

DOI:10.13296/j.1001-1609.hva.2026.09.018

面向换流变压器故障溯源的可解释知识图谱推理方法

吴婉豪, 王家文, 张永浩, 武宏斌, 李清泉, 任富强

(山东大学特高压输变电技术与装备山东省重点实验室, 济南 250061)

摘要: 换流变压器是高压直流输电系统的关键设备,其故障演化过程具有非线性和强耦合特征。针对运维文本数据利用不足和诊断过程缺乏可解释性的问题,提出一种可解释知识图谱推理方法(IKGR)。首先,采用 ALBERT-BiLSTM-CRF 从检修记录和故障报告等非结构化文本中抽取实体,并依据图谱模式层和物理因果约束组织关系三元组,构建换流变压器故障溯源知识图谱。其次,设计双智能体强化学习推理模型,引入软奖励机制,并利用短期同策略轨迹缓冲区同步更新双智能体参数,实现多跳故障溯源。实验结果表明,IKGR 的根因排序指标 $Hits@10$ 达到 94.8%,并可生成包含设备部件、故障状态、保护动作和试验方法的推理路径,为换流变压器故障处置和运维决策提供路径级解释。

关键词: 换流变压器; 故障溯源; 知识图谱; 双智能体强化学习; 可解释人工智能

Interpretable Knowledge Graph Reasoning Method for Fault Traceability in Converter Transformer

WU Wanhao, WANG Jiawen, ZHANG Yonghao, WU Hongbin, LI Qingquan, REN Fuqiang

(Shandong Provincial Key Laboratory of UHV Transmission Technology and Equipment, Shandong University, Jinan 250061, China)

Abstract: Converter transformer is a critical component of high-voltage direct-current (HVDC) transmission systems, and its fault evolution exhibits nonlinear and strongly coupled characteristics. To address the problems of underutilized operation and maintenance text data and the lack of interpretability in the diagnostic process, an interpretable knowledge graph reasoning method (IKGR) is proposed. First, an ALBERT-BiLSTM-CRF model is adopted to extract entities from such unstructured text as maintenance records and fault reports. The relational triples are organized in accordance with the schema layer of the knowledge graph and physical causal constraints, thereby constructing a converter transformer fault traceability knowledge graph. Then, a dual-agent reinforcement learning reasoning model is designed, in which a soft reward mechanism is introduced and a short-term on-policy trajectory buffer is utilized to synchronously update the parameters of the dual agents, thereby achieving multi-hop fault traceability. Experimental results show that IKGR achieves 94.8% in terms of the root cause ranking metric $Hits@10$, and is capable of generating reasoning paths comprising equipment components, fault status, protective actions and testing methods, thereby providing path-level explanations for converter transformer fault handling and O & M decision-making.

Key words: converter transformer; fault traceability; knowledge graph; dual-agent reinforcement learning; interpretable artificial intelligence

0 引言

换流变压器是高压直流输电系统的关键设备,

长期承受着交直流叠加等复杂工况,其内部绝缘老化和故障演化过程具有非线性和强耦合特征^[1-4]。换流站检修记录、故障报告等运维文本包含异常现

收稿日期:2026-04-02; 修回日期:2026-06-28

基金项目:国家自然科学基金项目(52307180);山东省重大基础研究项目(ZR2024ZD29)。

Project Supported by National Natural Science Foundation of China(52307180), Major Fundamental Research Project of Shandong Province(ZR2024ZD29).

象、故障部位与处置措施等关联信息。将这些信息组织为可查询、可追溯的故障链路,可为复杂故障的根因定位和处置决策提供依据。

现有故障诊断方法通常将状态数据与人工智能算法相结合,通过非线性映射实现故障预测或分类。在换流变压器状态预测与故障诊断方面,Patil^[5]利用气体体积分数数据开展故障预测,Li^[6]基于声学特征进行故障诊断;孙长海^[7]和汤健^[8]分别研究了局部放电阶段识别和不平衡样本故障分类。上述研究主要利用数值型数据或故障样本开展预测与分类,未充分利用运维文本数据中蕴含的丰富信息,且诊断过程缺乏可解释性。

为利用非结构化运维文本,知识图谱(knowledge graph, KG)已用于电力系统中复杂数据的组织与关联。Tang^[9]将知识图谱用于电力设备管理;Tang^[10]提出基于电力知识图谱的智能问答系统,用于识别用户意图;Li^[11]利用知识图谱进行电力系统故障诊断与分类。然而,现有知识抽取模型在专业术语密集、逻辑关联复杂的运维文本中,难以兼顾模型规模与语义表征能力^[12]。

为提高诊断过程的可解释性,可将电力设备故障溯源建模为知识图谱推理(knowledge graph reasoning, KGR)问题。现有KGR方法主要包括嵌入式方法、路径搜索方法和基于强化学习的多跳推理方法。嵌入式方法可直接计算关系预测得分,但缺少显式推理路径;传统路径搜索方法可输出路径,但搜索空间随图谱规模和路径长度增加;强化学习方法通过智能体在图谱中逐跳选择关系和实体,可兼顾目标导向搜索与路径生成。Liu^[13]提出基于图注意力卷积网络的可解释多跳知识图谱推理方法;Zhang^[14]整合空间、时间和不确定性维度,开发了基于不确定时空知识图谱的知识链多跳推理方案;Wang^[15]提出基于双智能体动态交互的知识图谱推理模型,用于变压器故障诊断。但是,当知识图谱中包含高连通度部件节点或推理路径较长时,候选搜索空间随之扩大,推理过程可能出现目标导向减弱和轨迹偏离问题^[16]。

针对上述问题,提出面向换流变压器故障溯源的可解释知识图谱推理方法(ICKGR)。首先,采用ALBERT-BiLSTM-CRF抽取运维文本中的实体,依据模式层关系集合和物理因果约束组织关系三元组,构建换流变压器故障溯源知识图谱;其次,设计双智能体强化学习推理模型,并引入软奖励和短期同策略轨迹缓冲区同步更新双智能体参数,实现多跳故障溯源。实验部分采用Hits@K和平均倒数排名评价模型根因排序性能,并通过故障案例展示由设备部件、故

障状态、保护动作和试验方法组成的推理路径。

1 换流变压器故障溯源知识图谱构建

1.1 知识图谱分层建模

换流变压器故障溯源需要从非结构化运维文本中提取因果关系,并将离散的运维知识组织为可查询的语义网络。结合自顶向下与自底向上的构建路径,建立换流变压器故障溯源知识图谱(converter transformer fault tracing knowledge graph, CTFT-KG)。如图1所示,CTFT-KG的构建体系由数据源、模式层和数据层3部分组成。数据源包括换流站运维记录、故障处理报告、行业标准等文本数据。模式层采用自顶向下的方法开展领域本体建模。在模式层约束下,采用自底向上的方法从多源数据中抽取信息并填充数据层,包括数据采集与预处理、知识抽取、知识融合和知识更新4个步骤。




图1 CTFT-KG 构建流程

Fig. 1 Construction process of CTFT-KG

具体而言,换流站运维档案和故障处理报告等数据用于形成数据层中的设备部件、状态、故障、保护动作及处置等实体与关系;行业标准、电力系统运维规程、设备技术手册和专家经验用于模式层建模,并为三元组的物理约束核对提供依据。

1.2 实体抽取模型

针对换流变压器运维文本专业术语密集、逻辑关联紧密且标注样本规模有限的特点,采用ALBERT-BiLSTM-CRF自动抽取故障实体。模型采用自底向上的3层架构,将文本语义转化为逻辑标注,具体架构见图2。首先,ALBERT^[17]生成上下文语义表示,BiLSTM^[18]建模双向上下文和长距离语义依赖,CRF^[19]依据标签转移约束输出实体标签序列,

从而识别设备部件、故障状态、保护动作和试验方法等实体的边界与类别。




图2 ALBERT-BiLSTM-CRF 模型

Fig. 2 ALBERT-BiLSTM-CRF model

实体抽取完成后,依据模式层规定的实体类型组合和关系集合组织候选三元组,并采用设备层级、故障传播方向、试验验证和处置顺序等约束进行核对。

1.3 物理因果约束

三元组入库前施加物理因果约束,主要包括:设备层级约束,即部件关系应符合换流变压器结构;传播方向约束,即状态或部件异常应指向故障和保护动作;试验验证约束,即试验方法应服务于部件状态或故障验证;处置顺序约束,即保护动作和检修处置应位于异常识别之后。对关系 r 定义约束模式 $C_r=(D, R, O)$,分别表示允许的头实体类型、尾实体类型及语义方向。候选三元组 (e, r, τ) 仅在实

体类型和关系方向均满足约束时写入图谱;存在约束冲突、关系歧义或方向不明确的结果不自动入库,而是转入人工复核。

采用TransE^[20]对三元组集合进行嵌入预训练,将实体与关系映射至低维向量空间。实体 e, τ 分别对应嵌入向量 e_e, e_τ ,关系 r 对应嵌入向量 r 。这些嵌入向量构成后续双智能体推理的连续语义表示,并用于强化学习的状态表征、相似度评估和软奖励计算。

2 可解释知识图谱推理模型 IKGR

2.1 故障溯源任务建模

将换流变压器故障溯源表述为知识图谱上的多跳路径搜索问题,并采用马尔可夫决策过程建模。智能体根据当前状态选择关系和实体,环境返回奖励信号;模型采用软奖励和短期同策略轨迹缓冲区更新参数,并输出由观测征兆指向根因实体的推理路径。

IKGR 推理流程见图 3,给定查询 (e_s, r_q, e_t) , e_s 为起始实体, r_q 为溯源意图的查询关系, e_t 为目标根因实体。在第 i 步,智能体依据当前实体、查询关系、历史路径和候选邻域进行决策。直接在完整邻域中搜索时,高连通度部件节点可能产生较多与当前查询无关的候选分支。因此,将动作决策分为全局关系选择和局部实体导航两个阶段。在换流变压器故障溯源场景中,起始实体 e_s 对应现场观测到的设备状态或异常现象,查询关系 r_q 表示需要追溯的故障关联类型,目标实体 e_t 对应待定位的根因实体。当前实体 e_i 可以是推理过程中到达的设备部件、故障状态、保护动作或试验方法;历史路径向量 h_i 编码此前经过的实体和关系序列。




图3 IKGR 双智能体推理框架

Fig. 3 IKGR dual-agent reasoning framework

2.2 双智能体协同推理架构

全局智能体(global agent)负责在推理轨迹的每一步筛选候选关系,以缩小后续实体搜索范围。全局智能体状态定义为元组 (e_s, r_q, e_i, r_{i-1}) , e_i 为当前第 i 步所在的实体, r_{i-1} 为上一步选择的关系。动作空间由当前实体 e_i 的所有相邻边对应的关系构成,即

$$A_i^G = \{(r, e) | (e_i, r, e) \in G, e \notin \{e_0, e_1, \dots, e_{i-1}\}\} \quad (1)$$

采用LSTM编码历史路径,得到第 i 步的历史路径向量 h_i 。其中, h_{i-1} 为上一步的历史路径向量,另一输入为上一步所选关系向量 A_{i-1}^G 。在换流变压器故障溯源任务中, h_i 记录从观测征兆出发已经经过的设备部件、故障状态及相关关系,为后续关系选择保留路径上下文。全局策略将当前状态映射为候选关系上的概率分布。计算时,先通过拼接算子组合语义特征,再经非线性变换得到各候选关系的得分

$$u(s_i^G, A_i^G) = \text{softmax}\{A_i^G \times W_{g1} \text{ReLU}(W_{g2}[e_i; r_q; h_i])\} \quad (2)$$

式(2)中, W_{g1} 、 W_{g2} 为可学习参数。全局智能体根据该概率分布选择当前关系,并以所选关系限定局部智能体的动作空间。

局部智能体(local agent)在全局智能体所选关系 A_i^G 的约束下,从可达候选实体中选择下一跳节点。局部候选实体是CTFT-KG中经关系 r_i 与当前实体相连的节点,其语义类型包括设备部件、故障状态、保护动作或试验方法。局部智能体状态 s_i^L 定义为元组 (e_s, r_q, e_i, A_i^G) 。局部动作空间为

$$A_i^L = \{e'_{i+1} | (e_i, r, e'_{i+1}) \in G, r \in A_i^G\} \quad (3)$$

局部策略 $\pi(s_i^L, A_i^L)$ 根据候选实体的拓扑邻域权重计算选择得分,并据此确定下一跳实体。

$$\pi(s_i^L, A_i^L) = \text{softmax}\{A_i^L \times W_{l1} \text{ReLU}(W_{l2}[e_i; r_q; h_i; A_i^L])\} \quad (4)$$

式(4)中, W_{l1} 、 W_{l2} 为可学习参数。两个智能体通过状态更新进行交互:全局智能体提供关系约束,局部智能体选择下一跳实体。局部智能体选定下一跳实体 e_{i+1} 后,环境返回新状态,模型据此更新历史轨迹编码 h_{i+1} 。上述过程持续至到达目标实体或最大搜索步数。

2.3 基于软奖励机制的策略优化

长路径故障溯源中的奖励信号较为稀疏,可能增加训练收敛难度。为此,引入基于空间相似度的软奖励机制^[21],对未命中目标的终止实体引入由预训练TransE嵌入计算的查询一致性得分,并采用同

策略轨迹缓冲区更新双智能体参数。该机制根据中间节点与目标根因、查询关系和历史路径的一致性提供连续反馈。模型的奖励由软奖励与最终命中奖励共同构成。对查询 (e_s, r_q, e_i) 及轨迹终止实体 e_T ,采用预训练TransE向量计算

$$f(e_s, r_q, e_i) = \frac{1}{1 + \|e_s + r_q - e_i\|_1} \quad (5)$$

式(5)中: e_s 、 r_q 、 e_i 分别为起始实体、查询关系、轨迹终止实体的预训练TransE向量; $f(e_s, r_q, e_i) \in (0, 1]$,距离越小,终止实体与查询关系越一致。定义即时奖励 $R(s_T)$,用于衡量当前实体在查询关系 r_q 约束下与目标实体 e_T 的逼近程度

$$R(s_T) = \begin{cases} 1 & e_T = e_i \\ \lambda_{\text{soft}} f(e_s, r_q, e_i) & e_T \neq e_i \end{cases} \quad (6)$$

式(6)中, λ_{soft} 为软奖励权重。加权后的未命中奖励位于 $(0, 0.5]$,始终低于命中奖励1。有限时域内只在终点计算回报,取 $\gamma=1$,轨迹回报为 $G(\tau)=R(s_T)$ 。训练阶段将推理轨迹及相应软奖励存入短期同策略轨迹缓冲区。采用策略梯度算法迭代更新双智能体参数^[22],优化目标为最大化期望奖励。第 k 轮由当前策略生成短期轨迹并写入缓冲区,设批次大小为 B

$$D_k = \{\tau_j | \tau_j \sim P(\tau | q_j), j = 1, \dots, B\} \quad (7)$$

两组参数的梯度估计分别为:

$$g_g = E_B[(G - b_k) \sum_i q_i^g] \quad (8)$$

$$g_l = E_B[(G - b_k) \sum_i q_i^l] \quad (9)$$

式(8)、(9)中: E_B 为训练批次上的经验平均; b_k 为批次平均回报基线; q_i^g 和 q_i^l 分别为轨迹第 i 步全局策略与局部策略的对数概率关于各自参数的梯度。两组参数在同一训练批次结束后同步更新。

3 实验设计与结果分析

3.1 实验设置

实验在所构建的CTFT-KG数据集上开展。该数据集包含980个实体和12类关系,其中训练集、验证集和测试集分别包含3 450、1 100、1 080条三元组。实体包括设备部件、故障状态、保护动作和试验方法等语义类型,关系用于描述设备层级、故障传播、保护动作、试验验证和处置顺序等联系。主要超参数见表1。模型基于PyTorch实现,采用Adam优化器训练。CTFT-KG的局部子图及其三元组示例见图4。放大区域中的“烧断”为故障状态实体,“缺陷—试验方法”为关系,“零电位法”和“直流

电阻测试”为试验方法实体。

表1 主要超参数设置

Table 1 Main hyperparameter settings

模块	超参数	数值
通用设置	batch size	64
	learning rate	0.002
	epoch	150
	dropout	0.5
知识抽取	max sequence length	250
	hidden size	200
	entity/relation embedding	100
双智能体推理	history embedding	200
	max reasoning steps	15

表1中:batch size为每个批次包含的样本数量; learning rate为Adam优化器的初始学习率;epoch为训练轮数;dropout为随机失活比例;知识抽取模块中的max sequence length为输入文本的最大标记长度;hidden size为BiLSTM隐藏状态维度;双智能体推理模块中的entity/relation embedding为实体和关系的嵌入维度;history embedding为历史路径向量的维度;max reasoning steps为单次推理允许的最大步数。

实验采用 $Hits@K$ 和平均倒数排名 MRR (mean reciprocal rank)评价根因排序性能。 $Hits@K$ 表示真实根因位于前 K 个候选节点中的查询比例, MRR 表示真实根因排名倒数的平均值,计算公式分别为:




图4 CTFT-KG 局部子图示例

Fig. 4 Local subgraph of CTFT-KG

$$Hits@K = \frac{1}{|Q|} \sum_{i=1}^{|Q|} \mathbb{I}(rank_i \leq K) \quad (10)$$

$$MRR = \frac{1}{|Q|} \sum_{i=1}^{|Q|} \frac{1}{rank_i} \quad (11)$$

式(10)、(11)中: $|Q|$ 为测试集查询总数; $rank_i$ 为在第 i 次查询中真实根因在候选实体排序中的名次; $\mathbb{I}$ 为指示函数,当条件成立时其取值为1,否则为0。

3.2 故障溯源性能

为评价 IKGR 在工业垂直领域知识图谱上的多跳推理与故障溯源性能,在构建好的 CTFT-KG 中,

将 IKGR 与嵌入模型 TransE^[20]、单智能体模型 DeepPath^[23]及多跳推理模型 MINERVA^[24]、Multihop-KG^[21]、KGR-DIDA^[15]进行比较。推理路径长度分别设为 1、3、5、7、9、11、13、15,并采用 $Hits@10$ 和 MRR 评价根因排序性能。

实验结果曲线图见图5,各模型在推理路径长度为7跳时的实验结果见表2。IKGR两项指标的曲线整体高于除KGR-DIDA外的4种基线模型;在推理路径长度超过5跳时,IKGR在故障溯源任务上的表现优于KGR-DIDA,这得益于软奖励联合同策略轨迹缓冲区的参数更新机制。当推理路径长度

(L)为7跳时, $Hits@10$ 达到最高值94.8%。




图5 故障溯源对比实验

Fig. 5 Comparative experiment on fault tracing

表2 故障溯源对比实验结果($L=7$)

Table 2 Comparative experimental results on fault tracing($L=7$)

模型	$Hits@10/\%$	$MRR/\%$
TransE	74.5	55.2
DeepPath	87.6	69.8
MINERVA	91.2	80.5
Multihop-KG	86.4	74.5
KGR-DIDA	93.7	84.9
IKGR	94.8	88.6

表4 IKGR故障溯源案例

Table 4 Fault-tracing cases of IKGR

故障问题	推理链路	路径准确率/%
当压力释放装置(PRD)启动并排出油液时, 应采取何种响应措施?	压力释放装置→PRD因油液泄漏而启动→储油柜油位保护→气体继电器测试	93.9
220 kV 网侧引线单相接地时应采取何种保护和试验方法?	换流变压器→220 kV 网侧引线或套管→单相接地故障→零序电流保护→绝缘电阻测量	93.7
套管升高座潜伏性绝缘故障的保护策略?	绝缘套管→套管升高座→潜伏性绝缘故障→局部放电带电检测→保护设备免受严重损坏	94.5
频率响应曲线与历史曲线相比发生明显偏移是何原因?	频率响应曲线异常→绕组机械状态异常→阀侧绕组→短路电力引起的绕组变形	92.7
为何铁心接地电流持续异常升高?	铁心接地电流异常→接地回路异常发热→铁心接地回路→铁心多点接地	94.1

3.3 消融实验

为分析全局智能体、局部智能体和软奖励对根因排序性能的影响,在CTFT-KG上进行了消融实验,结果见表3。

表3 IKGR 消融实验结果

Table 3 Ablation results of IKGR

模型	$Hits@1/\%$	$Hits@3/\%$	$Hits@10/\%$	$MRR/\%$
IKGR (w/o global agent)	77.2	79.4	85.1	81.3
IKGR (w/o local agent)	79.5	82.4	84.7	84.4
IKGR (w/o soft reward)	78.4	85.1	90.5	85.3
IKGR	85.4	89.5	94.8	88.6

完整模型的 $Hits@1$ 、 $Hits@3$ 、 $Hits@10$ 、 MRR 分别为 85.4%、89.5%、94.8%、88.6%。移除任一组件后,各项指标均下降。移除全局智能体和局部智能体后, MRR 分别降至 81.3%和 84.4%,低于完整模型的 88.6%,说明全局关系筛选和局部实体导航均对根因排序性能有贡献。移除软奖励后, $Hits@10$ 由 94.8%降至 90.5%。该结果与软奖励为中间状态提供连续反馈的设计目标一致,说明软奖励对本实验设置下的排序性能具有正向作用。

3.4 案例分析

5个故障溯源案例见表4,用于展示IKGR的路径输出。为量化输出路径相对于标准答案链的偏离程度,将第 i 个测试查询的输出路径表示为实体与关系交替排列的序列 P_i ,其标准答案链集合表示为 G_i 。故障场景 s 的路径准确率定义为

$$PA_s = \frac{100\%}{N_s} \sum_{i=1}^{N_s} \left[1 - \min_{1 \leq j \leq M_i} \frac{D_{lev}(P_i, G_i^{(j)})}{\max(|P_i|, |G_i^{(j)}|)} \right] \quad (12)$$

式(12)中: N_s 为故障场景 s 中的测试查询数; M_i 为第 i 个查询对应的标准答案链数量; $D_{lev}(\cdot)$ 为编辑距离,即输出路径相对于标准答案链发生插入、删除和替换的最少次数。若一个查询只有一条标准

答案链, 则 $M_i=1$; 若存在多条经专家确认且工程含义等价的标准链, 则取与输出路径偏离最小的一条。发生节点或关系偏离时, 得分按归一化编辑距离相应降低。

以“换流变压器压力释放装置(PRD)启动并排出油液”为例, 全局智能体筛选“包含部件”“发生缺陷”“触发保护”等关系, 局部智能体在相应关系约束下选择下一跳实体, 最终形成由设备部件、故障状态、保护动作和试验方法组成的推理链路, 该案例的溯源路径准确率为93.9%。

4 结论

1) 采用 ALBERT-BiLSTM-CRF 抽取换流变压器非结构化运维文本中的实体, 并依据图谱模式层和物理因果约束组织关系三元组, 构建故障溯源知识图谱 CTFT-KG。

2) 双智能体分别执行全局关系选择和局部实体导航, 并采用软奖励和短期同策略轨迹缓冲区同步更新双智能体参数, 从而缓解长路径下的奖励稀疏问题, 提高了 IKGR 模型在多跳推理中的稳定性。

3) 在 CTFT-KG 上, IKGR 在最优推理路径长度下的 $Hits@10$ 达到 94.8%, 输出路径包含设备部件、故障状态、保护动作和试验方法, 可为换流站智能化运维与诊断决策提供高效、可解释的路径级决策依据。

后续研究将进一步融合在线监测量、跨设备型号及跨站点运维数据, 并从路径正确性、约束满足情况、解释稳定性和实际决策效用等方面开展综合评估。

参考文献:

- [1] 刘洪顺, 隋宜臻, 赵茹雪, 等. 换流变压器油纸绝缘气泡动态行为与高能电弧演化机理及其防治技术综述[J]. 高压电器, 2026, 62(4): 1-16.
Liu Hongshun, Sui Yizhen, Zhao Ruxue, et al. Review on the evolution mechanism and active prevention of high-energy arcing induced by gas bubble dynamics in oil-paper insulation of converter transformers[J]. High Voltage Apparatus, 2026, 62(4): 1-16.
- [2] 陈洪波, 曹培, 高凯, 等. 换流变压器有载调压开关防爆试验研究与分析[J]. 高压电器, 2024, 60(2): 119-126.
Chen Hongbo, Cao Pei, Gao Kai, et al. Research and analysis on explosion-proof test of converter transformer OLTC[J]. High Voltage Apparatus, 2024, 60(2): 119-126.
- [3] 汪佛池, 程祥瑞, 赵涛, 等. 油纸绝缘中气泡的生成特性及其对击穿性能的影响[J]. 高压电器, 2020, 56(1): 61-67.
Wang Fochi, Cheng Xiangrui, Zhao Tao, et al. Characteristics of bubble formation in oil-paper insulation and its influence on the breakdown[J]. High Voltage Apparatus, 2020, 56(1): 61-67.
- [4] 邱晟璇, 王松, 刘子瑞, 等. 基于 FRA 法和 CNN 的变压器绕组故障诊断研究[J]. 大电机技术, 2025(3): 108-116.
Qiu Shengxuan, Wang Song, Liu Zirui, et al. Research on fault diagnosis of transformer windings based on FRA method and CNN[J]. Large Electric Machine and Hydraulic Turbine, 2025(3): 108-116.
- [5] Patil M, Paramane A, Das S, et al. Hybrid algorithm for dynamic fault prediction of HVDC converter transformer using DGA data[J]. IEEE Transactions on Dielectrics and Electrical Insulation, 2024, 31(4): 2128-2135.
- [6] Li H, Yao Q, Li X. Voiceprint fault diagnosis of converter transformer under load influence based on multi-strategy improved mel-frequency spectrum coefficient and temporal convolutional network[J]. Sensors, 2024, 24(3): 757.
- [7] 孙长海, 苏晓敏, 李天伦, 等. 基于概率神经网络的油纸绝缘局部放电发展阶段识别[J]. 高压电器, 2022, 58(1): 138-147.
Sun Changhai, Su Xiaomin, Li Tianlun, et al. Development stage recognition of partial discharge in oil-paper insulation based on probabilistic neural network[J]. High Voltage Apparatus, 2022, 58(1): 138-147.
- [8] 汤健, 侯慧娟, 盛戈峰, 等. 变压器不平衡样本故障诊断的过采样和代价敏感算法[J]. 高压电器, 2023, 59(6): 93-102.
Tang Jian, Hou Huijuan, Sheng Gehao, et al. Oversampling and cost-sensitive algorithm for transformer fault diagnosis with unbalanced samples[J]. High Voltage Apparatus, 2023, 59(6): 93-102.
- [9] Tang Yachen, Liu Tingting, Liu Guang, et al. Enhancement of power equipment management using knowledge graph[EB/OL]. [2026-04-02]. <https://arxiv.org/abs/1904.12242>.
- [10] Tang Yachen, Han Haiyun, Yu Xianmao, et al. An intelligent question answering system based on power knowledge graph[C]//2021 IEEE Power & Energy Society General Meeting (PESGM), 2021: 1-5.
- [11] Li Cheng, Wang Bo. A knowledge graph method towards power system fault diagnosis and classification[J]. Electronics, 2023, 12(23): 4808.
- [12] Chaudhary A, Kafaie S, Rajabi E. EZ-check: explainable zero-shot knowledge extraction and fact checking using knowledge graphs[J]. Information Sciences, 2026(742): 123293.
- [13] Liu Hao, Li Dong, Zeng Bing, et al. Graph attention convolutional networks for interpretable multi-hop knowledge graph reasoning[J]. Information Processing & Management, 2026, 63(4): 104581.
- [14] Zhang Xiaowen, Yan Li, Ma Zongmin. Multi-hop reasoning of knowledge chain over fuzzy spatiotemporal knowledge graphs with box embeddings[J]. Engineering Applications of Artificial Intelligence, 2026(173): 114443.
- [15] Wang Xiaowen, Han Huihui, Gao Benhe. Enhancing power transformer fault diagnosis through dynamic knowledge graph reasoning[J]. IEEE Transactions on Instrumentation and Measurement, 2025(74): 1-9.
- [16] Ren Yuan, Nie Zhijie, Zhang Richong, et al. Progressive multi-hop reasoning for question answering over knowledge graphs[J]. Information Systems, 2026(140): 102721.

(下转第 198 页)

- [15] 韩志. 基于多元信息融合的变压器励磁涌流识别研究[J]. 微型电脑应用, 2023, 39(12): 215-219.
Han Zhi. Research on transformer inrush current identification based on multivariate information fusion[J]. Microcomputer Applications, 2023, 39(12): 215-219.
- [16] 马云龙, 李秀广, 周秀, 等. 基于高压真空快速断路器的变压器励磁涌流抑制技术研究[J]. 高压电器, 2022, 58(10): 136-142.
Ma Yunlong, Li Xiuguang, Zhou Xiu, et al. Research on excitation inrush current suppression technology of transformer based on high voltage vacuum fast circuit breaker[J]. High Voltage Apparatus, 2022, 58(10): 136-142.
- [17] Peng Qingjun, Du Hantao, Zheng Zezhong, et al. Prediction of magnetic fields in single - phase transformers under excitation inrush based on machine learning[J]. Sensors, 2025, 25(13): 4150.
- [18] Chu Wenchao, Wang Qiong, Yang Bo, et al. Analysis and study of excitation inrush current characteristics of high-impedance power transformer[C]//2025 2nd International Conference on Smart Grid and Artificial Intelligence (SGAI), 2025: 1592-1596.
- [19] Wang Jianting, Gao Yonglin, Liu Yaxing, et al. Application of a multi-scale feature-enhanced transformer for segmentation in complex intercropping scenarios[J]. Smart Agricultural Technology, 2026(14): 102137.
- [20] Qazi E U H, Almorjan A, Zia T. A one-dimensional convolutional neural network(1D-CNN)based deep learning system for network intrusion detection[J]. Applied Sciences, 2022, 12(16): 7986.
- [21] Zhang Ping, Jia Yiqiao, Shang Youlin. Research and application of XGBoost in imbalanced data[J]. International Journal of Distributed Sensor Networks, 2022, 18(6): 15501329221.
- [22] Ren Weiqing, Qu Yuben, Dong Chao, et al. A survey on collaborative DNN inference for edge intelligence[J]. Machine Intelligence Research, 2023, 20(3): 370-395.
- [23] 肖白, 李森, 焦明曦, 等. 基于霜冰优化组合模态分解及Informer的空间负荷预测[J]. 电力建设, 2026, 47(4): 108-121.
Xiao Bai, Li Sen, Jiao Mingxi, et al. Spatial load forecasting based on RIME-optimized combination modal decomposition and Informer[J]. Electric Power Construction, 2026, 47(4): 108-121.
- [24] 郑玉周, 杜金龙, 武永强, 等. 基于改进热路模型和PINN的变压器直流偏磁温升预测及绝缘寿命评估[J]. 电力电容器与无功补偿, 2026, 47(2): 107-117.
Zheng Yuzhou, Du Jinlong, Wu Yongqiang, et al. Prediction of DC-bias temperature rise in transformer and insulation life assessment based on an improved thermal circuit model and PINN[J]. Power Capacitor & Reactive Power Compensation, 2026, 47(2): 107-117.
- [25] 张楚, 王熠炜, 张越, 等. 基于改进堆优化算法和TimesNet神经网络的锂电池剩余寿命预测方法[J]. 太阳能学报, 2025, 46(11): 98-108.
Zhang Chu, Wang Yiwei, Zhang Yue, et al. Lithium-ion battery remaining useful life prediction method based on improved heap optimization algorithm and TimesNet neural network[J]. Acta Energiae Solaris Sinica, 2025, 46(11): 98-108.
- 郜晓娜(1983—), 女, 硕士研究生, 工程师, 主要研究方向为调度运行(通信作者)(E-mail: xiaonagao83@outlook.com)。

(上接第185页)

- [17] Lan Z, Chen M, Goodman S, et al. ALBERT: a lite BERT for self-supervised learning of language representations[EB/OL]. [2026-04-02]. <https://arxiv.org/abs/1909.11942>.
- [18] Graves A, Schmidhuber J. Framewise phoneme classification with bidirectional LSTM and other neural network architectures[J]. Neural Networks: The Official Journal of the International Neural Network Society, 2005, 18(5/6): 602-610.
- [19] Lafferty J D, McCallum A, Pereira F C N. Conditional random fields: probabilistic models for segmenting and labeling sequence data[C]//Proceedings of the Eighteenth International Conference on Machine Learning, 2001: 282-289.
- [20] Bordes A, Usunier N, Garcia-Durán A, et al. Translating embeddings for modeling multi-relational data[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems, 2013: 2787-2795.
- [21] Lin X V, Socher R, Xiong C. Multi-hop knowledge graph reasoning with reward shaping[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, 2018: 3243-3253.
- [22] Williams R J. Simple statistical gradient-following algorithms for connectionist reinforcement learning[J]. Machine Learning, 1992, 8(3): 229-256.
- [23] Xiong W, Hoang T, Wang W Y. DeepPath: a reinforcement learning method for knowledge graph reasoning[C]//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, 2017: 564-573.
- [24] Das R, Dhuliawala S, Zaheer M, et al. Go for a walk and arrive at the answer: reasoning over paths in knowledge bases using reinforcement learning[EB/OL]. [2026-04-02]. <https://arxiv.org/abs/1711.05851>.
- 吴婉豪(2002—), 女, 硕士研究生, 主要研究方向为变压器缺陷检测与诊断方法。
- 任富强(1990—), 男, 博士, 副研究员, 主要研究方向为新型电力系统构建背景下电力设备多场耦合分析及可靠性提升、绝缘劣化机理、绝缘状态评估、人工智能在电力设备中的应用(通信作者)(E-mail: renfuqiang@sdu.edu.cn)。