目资助(51777120)

力系统安全稳定至关重要,因此在新型电力系统背景下,探究多物理场耦合条件下电力变压器的状态演化规律,研究更加全面综合的电力变压器健康管理和智能运维新技术具有重要意义^[2-4]。

电力变压器是由油、铜、铁等多种材料组成的复杂系统,在日常运维过程中发生电、热、老化等故障而产生少量的气体溶解于绝缘油中,其各种成分体积分数及不同组的比率关系与变压器运行状态密切相关^[5-7],采用变压器油中溶解气体分析(dissolved gas analysis, DGA)进一步预测变压器的运行状态。但文献[8-9]指出,在新型电力系统下电力变压器复杂程度更高、集成性更强,各部件之间的耦合程度更深,运用传统的因果分析法对其状态评估和故障预警存在极大困难。随着数字化和人工智能技术的发展,运用数据驱动模型对变压器进行状态评估成为近年研究热点^[10]。文献[11]通过引入特征和时序双重注意力机制实现对变压器油中溶解气体进行更准确和稳定的预测。文献[12]提出基于长短期记忆(long short-term memory, LSTM)网络模型实现了对变压器运行状态间各特征参量间蕴藏的内在规律和关联性的深度挖掘。文献[13]提出了一种高功率谱熵差值寻优的变分模态分解和长短期记忆网络的预测方法,减弱非周期信号对预测的影响,提高了状态预测的精度。但是,上述文献都是采用纯数据驱动方法对电力变压器进行状态评估,存在着在电力系统运维工作中的“黑箱”问题,对模型机理的可解释性、泛化性差,同时工作人员在日常运维中采集到的数据大多为正常样本,而关键的异常状态样本数据稀少^[14];采用纯物理模型的方法,虽然有助于辨明问题起源、认清问题机理的优点,但是在新型电力系统背景下各状态特征量间与变压器设备间存在复杂的耦合关联特性,物理知识模型难以清晰表达^[15],限制了物理机理方法在新型电力系统中的实施效果。采用数据驱动的方法往往适用于数据样本齐全场景下,能够构建相关的模型,从数据中挖掘关联特征,而物理知识驱动方法能够研究系统整体的机理模型。因此,若能将物理知识驱动与数据驱动方法相结合,实现全局问题和局部特征、规则与经验的有机集合^[16],将有助于提出性能更优的联合方法以解决新型电力系统下源荷双向不确定问题^[17],文献[18]提出了一种基于物理信息神经网络(physics-informed neural network, PINN)模型对湖水温度进行预测,把物理模型隐含的先验知识和机器学习结合,通过结合少量真实数据,得到预测效果和泛化能力更好的融合模型,这些特点可以

很好地解决在新型电力系统场景下,电力变压器状态评估中存在的物理上不可行或不一致的解、泛化性和可解释性差等问题。

综上所述,本文提出基于物理信息 LSTM 网络的电力变压器状态评估方法,采用知识-数据联合驱动架构,将多物理场耦合工况下电力变压器温度模型嵌入至新构造的损失函数中,充分利用先验知识和数据驱动的函数近似能力,实现电力变压器多源状态数据与设备关键性能的综合预测和健康管理评估,为电力变压器在新型电力系统背景下的精细化管理和智能运维带来新的研究范式。

1 物理信息神经网络

1.1 物理信息神经网络模型

2019 年布朗大学应用数学研究团队首次提出了一种物理方程作为运算限制约束的物理信息神经网络模型,其有效地解决了在物理机理不是很明确且观测到的数据样本不足的情况下,通过在机器学习建模的过程中嵌入物理知识先验的方法,将物理规律作为神经网络的模型约束和归纳偏好,提升了机器学习模型的可解释性、泛化性和鲁棒性,同时提高了有限观测数据样本下的训练速度和计算效率。物理信息神经网络如图 1 所示。

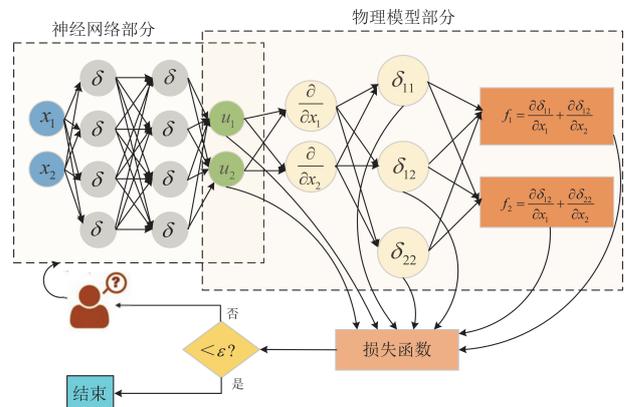


图 1 物理信息神经网络示意图

Fig. 1 Schematic diagram of physical-informed neural network

从图 1 可以看出,各种物理规律模型可以作为先验约束条件嵌入现有的神经网络,其主要是将知识经验嵌入到损失函数中,本质上有两个关键点: 1) 在神经网络中的输出或隐藏层中的变量变更为知识驱动下的变量; 2) 通过正则化对控制函数中的损失函数嵌入知识驱动下的变量。因此,知识-数据联合驱动下的新损失函数 L 为

$$L = \underbrace{L_s(u, \tilde{u})}_{\text{数据驱动}} + \lambda \cdot R(w, b) + \gamma \cdot \underbrace{R_z(x, \tilde{u})}_{\text{知识驱动}} \quad (1)$$

式中: L_s 为常规的损失函数; u 为监督学习下预测的输出值; \tilde{u} 为实际测量值; λ 和 γ 分别为神经网络下正则化系数和物理正则化系数; R 为神经网络下正则化函数项; w 为神经网络下输入变量至输出变量权重; b 为偏移误差; R_z 为物理正则化函数项; x 为输入值。

物理正则化函数项是区分 PINN 和普通神经网络的关键, 其具有以下优点: 1) 在具有非线性、不确定性为特征的新型电力系统工况下, 物理正则化项的融合可以鼓励神经网络产生符合物理规律的解; 2) 神经网络由于其“黑箱”特点不具有可解释性, 因此借助物理正则化项可以帮助运维人员更好地解释神经网络的输出项; 3) 由于电力系统日常获取到的数据往往是正常样本数据, 关键的异常状态数据样本稀少, 嵌入物理正则化项可以显著压缩网络参数搜索空间, 减少对训练样本数量需求。

1.2 基于物理信息的 LSTM 网络模型

由于传统的深度神经网络算法与模型无关, 因此有许多的冗余连接, 并且一些参数阻碍了其输出层的性能。而基于物理信息的神经网络模型包含了知识-数据联合驱动的设计架构, 因此本文对传统的 LSTM 模型结构进行了改进, 提出了一种基于物理先验的 LSTM 模型, 将变压器多物理场耦合下的能量流物理模型嵌入至传统的 LSTM 递归过程模型中。

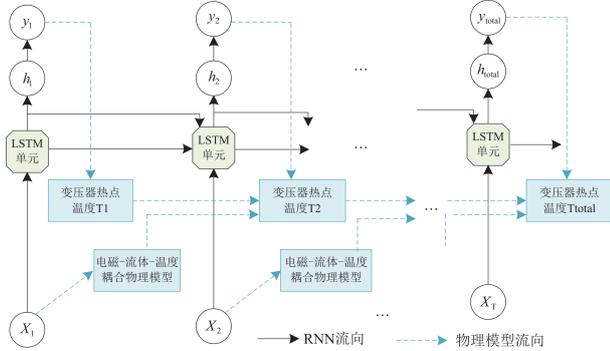


图2 基于物理先验的 LSTM 模型架构

Fig. 2 Model architecture based on physical-informed LSTM network

随着深度学习技术的发展, 传统的 LSTM 模型可从多变量输入的时序数据中自动提取具有代表性的数据, 从而更好地对目标变量进行预测。循环神经网络(recurrent neural network, RNN)模型作为近期热门的时序深度学习模型, 其在多个领域得到应用。RNN 模型通过在当前和以前的时间节点下结合输入数据来提取隐藏层的信息 h_t , 其表达式为

$$h_t = \tanh(W_h \cdot h_{t-1} + W_x \cdot x_t) \quad (2)$$

式中: h_{t-1} 为隐藏层在 $t-1$ 时刻的信息; W_h 、 W_x 分别为 h_{t-1} 和 x_t 权重矩阵; x_t 为 t 时刻输入信息。

尽管 RNN 模型可以跨时间序列, 但在长时间序列跨度下存在梯度消散的问题, 为解决该问题, 本文提出了 LSTM 模型, 通过在隐藏层中定义一个转换单元, 使每个 LSTM 单元中包含单元状态 c_t , 其具备记忆功能迫使隐藏层变量 h_t 可以保留过去的信息。因此在 LSTM 模式下新的单元状态 c_t 的表达式为

$$c_t = \tanh(W_h^c \cdot h_{t-1} + W_x^c \cdot x_t) \quad (3)$$

式中: W_h^c 、 W_x^c 分别为 LSTM 模式下连接至 h_{t-1} 和 x_t 的权重矩阵。

LSTM 模型中通过 Sigmoid 激活函数产生一个遗忘门 f_t 、输入门 g_t 和输出门 o_t , 表达式分别为

$$f_t = \tanh(W_h^f \cdot h_{t-1} + W_x^f \cdot x_t) \quad (4)$$

$$g_t = \tanh(W_h^g \cdot h_{t-1} + W_x^g \cdot x_t) \quad (5)$$

$$o_t = \tanh(W_h^o \cdot h_{t-1} + W_x^o \cdot x_t) \quad (6)$$

式中: W_h^f 、 W_x^f 、 W_h^g 和 W_x^g 、 W_h^o 、 W_x^o 分别为遗忘门 f_t 、输入门 g_t 和输出门 o_t 连接至 h_{t-1} 和 x_t 的权重矩阵。

新的单元状态和隐藏层信息的表达式分别为

$$c_t = f_t \otimes c_{t-1} + g_t \otimes \tilde{c}_t \quad (7)$$

$$h_t = o_t \otimes \tanh(c_t) \quad (8)$$

式中: \tilde{c}_t 表示归一化之后 t 时刻输入的单元状态; “ \otimes ”表示乘积运算。

2 物理信息神经网络的电力变压器状态评估

2.1 多物理场耦合下变压器热点温度模型

电力变压器中绝缘问题是影响其运行状态优劣的关键。变压器油流的物理规律主要受到质量守恒定律、动量守恒定律和能量守恒定律三大定律的影响, 其表达式为

$$\begin{cases} \nabla \cdot \rho_T \omega = 0 \\ \rho_T \cdot \nabla \cdot \omega = F - \nabla \cdot \rho_T + U \nabla^2 \cdot \omega \\ \rho_T c \omega \cdot \nabla \cdot T = \nabla \cdot (k \cdot \nabla \cdot T) + P_b \end{cases} \quad (9)$$

式中: “ ∇ ”为梯度运算符号; ρ_T 为变压器油密度; ω 为变压器油流速; F 为变压器外部体积力; p 为变压器压力; U 为变压器油流动黏度; c 为变压器比热容; T 为变压器油温; k 为热导率; P_b 为变压器损耗。

在多物理场耦合下求解变压器内部热点温度分布时, 先对变压器电磁场模型分析求解铁芯及绕组

损耗,在此基础上,通过求解流体-温度场模型获取变压器内部温度分布,根据绕组温度对绕组损耗加以修正,进行迭代计算重新求解变压器流体-温度场。因此,电磁场数值计算是解决耦合模型的基础,基于磁矢量 \mathbf{B} 的磁场控制方程为

$$\mathbf{B} = \nabla \times \mathbf{A} \quad (10)$$

式中: \mathbf{A} 为矢量磁位。

变压器的损耗 P_w 主要由磁滞损耗 P_c 、涡流损耗 P_w 及额外损耗 P_f 相加组成,其表达式分别为

$$\begin{cases} P_c = C_1 \cdot \mathbf{B}^2 \cdot f \cdot V \\ P_w = C_2 \cdot \frac{\mathbf{B}^2 \cdot f^2 \cdot d^2}{\rho_D} \\ P_f = C_3 \cdot \frac{\mathbf{B}^2 \cdot v^2 \cdot t}{\rho_D} \end{cases} \quad (11)$$

式中: C_1 为硅钢片材料特性系数,其与铁芯导磁率和密度有关; f 为频率; V 为铁芯体积; C_2 为硅钢片材料性质厚度系数; d 为硅钢片厚度; ρ_D 为电阻率; C_3 为硅钢片材料属性常数; v 为磁化时硅钢片内磁壁的移动速度。

其次,对变压器的散热物理规律进行建模。变压器的散热主要通过与外部空气进行对流换热及辐射散热,其散热的控制方程 $T_{out}(t)$ 为

$$\begin{cases} T_{out}(t) = h_D S (T_s - T_f) \\ h_D = \frac{N_u}{\delta} \end{cases} \quad (12)$$

式中: h_D 为变压器的对流换热系数; S 为变压器的油箱散热表面积; T_s 为油箱表面温度; T_f 为空气温度; δ 为特征系数; N_u 为努谢尔系数。

参考文献[19]基于有限元法对变压器电磁-流体-温度多物理场景耦合下的热点温度进行建模,变压器绕组随温度变化的关系 $T_{in}(t)$ 为

$$T_{in}(t) = P(t-1)\{1 + \alpha[T(t) - T(t-1)]\} \quad (13)$$

式中: $P(t-1)$ 为 $t-1$ 时刻的绕组损耗; α 为铜导体导线的温度系数; $T(t)$ 为 t 时刻的绕组温度。

在电磁-流体-温度耦合下变压器遵循温度流体的物理规律,其控制方程为

$$\frac{\partial(\rho_D u \phi)}{\partial x_1} + \frac{\partial(\rho_D v \phi)}{\partial y_1} = \frac{\partial}{\partial x_1} (T_L \frac{\partial \phi}{\partial x_1}) + \frac{\partial}{\partial y_1} (T_L \frac{\partial \phi}{\partial y_1}) + S \quad (14)$$

式中: x_1 、 y_1 分别表示油流方向; T_L 为多物理场耦合作用下变压器温度流; ϕ 为广义扩散系数; S 为广义源。

考虑绕组与油之间的热量交换属于固体与流体

之间传热^[20],引入温度连续性条件、热流密度连续性条件,并添加第一类和第三类边界条件,其表达式为

$$\begin{cases} T_L|_{\Gamma_1} = T_b \\ \lambda_b \frac{\partial T_L}{\partial n}|_{\Gamma_3} = k(T_f - T_L) \\ T_L|_{S_a} = T_L|_{S_b} \\ \lambda_a \frac{\partial T_L}{\partial n}|_{S_{ab}} = \lambda_b \frac{\partial T_L}{\partial n}|_{S_{ba}} \end{cases} \quad (15)$$

上述 4 个式子中,第 1 个式子为第一类边界条件,即给定边界 Γ_1 下温度值为 T_b ; 第 2 个式子为第三类边界条件, k 为边界 Γ_3 上温度的梯度值与边界流体温度关系, λ_b 为流体的对流换热系数; 第 3 个式子为温度连续条件, S_a 和 S_b 分别为固体与流体分界面; 第 4 个式子为热流密度连续性条件, λ_a 为流体的热流系数; S_{ab} 表示热量沿分界面法线的方向由 a 传至 b ; n 为边界外法线方向。

2.2 电力变压器状态评估

电力变压器是电力系统中较为重要、关键的设备。然而,在实际运维过程中由于故障样本稀缺,设备大部分情况处于健康或亚健康状态,此时采用传统的机器学习算法对电力变压器进行健康管理评估往往出现故障状态预测不够精确的问题。目前对电力变压器的健康评估往采用溶解气体分析策略,当变压器发生故障时,往往会产生 CO_2 、 CH_4 、 C_2H_6 、 CO 、 H_2 、 O_2 、 N_2 等气体,通过采集这些气体并进行溶解气体分析,来诊断变压器故障、评估变压器健康状态。健康指数是将获得的变压器不同特征状态数据值进行综合比较的量化指标,用来综合评估导致绝缘性能长期退化和寿命终止的各类关联因素^[21]。

本文使用 DGA 数据评估变压器的综合健康状况,对变压器健康评估影响函数 F 的表达式为

$$F = \frac{\sum_{i=1}^7 S_i \times W_i}{\sum_{i=1}^7 W_i} \quad (16)$$

式中: i 分别为 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2 、 CO_2 和 CO 这 7 种溶解气体序号; S_i 为溶解气体的体积含量系数; W_i 为溶解气体的权重系数。

设定电力变压器的运行状态所对应的状态集为 $s = \{s_1, s_2, s_3, s_4\}$, s_1 、 s_2 、 s_3 、 s_4 分别代表变压器正常、一般缺陷、严重缺陷和危机状态。根据文献[2]所提的模糊综合评判法对电力变压器运行工况、检修记录、运行时间、隶属度评估以预测其运行状态。油中溶解气体相对劣化度 r 对应状态集合 S ,

其隶属度函数 $\phi(r) = \{\phi_{s_1}, \phi_{s_2}, \phi_{s_3}, \phi_{s_4}\}$ 。

$$\phi_{s_1}(r) = \begin{cases} 1 & r < 0.218 \\ -5.155r + 2.124 & 0.218 \leq r \leq 0.412 \\ 0 & r > 0.412 \end{cases} \quad (17)$$

$$\phi_{s_2}(r) = \begin{cases} 5.155r - 1.124 & 0.218 < r \leq 0.412 \\ -0.515 + 3.124 & 0.412 < r \leq 0.606 \\ 0 & r > 0.606 \end{cases} \quad (18)$$

$$\phi_{s_3}(r) = \begin{cases} 5.155r - 2.124 & 0.412 < r \leq 0.606 \\ -5.155r + 4.124 & 0.606 < r \leq 0.8 \\ 0 & r > 0.8 \end{cases} \quad (19)$$

$$\phi_{s_4}(r) = \begin{cases} 0 & r < 0.606 \\ 5.155r - 3.124 & 0.606 \leq r \leq 0.8 \\ 1 & r > 0.8 \end{cases} \quad (20)$$

2.3 基于物理信息 LSTM 的变压器状态评估

本文将在变压器状态监测中获得的 H_2 、 CH_4 、 C_2H_6 、 C_2H_4 、 C_2H_2 、 CO_2 、 CO 这 7 种气体的 DGA 数据以及运行工况、检修记录、运行时间的隶属度作为输入, 将下一时刻的变压器状态信度区间作为输出。运用图 2 设计的物理先验改进 LSTM 模型进行时序联系, 通过 Softmax 分类器进行电力变压器的状态预测及评估。需要注意的是, 定义新的物理正则化函数项 R_z 是区别于传统神经网络损失函数的关键, 其可以根据实际工况中所要解决的问题而自适应定义。结合上述变压器电磁-流体-温度多物理场耦合模型, 物理正则化函数项 R_z 表达式为

$$R_z = \frac{1}{T_i} \sum_{t \in T_i} \text{ReLU}(|T(t) - (T_{in}(t) - T_{out}(t))| - \tau) \quad (21)$$

式中: T_i 为变压器顶层油温数据集; τ 为热点温度变化的阈值; $T_{in}(t)$ 为变压器绕组温度; $T_{out}(t)$ 为变压器散热温度; $T(t)$ 为多物理场耦合条件下求得的绕组温度。

考虑到实际运维过程中会产生观测误差或者其他未知因素的影响, 因此只有当温差变化大于设定阈值 τ 时才会启动 ReLU 函数。

结合上述分析, 本文提出基于物理信息 LSTM 模型变压器状态评估框架, 如图 3 所示, 具体实现步骤如下所述。

本文选用的变压器 DGA 数据来源于文献[22], 采集 868 个 DGA 数据作为变压器油的样本。其中 80%用于训练, 20%用于测试。

1) 初始值设定。鉴于深度神经网络算法具有很强的非线性和非凸特性, 这对初始值的选取提出了

更高的要求。在知识驱动下初始值选取的好坏直接影响了算法的收敛特性, 好的初始值设定可以帮助算法快速收敛并且避免陷入局部最优。因此, 本文首先利用知识经验模型模拟生成数据集进行训练获取权重矩阵, 然后将其转移到预测任务中, 并用实际工况中的真实数据对训练结果进行微调, 从而获取更好的初始设定值。

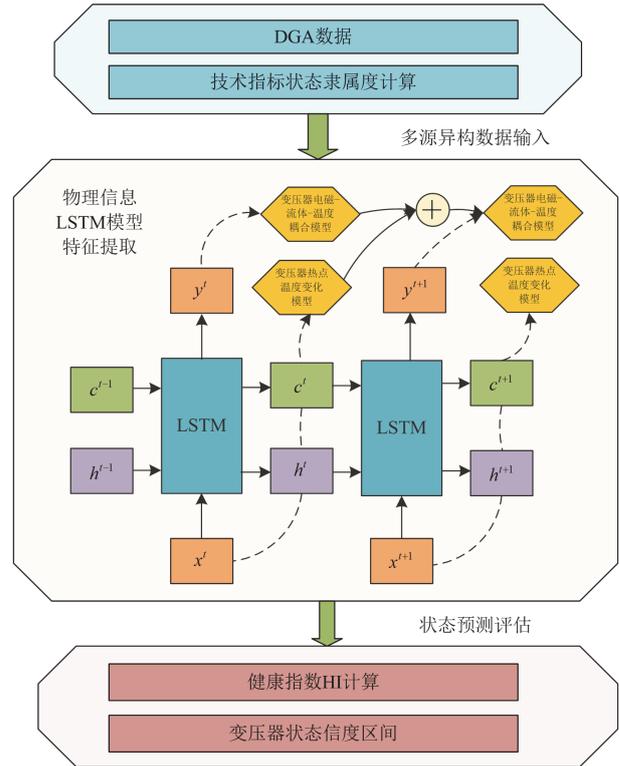


图3 基于物理信息 LSTM 模型变压器状态评估框架
Fig. 3 Transformer state assessment framework based on physical-informed LSTM model

2) 数据归一化处理。由于在实际运维过程中获取的数据来源多源异构, 且往往存在数据样本不全的问题, 因此本文先对 DGA 数据、运行工况、检修记录等输入参数采用离差标准化处理, 基于三比值法的 DGA 和隶属度函数组合得到电力变压器不同状态的分布函数。

3) 基于物理信息 LSTM 模型的特征提取。利用本文提出的改进 LSTM 模型进行电力变压器的状态预测, 利用知识-数据联合驱动架构的优势, 运用多物理场耦合温度模型对损失函数进行新定义以此提高算法计算性能, 实现在数据样本不全、物理机理不完全明确的工况下实现特征提取和分类器建模。

4) 电力变压器状态预测评估。通过 Softmax 分类层, 对电力变压器多源状态数据与关键性能的相关

性进行分析, 获取变压器在全寿命周期的多物理场耦合工况下健康管理和寿命预测模型, 实现多物理场耦合下电力变压器的实时状态预测和健康评估。

3 仿真验证

本文输入数据来源多源异构, 包含文献[11]的 DGA 数据以及实际工作中的运行、检修记录。其中从电力变压器采集到的油样本数量为 868 个: 其中 463 个数据来自文献[19], 244 个数据来自文献[21], 117 个数据来自文献[22]及 IEC10 的数据库。共计 360 个来自不同地区的电力变压器样本数据, 变压器油样品是从位于不同位置、不同年龄和规格的电力变压器中提取的, 这可以更好地验证本文所提物理信息神经网络模型在面对不同工况、数据样本下的鲁棒性和泛化性。

3.1 电力变压器状态关联度分析

通过对 DGA 中各特征变量进行分析, 显示变压器各状态参量特征之间的关联度热力图, 如图 4 所示。图 4 中每个方块的颜色表征其对应的 DGA 气体和对应的某相关特征参量的相关性分数, 其中每行所有相关性分数之和为 1, 颜色越浅表征该列对应的特征量与变压器的相关状态关联性越强。通过观察图 4 中临界电压、含水量、H₂ 间的相关性, 对电力变压器在油降解的过程中临界电压和含水量与 H₂ 的关联分析, 从图 4 中可知当含水量增加时, 电力变压器的健康指数与其功率因数和 C₂H₆ 气体的产生具有强相关性, 通过分类器观察可知: 电力变压器的临界电压取决于其含水量, 健康指数取决于其油降解过程中产生的 C₂H₆、CO₂ 和 C₂H₄。

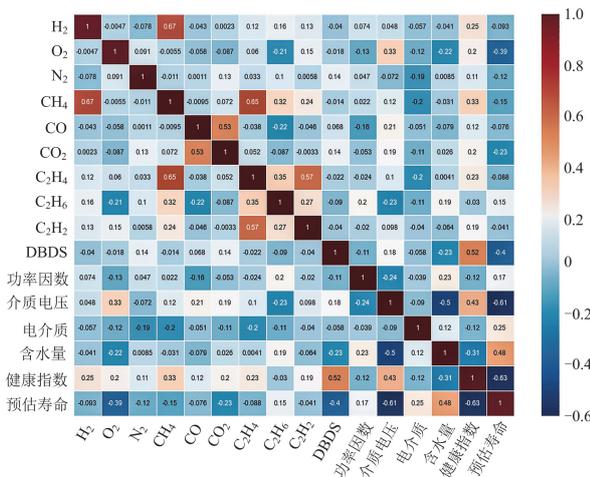


图 4 变压器各状态参量间关联度热力图

Fig. 4 Thermal map of correlation degree among various state parameters of transformer

3.2 电力变压器状态评估

通过基于物理信息 LSTM 模型挖掘变压器各状态参量间的特征值簇群如图 5 所示。由图 5 可知, H₂、临界电压与健康指数、变压器寿命具有强相关性, 相关系数为 0.6772。其中, H₂ 和临界电压与变压器的健康指数相关系数为 0.9643, 但是和变压器预期剩余寿命的相关系数为 0.8022, 而 CO、C₂H₂ 对于变压器的健康指数和剩余寿命具有强相关性, 相关系数为 0.9641。通过对各 DGA 组成气体、油色谱气体的状态参量相关性进行挖掘, 计算得到电力变压器的健康指数如图 6 所示, 其中健康指数由挖掘到各变压器状态参量相关性的权重线性组合评分得出。

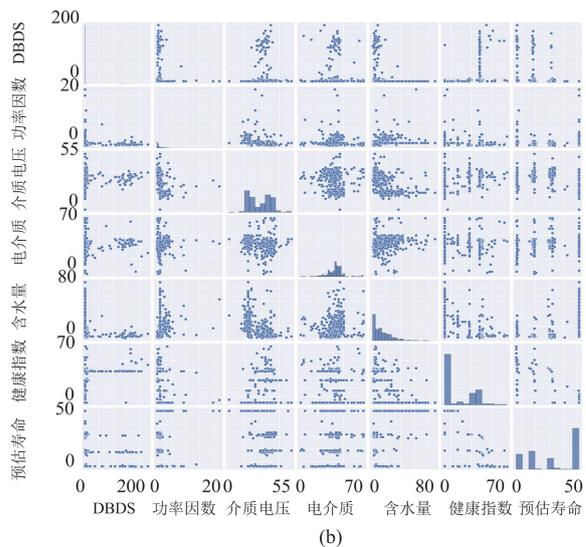
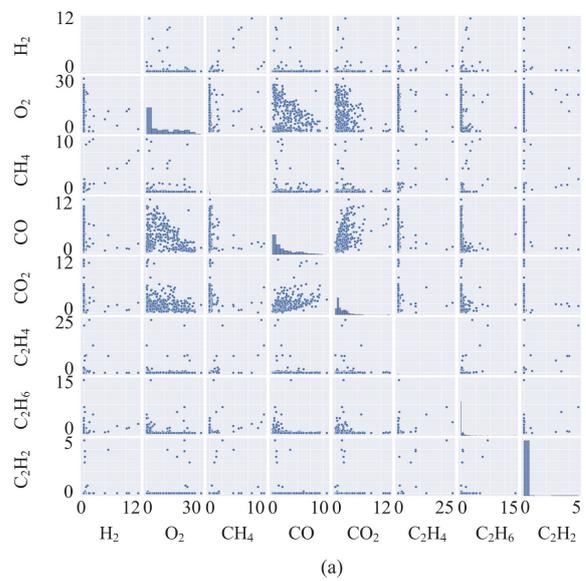


图 5 电力变压器各特征值簇群分析

Fig. 5 Clustering analysis of power transformer characteristic values

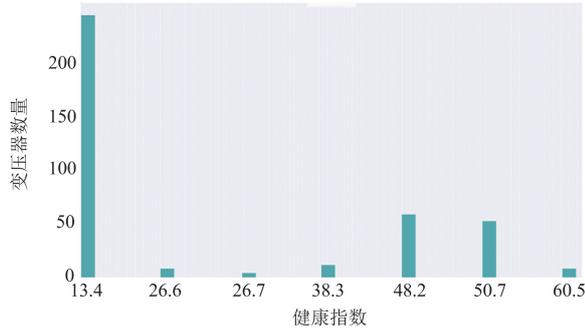
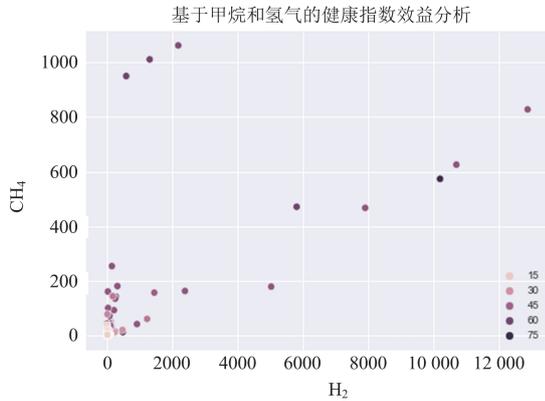


图6 电力变压器健康指数

Fig. 6 Power transformer health index

鉴于图5分析结果可知电力变压器的健康指数与DGA中 CH_4 和 H_2 的含量特征具有强关联性,对电力变压器的健康指数与 CH_4 和 H_2 的关联效益进行分析,仿真结果如图7所示。

图7 基于 CH_4 和 H_2 的变压器健康指数效益分析Fig. 7 Health index benefit analysis based on CH_4 and H_2

结合图5电力变压器各特征值簇聚类仿真结果和图6电力变压器健康指数分析,可以对电力变压器的使用寿命进行评估预测^[23],最终结果如图8所示,评估结果如下所述。

当 $\text{Health_index} < 13.4$ 时:

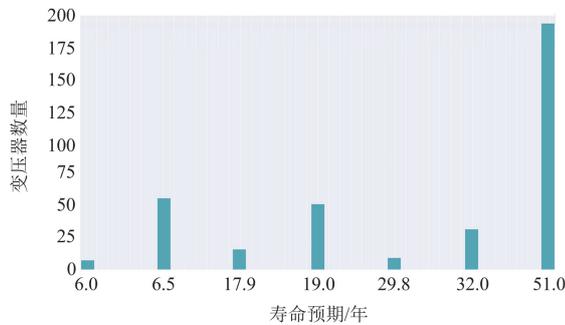


图8 电力变压器寿命预期

Fig. 8 Power transformer life expectation

$$\text{Life_expectation} = -0.0008 \cdot \text{O}_2 - 0.0025 \cdot \text{CO} - 0.0031 \cdot \text{CO}_2 + 0.0013 \cdot \text{C}_2\text{H}_6 - 0.1433 \cdot \text{Health_index} + 14.4$$

当 $13.4 \leq \text{Health_index} < 26.7$ 时:

$$\text{Life_expectation} = 0.0021 \cdot \text{CO} + 0.0011 \cdot \text{C}_2\text{H}_4 - 0.0233 \cdot \text{CH}_4 - 0.32 \cdot \text{H}_2 + 0.0019 \cdot \text{C}_2\text{H}_6 + 0.223 \cdot \text{Health_index} + 24.4$$

当 $26.7 \leq \text{Health_index} < 38.3$ 时:

$$\text{Life_expectation} = 0.0028 \cdot \text{CO} + 0.0017 \cdot \text{C}_2\text{H}_4 - 0.0129 \cdot \text{CH}_4 - 0.11 \cdot \text{H}_2 + 0.0012 \cdot \text{C}_2\text{H}_6 - 0.1157 \cdot \text{Health_index} + 34.9$$

当 $38.3 \leq \text{Health_index} < 48.2$ 时:

$$\text{Life_expectation} = -0.0011 \cdot \text{O}_2 - 0.0028 \cdot \text{C}_2\text{H}_4 - 0.0034 \cdot \text{CH}_4 + 0.0037 \cdot \text{C}_2\text{H}_6 - 0.1433 \cdot \text{Health_index} + 54.4$$

3.3 实测对比分析

为了更好地体现本文所提 PINN 求解器相较于传统的采用 CFD 数值计算方法对多物理场耦合下变压器热点估计的优越性,参考文献[24]中电力变压器温度物理特性和热点测算,将仿真结果和实测结果结合起来对比分析,并与现有的算法进行对比分析。采用相对误差指数来比较热点温度预测值和实际值,其计算表达式为

$$E_{\text{ess}} = \left| \frac{K_i - V_i}{V_i} \right| \times 100\% \quad (22)$$

式中: E_{ess} 为相对误差函数; K_i 为模拟计算值; V_i 为实际计算值。

仿真结果和采用传统数值方法求解、采用 PINN 求解器求解的对比如表1所示。

表1 所提 PINN 求解器法和传统数值方法实测对比分析

Table 1 Actual measurement comparison of proposed PINN solver algorithm and traditional method

温升	实测/ $^{\circ}\text{C}$	传统数值方法/ $^{\circ}\text{C}$	PINN 求解器法/ $^{\circ}\text{C}$	相对误差/%
平均温升	45.4	46	45.8	0.88
低压绕组温升	53.4	54.8	54.1	1.3
高压绕组温升	57.2	58.7	58.3	1.9

由表1可知,通过比较文献[19]中实测结果、传统的 CFD 数值计算方法及本文所提的 PINN 求解器方法,结果表明,通过 PINN 求解器对多物理场耦合下电力变压器的热点温度评估的相对误差小于2%,符合工程实际应用需求,相较于传统 CFD 数值计算方法具有更高的热点评估精准性。因此,采

用 PINN 方法可以实现电力变压器的热点温度实时辨识与精准预测,在新型电力系统背景下,为提高变压器热点状态量监测精度和评估计算结果的准确性提供了新的解决方案。

图 9 对本文所提算法预测的电力变压器健康指数和实际值进行比较,在数据样本不全、物理机理不明确的工况下,所提算法仍然具有良好的预测效果,在新型电力系统背景下基于物理信息的神经网络模型具有良好的鲁棒性和泛化性。

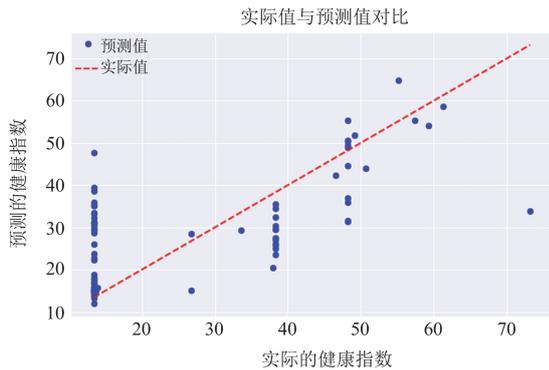


图 9 电力变压器健康指数实际值与预测值比较

Fig. 9 Comparison of actual and predicted health index of power transformer

4 总结

针对新型电力系统背景下电力变压器运行状态呈现多物理场耦合复杂工况,导致传统的评估模型无法有效挖掘变压器绝缘老化机理,且多源异构数据无法完美融合和有效利用问题,本文提出了基于物理信息 LSTM 网络的电力变压器状态评估方法,通过模型-数据联合驱动架构修正传统的状态评估模型,结论如下所述。

1) 物理信息 LSTM 网络模型可以有效地融合模型驱动和数据驱动的思想,通过在原有的损失函数中引入电力变压器电磁-流体-温度多物理场耦合的物理先验模型,约束了违反物理先验的不确定性数据,增强其 Softmax 分类器的可解释性和泛化性,有效地挖掘多物理场耦合复杂工况下电力变压器的演化规律。

2) 物理先验的神经网络技术可以很好地求解新型电力系统背景下电力变压器的多物理场耦合模型,对多源异构数据进行完美融合和有效利用,实现了电力变压器热点温度状态监测及精准评估。

参考文献

[1] 江涛,杨传凯,王荆,等.基于健康指数的电力变压器绝缘状态评估方法研究[J].高压电器,2024,60(5):

124-129.
 JIANG Tao, YANG Chuankai, WANG Jing, et al. Research on insulation state assessment method of power transformer based on health index[J]. High Voltage Apparatus, 2024, 60(5): 124-129.
 [2] 谢庆,齐晨晨,肖朝轩,等.基于可拓云模型与综合赋权的油纸绝缘阀侧套管状态评估[J].高压电器,2023,59(7): 136-144.
 XIE Qing, QI Chenchen, XIAO Chaoxuan, et al. Condition assessment of valve side bushing of oil-paper insulation based on extension cloud model and comprehensive weighting[J]. High Voltage Apparatus, 2023, 59(7): 136-144.
 [3] 王文森,贺馨仪,杨晓西,等.基于多参数数据回归分析的电力变压器状态监测方法[J].电网与清洁能源,2023,39(4): 83-90.
 WANG Wensen, HE Xinyi, YANG Xiaoxi, et al. Power transformer condition monitoring method based on multivariate statistical analysis[J]. Power System and Clean Energy, 2023, 39(4): 83-90.
 [4] AHSAN F, DANA N H, SARKER S K, et al. Data-driven next-generation smart grid towards sustainable energy evolution: techniques and technology review[J]. Protection and Control of Modern Power Systems, 2023, 8(3): 1-42.
 [5] 周家玉,侯慧娟,盛戈皞,等.状态参量关联规则挖掘及深度学习融合的变压器故障诊断算法[J].高压电器,2023,59(3): 108-115.
 ZHOU Jiayu, HOU Huijuan, SHENG Gehao, et al. Transformer fault diagnosis algorithm based on association rules mining of state parameters and deep learning[J]. High Voltage Apparatus, 2023, 59(3): 108-115.
 [6] 李刚,孟坤,贺帅,等.考虑特征耦合的Bi-LSTM变压器故障诊断方法[J].中国电力,2023,56(3): 100-108, 117.
 LI Gang, MENG Kun, HE Shuai, et al. A Bi-LSTM-based transformer fault diagnosis method considering feature coupling[J]. Electric Power, 2023, 56(3): 100-108, 117.
 [7] 王艳,李伟,赵洪山,等.基于油中溶解气体分析的DBN-SSAELM变压器故障诊断方法[J].电力系统保护与控制,2023,51(4): 32-42.
 WANG Yan, LI Wei, ZHAO Hongshan, et al. Transformer DGA fault diagnosis method based on DBN-SSAELM[J]. Power System Protection and Control, 2023, 51(4): 32-42.
 [8] 邹阳,林锦茹,李安娜,等.基于灰色关联分析和聚类云模型的变压器油纸绝缘状态评估[J].电力系统保护与控制,2023,51(21): 35-43.
 ZHOU Yang, LIN Jinqie, LI Anna, et al. Evaluation of transformer oil-paper insulation status based on grey relational analysis and a cluster cloud model[J]. Power System Protection and Control, 2023, 51(21): 35-43.
 [9] 郑含博,敬佳兴,罗晓庆,等.基于多源融合的油纸绝缘套管缺陷辨识及绝缘状态评估[J].电力系统保护与控制,2023,51(20): 119-128.
 ZHENG Hanbo, JING Jiaying, LUO Xiaoqing, et al.

- Defect identification and insulation condition assessment of an oil-immersed paper insulation bushing based on multi-source fusion[J]. *Power System Protection and Control*, 2023, 51(20): 119-128.
- [10] 张鸿儒. 基于数据信息挖掘的电力变压器故障诊断及健康评估[D]. 济南: 山东大学, 2023.
ZHANG Hongru. Fault diagnosis and health assessment of power transformers based on data information mining[D]. Jinan: Shandong University, 2023.
- [11] 代杰杰, 宋辉, 盛戈皞, 等. 考虑复杂关联关系深度挖掘的变压器状态参量预测方法[J]. *中国电机工程学报*, 2019, 39(2): 621-628.
DAI Jiejie, SONG Hui, SHENG Gehao, et al. A prediction method for power transformers state parameters based on deep association relation mining[J]. *Proceedings of the CSEE*, 2019, 39(2): 621-628.
- [12] ZHANG H, SUN H, KANG L, et al. Prediction of health level of multiform lithium sulfur batteries based on incremental capacity analysis and an improved LSTM[J]. *Protection and Control of Modern Power Systems*, 2024, 9(2): 21-31.
- [13] 郭方洪, 刘师硕, 吴详, 等. 基于联邦学习的含不平衡样本数据电力变压器故障诊断[J]. *电力系统自动化* 2023, 47(10): 142-152.
GUO Fanghong, LIU Shishuo, WU Xiang, et al. Federated learning based fault diagnosis of power transformer with unbalanced sample data[J]. *Automation of Electric Power Systems*, 2023, 47(10): 142-152.
- [14] 蒲天骄, 乔骥, 韩笑, 等. 人工智能技术在电力设备运维检修中的研究及应用[J]. *高电压技术*, 2020, 46(2): 369-383.
PU Tianjiao, QIAO Ji, HAN Xiao, et al. Research and application of artificial intelligence in operation and maintenance for power equipment[J]. *High Voltage Engineering*, 2020, 46(2): 369-383.
- [15] 尚宇炜, 马钊, 彭晨阳, 等. 内嵌专业知识和经验的机器学习方法探索(二): 引导学习的应用与实践[J]. *中国电机工程学报*, 2017, 37(20): 5852-5861.
SHANG Yuwei, MA Zhao, PENG Chenyang, et al. Study of a novel machine learning method embedding expertise (part II): applications and practices of guiding learning[J]. *Proceedings of the CSEE*, 2017, 37(20): 5852-5861.
- [16] 李峰, 王琦, 胡健雄, 等. 数据与知识联合驱动方法研究进展及其在电力系统中应用展望[J]. *中国电机工程学报*, 2021, 41(13): 4377-4390.
LI Feng, WANG Qi, HU Jianxiong, et al. Combined data-driven and knowledge-driven methodology research advances and its applied prospect in power systems[J]. *Proceedings of the CSEE*, 2021, 41(13): 4377-4390.
- [17] 边晓燕, 孙明琦, 赵健, 等. 基于一致性算法的源-荷协同分布式优化调控策略[J]. *中国电机工程学报*, 2021, 41(4): 1334-1347.
BIAN Xiaoyan, SUN Mingqi, ZHAO Jian, et al. Distributed coordinative optimal dispatch and control of source and load based on consensus algorithm[J]. *Proceedings of the CSEE*, 2021, 41(4): 1334-1347.
- [18] HUANG B, WANG J. Applications of physics-informed neural networks in power systems-a review[J]. *IEEE Transactions on Power Systems*, 2023, 38(1): 572-588.
- [19] 廖才波, 阮江军, 刘超, 等. 油浸式变压器三维电磁-流体-温度场耦合分析方法[J]. *电力自动化设备*, 2015, 35(9): 150-155.
LIAO Caibo, RUAN Jiangjun, LIU Chao, et al. Comprehensive analysis of 3-D electromagnetic-fluid thermal fields of oil-immersed transformer[J]. *Electric Power Automation Equipment*, 2015, 35(9): 150-155.
- [20] 张宇娇, 孙宏达, 赵志涛, 等. 基于物理信息神经网络的电磁场计算方法[J]. *电工技术学报*, 2024, 39(17): 5251-5261.
ZHANG Yujiao, SUN Hongda, ZHAO Zhitao, et al. Electromagnetic field calculation method based on physical informed neural network[J]. *Transactions of China Electrotechnical Society*, 2024, 39(17): 5251-5261.
- [21] VELÁSQUEZ R M A, LARA J V M. Root cause analysis improved with machine learning for failure analysis in power transformers[J]. *Engineering Failure Analysis*, 2020, 115(6).
- [22] DUVAL M, DEPABLA 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.
- [23] 王吉祥, 郝建, 许晶, 等. 油浸式变压器绕组热点动态温升演化规律及推演计算模型研究[J]. *高电压技术*, 2024, 1(1): 1-13.
WANG Jixiang, HAO Jian, XU Jing, et al. Study on the evolution law of hot spot dynamic temperature rise of oil-immersed transformer windings and deduction calculation model[J]. *High Voltage Engineering*, 2024, 1(1): 1-13.
- [24] 许萌超. 油浸式变压器数字孪生多物理场耦合建模与仿真平台开发[D]. 吉林: 东北电力大学, 2024.
XU Mengchao. Development of digital twin multiphysics field coupling modeling and simulation platform for oil-immersed transformers[D]. Jilin: Northeast Electric Power University, 2024.

收稿日期: 2024-05-02; 修回日期: 2024-11-07

作者简介:

林苑(1997—), 女, 通信作者, 硕士, 助理工程师, 研究方向为人工智能算法在电力系统中的应用。E-mail: schroambition@163.com

(编辑 张颖)