

DOI: 10.19783/j.cnki.pspc.231475

# 基于关系超图增强 Transformer 的智能站二次设备故障诊断研究

周海成<sup>1</sup>, 石恒初<sup>2</sup>, 曾令森<sup>3</sup>, 王飞<sup>1</sup>, 欧阳勇<sup>4</sup>

(1. 云南电网有限责任公司普洱供电局, 云南 普洱 665000; 2. 云南电力调度控制中心, 云南 昆明 650011;  
3. 武汉华电顺承科技有限公司, 湖北 武汉 430072; 4. 湖北工业大学计算机学院, 湖北 武汉 430072)

**摘要:** 随着智能变电站二次设备的状态感知与自描述能力不断提升, 在提高电网调控细粒度的同时, 其海量、驳杂、离散的状态信息也使故障诊断难度倍增。为提高二次设备故障诊断精度与效率, 提出基于关系超图增强 Transformer 的二次设备故障诊断算法。首先利用 Apriori 算法挖掘故障信号间的关联规则, 构建关系超图。然后利用超图卷积神经网络(hypergraph convolutional neural network, HGCN)和微调标准 Transformer 网络学习故障特征间的高阶关系和上下文表达, 再经过误差反向传播、非线性传递函数预测故障类型。最后, 以某地区一年的二次设备运行数据作为算例进行分析。结果表明, 所提方法能够去除冗余信息干扰, 准确定位故障元件和诊断故障类型, 为智能运维提供支持。

**关键词:** 关系超图; 超图卷积神经网络; Transformer; 故障预测; 二次设备; 设备关联模型

## Fault diagnosis of an intelligent substation secondary device based on a relational hypergraph-enhanced Transformer

ZHOU Haicheng<sup>1</sup>, SHI Hengchu<sup>2</sup>, ZENG Lingsen<sup>3</sup>, WANG Fei<sup>1</sup>, OUYANG Yong<sup>4</sup>

(1. Pu'er Power Supply Bureau of Yunnan Power Grid Co., Ltd., Pu'er 665000, China; 2. Yunnan Electric Power Dispatching Control Center, Kunming 650011, China; 3. Wuhan Huadian Shuncheng Science Technology Co., Ltd., Wuhan 430072, China; 4. School of Computer Science, Hubei University of Technology, Wuhan 430072, China)

**Abstract:** With the continuous improvement of state perception and self description capabilities of secondary equipment in intelligent substations, it not only improves fine-grained regulation of the power grid, but also doubles the difficulty of fault diagnosis because of its massive, complex, and discrete state information. To improve the accuracy and efficiency of secondary equipment fault diagnosis, a secondary equipment fault diagnosis algorithm based on a relational hypergraph-enhanced Transformer is proposed. First, a Priori algorithm is used to mine the association rules between fault signals and a relationship hypergraph is constructed. Then, a hypergraph convolutional neural network (HGCN) and a fine-tuned standard Transformer network are used to learn high-order relationships and contextual expressions between fault features, and then fault types are predicted through error backpropagation and a nonlinear transfer function. Finally, the annual operational data of secondary equipment in a certain region is taken as an example for analysis. The results show that the proposed method can remove redundant information interference, accurately locate faulty components and diagnose fault types, providing support for intelligent operation and maintenance.

This work is supported by the Science and Technology Project of China Southern Power Grid Co., Ltd. (No. YNKJXM20220093).

**Key words:** relational hypergraph; HGCN; Transformer; fault prediction; secondary equipment; device association model

## 0 引言

随着以风电、光伏为主的新能源大规模接入电

网, 高比例新能源、高比例电力电子设备的“双高”特征显现, 使得电力系统故障形态越发复杂, 为继电保护适应性带来了全新挑战<sup>[1]</sup>。

“双高”型新型电力系统呈现强不确定性、脆弱性和复杂性, 要求调度对二次设备故障的分析和处理更加科学和迅速。目前二次设备故障诊断很大

基金项目: 中国南方电网有限责任公司科技项目资助 (YNKJXM20220093)

程度上依赖人工干预，未形成系统化的决策信息链闭环，很容易漏判、误判，难以满足经济快速发展趋势下对故障诊断速度和精度的高要求<sup>[2]</sup>。因此有必要研究二次设备故障诊断方法，提高故障诊断水平。二次设备故障诊断任务是基于给定二次设备发生故障时所产生的大量异常告警信息，预测具体的故障类型。

在二次设备故障诊断方面，文献[3]根据二次设备物理与逻辑连接关系构建图神经网络，结合设备告警信号表征实现二次回路故障定位。文献[4]结合变压器抗阻测量，利用可靠性评估与Petri网模型辨别二次回路运行状态，引入广义变比实现故障诊断任务。文献[5]使用k-dist图优化密度聚类算法对正常数据流样本进行聚类，再使用改进的粒子群算法优化单类支持向量机来建立通信网络异常数据流检测模型。文献[6]挖掘各设备故障与告警信号之间的关联程度，从而构造对应的告警故障树。文献[7]按照综合逻辑推理机制回复设备保护功能的判别结果，通过自主信息互校定位和诊断故障。但这些方法适用于单一故障特征的故障诊断，对于复杂故障特征信息，定性定量分析均具有局限性，诊断模型还需优化和改进。

近年来，人工智能相关算法从大量、随机数据中提取隐含的丰富潜在知识，实现深层次的数据特征挖掘，具有良好的鲁棒性、自组织及自适应能力，广泛应用于分类、预测和故障识别等方面。文献[8]构建故障树并转换成贝叶斯网络，实现保护系统的先验预测和故障后验定位及溯源。文献[9-10]均基于关联规则挖掘事件影响因素与结果间的关联程度，筛选出频繁项集，建立事件特征知识库，应用专家系统进行故障诊断。文献[11-12]采用小波包变换原理对滚动轴承振动信号进行降噪处理，再用经验模态分解方法重构振动信号并解调得到所需故障特征。文献[13]介绍了多种深度学习算法在智能设备故障诊断中的应用。但智能变电站内部网络拓扑连接复杂，异常告警信息数据量大且关联度高，利用单一的故障辨识方法无法高效地捕获重要的告警信息，准确定位诊断位置。因此，本文尝试引入关系超图<sup>[14-15]</sup>的概念来捕捉其复杂的拓扑关系。

超图是一种广义的图结构，它由节点和超边组成，其中超边可以连接任意数量的节点。与图1(a)所示的传统图结构不同，图1(b)所示的超图中的边可以连接多个节点，即超边。当所有超边只连接2个节点时，超图将等同于普通图结构。超图的特殊结构可以更好地描述一些复杂的高阶关系，十分适合智能站二次设备的关系梳理和故障排查。

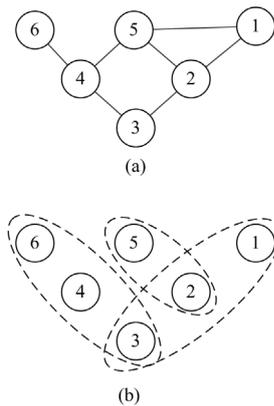


图1 传统图和超图的结构对比

Fig. 1 Structure of traditional graph and hypergraph

具体来说，针对二次设备关联性强、故障诊断复杂度高等问题，本文首先利用 Apriori 算法挖掘故障告警信号之间的相关关系，并构建关系超图；然后对该关系超图执行图卷积神经网络(hypergraph convolutional neural network, HGCN)以学习故障特征的高阶关系；随后微调标准 Transformer 网络来学习故障特征的上下文表达；最后经过误差反向传播、非线性传递函数计算后，预测出故障类型，锁定故障元件。并以南方电网某区域内二次设备故障数据样本进行算例仿真，验证了所提方法的有效性。

本文的主要贡献如下所述。

- 1) 本文构建关系超图以捕捉故障告警信号之间的高阶关系，提升对故障特征的挖掘能力。
- 2) 本文提出关系超图增强的 Transformer 网络，其捕捉故障特征的上下文关系，从而提升故障诊断效果。
- 3) 在南方电网某区域上进行仿真实验，结果表明本文提出的模型较现有模型在故障诊断准确率方面有明显提升。

## 1 关系超图构建

关系反映事物之间的依存和关联，对于二次设备故障诊断的研究任务来说，对故障信号关系的建模至关重要。由于智能变电站内部网络拓扑连接复杂、异常告警信息数据量大且关联度高，本文主要尝试引入超图的概念来捕捉故障信号之间的关系。

为了构建超边，本文借助 Apriori 关联规则算法<sup>[16]</sup>挖掘故障告警信号的共现关系，如“自检异常”和“装置闭锁”信号共现是否代表“DSP 模块故障”的发生？通过挖掘这类关联关系后，属于同一个关系中的告警信息可以被认为属于同一个超边，从而构建一个可以表示故障信号间高阶关系的超图。由

于这种超图旨在刻画信号间的关联关系, 因此本文称为“关系超图”。

### 1.1 关系挖掘

以异常告警信息作为故障特征信息, 关系挖掘主要利用 Apriori 算法提取频繁项集, 以探索其与故障区域的潜在联系。

设二次设备故障事务数据集为  $Q$ , 一个事务数据集就是一个项集, 项集  $Q = \{Q_1, Q_2, Q_3, \dots, Q_r\}$  包含二次设备发生故障时接收到的异常告警信息、故障区域等具体数据项的集合,  $Q_r$  称为项集中的第  $r$  件事务。  $M$ 、 $N$  为属于  $Q_r$  的项,  $M \neq \emptyset$  且  $N \neq \emptyset$ 、 $M \cap N \neq \emptyset$ , 关联规则  $M \Rightarrow N$  表示二者之间的存在关联, 其中前项  $M$  是规则产生的条件, 后项  $N$  是规则的结果。

支持度与置信度评价关联规则优劣。支持度指  $M$ 、 $N$  同时发生的概率, 是筛选频繁项集的依据<sup>[17]</sup>, 定义为

$$S(M \Rightarrow N) = \frac{\text{Count}(M \cup N)}{|A|} \quad (1)$$

式中:  $S(M \Rightarrow N)$  为项集  $\{M, N\}$  的支持度;  $\text{Count}(M \cup N)$  为项集  $\{M, N\}$  出现的次数;  $|A|$  为项集总数。

置信度指在  $M$  情况下  $N$  发生的概率, 用来评价关联规则可靠程度, 定义为

$$C(M \Rightarrow N) = \frac{S(M \Rightarrow N)}{S(M)} \quad (2)$$

式中:  $C(M \Rightarrow N)$  为项集  $\{M, N\}$  的置信度;  $S(M)$  为项集  $\{M\}$  的支持度。

最小支持度与最小置信度根据实际情况设置, 分别记作  $S_{\min}$ 、 $C_{\min}$ 。

关联规则挖掘具体流程如图 2 所示, 主要通过以下 3 个步骤实现。

1) 扫描事务数据集产生候选 1 项集  $C_1$ , 计算  $C_1$  中每个元素的支持度  $S_{e1}$ , 删除支持度小于  $S_{\min}$  的元素, 生成频繁 1 项集  $L_1$ 。

2) 经过逐层搜索迭代, 将频繁项集  $L_{k-1}$  中前  $K-2$  个项相同的元素进行连接, 生成候选  $K$  项集  $C_k$ , 扫描事务数据集计算  $C_k$  中每个元素的支持度  $S_{ek}$ , 删除支持度小于  $S_{\min}$  的元素, 生成频繁  $K$  项集  $L_k$ 。

3) 扫描事务数据集计算  $L_k$  中每个元素的置信度  $C_{ek}$ , 删除置信度小于  $C_{\min}$  的元素, 生成关联规则。

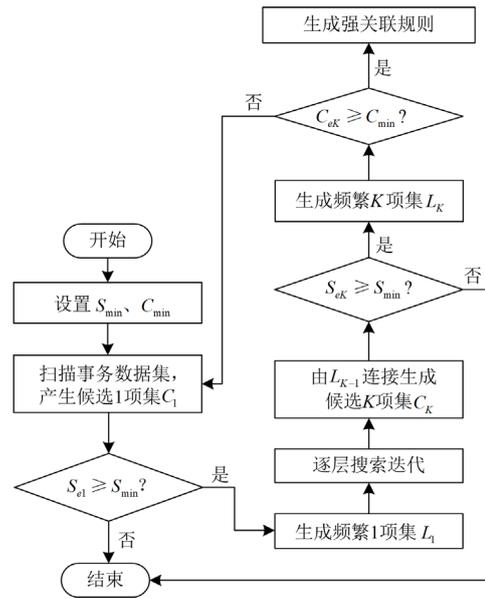


图 2 Apriori 算法流程图

Fig. 2 Flow chart of Apriori algorithm

### 1.2 置信度校正模型

本文进一步依据全站系统配置文件(substation configuration description, SCD)<sup>[18]</sup>设计设备关联模型(device association model, DAM)以校正关联关系的置信度。DAM 模型将变电站(Substation)、电压等级(VoltageLevel)、间隔(Bay)、智能电子设备(intelligent electronic devices, IED)、功能元件(logical device, LDevice)、逻辑节点(logical node, LN)进行树形排列, 描述设备及其功能元件和逻辑节点之间的关系。

DAM 模型根据逻辑关系校正故障区域中故障元件的置信度, 同时排除关联规则中误报的故障特征信息。

在 DAM 模型中, 存在 4 种逻辑关系, 分别为 ①从属关系、②单一源关系、③同源关系、④上层同源关系, 如图 3 所示。

其中, 从属关系指 DAM 模型的树形结构中的父子节点关系, 如图 3: ①中 VoltageLeve2 与其父节点 Substation1, 表述为 VoltageLevel2 从属于 Substation1。同理 LN0 与其父节点 LDevice1 也是从属关系, 基于从属关系建立路径(如 Substation1/VoltageLeve2/Bay1/IED1/LDevice1/LN0)以准确表示节点在模型中的位置, 结合故障类型及故障置信度即形成故障元件定位。

单一源关系和同源关系指逻辑节点(LN)之间存在虚回路连接关系, 主要用于逻辑节点和虚回路相关故障类型的置信度校正。单一源关系指逻辑节点之间有且只有一条虚回路连接, 如图 3: ②所示:

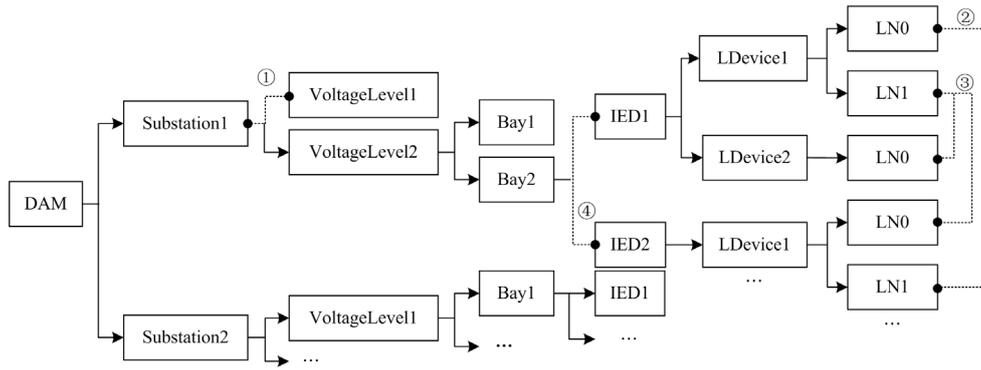


图 3 DAM 模型  
Fig. 3 DAM model

同源关系指一个逻辑节点与多个逻辑节点之间有虚回路连接，如图 3：③所示。虚回路是一种报文交互方式，具有方向性，设定报文发送端为 O、接收端为 P。

在单一源关系中，发送端发出异常告警信息是其接收端发出同类型异常告警信息的充分不必要条件。设定  $G_o$  和  $G_p$  分别为发送端 O 和接收端 P 的对应元件出现故障的原始置信度。

接收端 P 的对应元件出现故障的校正置信度为  $G_{c,p}$ ，如式(3)所示。

$$G_{c,p} = G_o \times G_p \quad (3)$$

发送端 O 的对应元件出现故障的校正置信度为  $G_{c,o}$ ，如式(4)所示。

$$G_{c,o} = 1 - G_{c,p} \quad (4)$$

在同源关系中，发送端发出异常告警信息是其  $n$  个接收端中第  $i$  个接收端  $P_i$  发出同类型异常告警信息的充分不必要条件。设定  $G_o$ 、 $G_i$  分别为发送端 O 和接收端  $P_i$  的对应元件出现故障的置信度。

$n$  个接收端的对应元件同时出现故障的置信度为  $G_p$ ，如式(5)所示。

$$G_p = G_o \times \prod_{i=1}^n G_i \quad (5)$$

发送端 O 的对应元件出现故障的校正置信度为  $G_{c,o}$ ，如式(6)所示。

$$G_{c,o} = G_o - G_p \quad (6)$$

接收端  $P_i$  的对应元件出现故障的校正置信度为  $G_{c,i}$ ，如式(7)所示。

$$G_{c,i} = G_i - G_p \quad (7)$$

上层同源关系指设备(IED)处于同一厂站、电压等级和间隔内的关系，在 DAM 模型中表示为在同一 Substation/VoltageLevel/Bay/路径下，如图 3：④所示的 IED1 与 IED2。上层同源关系主要用于对 IED

所在公共网络的共性故障进行排除性校正，例如：电源、时钟、网络等相关故障类型。

上层同源关系中，设定  $D_j$  为公共网络内  $m$  个 IED 中第  $j$  个 IED，则公共网络设备故障是  $D_j$  发出同类型异常告警信息的充分不必要条件。由于已投运的公共网络设备大多不支持基于 IEC61850 标准的异常告警信息，无法通过关系挖掘得到其故障特征及置信度，此处仅对 IED 对应元件故障的原始置信度进行校正。设定  $G_j$  为  $D_j$  对应元件出现故障的原始置信度。

$m$  个 IED 对应元件同时出现故障的置信度为  $G_D$ ，如式(8)所示。

$$G_D = \prod_{j=1}^m G_j \quad (8)$$

$D_j$  对应元件出现故障的校正置信度为  $G_{c,j}$ ，如式(9)所示。

$$G_{c,j} = G_j - G_D \quad (9)$$

### 1.3 关系超图构建

根据 1.1 节和 1.2 节的关系挖掘流程，本文最终得到多条故障信号关联关系，如{自检异常，装置闭锁，SV 总告警，SV 采样数据异常}这 4 个异常告警信息与故障类型{合并单元 DSP 模块故障}存在关联关系。基于此，本节进一步定义关系超图。

在图 1 中，本文展示了普通图一般为一条边连接两个节点，其度为 2，而超图的度理论上是无限的，即一条超边可以连接多个节点，它们代表着共同的语义模式。本文定义图节点为每种异常告警信息，超边为关联关系集合，超图的最大度为 5。以上述关联关系为例：图节点①、②、③、④分别代表自检异常、装置闭锁、SV 总告警、SV 采样数据异常，而超边  $E_1$ 、 $E_2$  则表示以上图节点之间的关联关系，如图 4 所示。节点的初始特征向量定义为

独热编码, 以便于完成后续神经网络的计算。

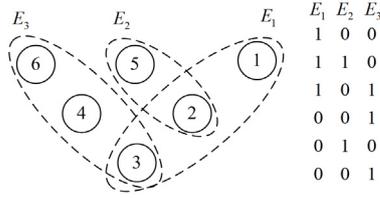


图 4 超边和邻接矩阵示例

Fig. 4 Examples of hyperedges and adjacency matrices

## 2 超图卷积神经网络

随着图卷积神经网络(graph convolutional neural networks, GCN)<sup>[14]</sup>的发展, 超图神经网络(hypergraph neural network, HGN)架构<sup>[15]</sup>被提出。由于利用普通的图结构方法难以学习超图中的高阶相关性, 本文

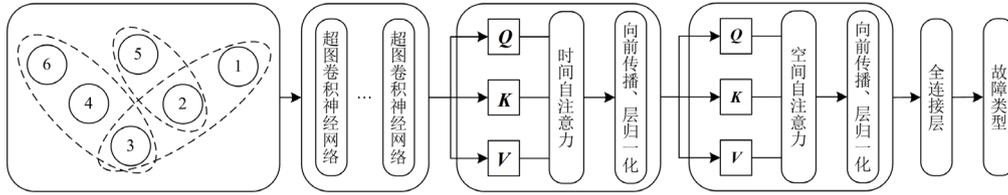


图 5 基于关系超图增强的 Transformer 结构图

Fig. 5 Transformer structure diagram based on relationship hypergraph enhancement

## 3 基于关系超图增强的 Transformer

现有的研究证明 Transformer<sup>[19-20]</sup>在自然语言处理及计算机视觉中具有良好的性能。然而, 本文发现由于设备故障数据稀疏化, 很难有效准确地优化标准 Transformer。在对传统 Transformer 进行组件分析后, 本节构建基于关系超图增强的 Transformer 提高二次设备故障诊断精度。

本文沿时间轴和空间轴应用标准 Transformer 从关系超图节点特征的上下文表达中捕获隐藏增强特征。给定隐藏增强特征  $Y \in \mathbb{R}^{N \times d_f}$ , 其中  $N$  为节点个数,  $d_f$  为特征嵌入的维度, 按式(11)获得注意力机制的查询、键、值矩阵, 表示为

$$\mathbf{Q} = \mathbf{Y}\mathbf{W}_q, \mathbf{K} = \mathbf{Y}\mathbf{W}_k, \mathbf{V} = \mathbf{Y}\mathbf{W}_v \quad (11)$$

式中:  $\mathbf{Q}$ 、 $\mathbf{K}$ 、 $\mathbf{V}$  分别表示注意力机制的查询、键、值矩阵;  $\mathbf{W}_q$ 、 $\mathbf{W}_k$ 、 $\mathbf{W}_v \in \mathbb{R}^{d_f \times d_f}$  为学习参数。

按式(12)计算自注意力分数, 以获取不同空间节点间的时间关系, 表示为

$$\mathbf{A} = \text{Softmax} \left( \frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_f}} \right) \quad (12)$$

式中,  $\mathbf{A} \in \mathbb{R}^{N \times N}$ 。

将利用超图卷积神经网络(HGCN)对关系进行编码。

给定图 5 中定义的超图, 本节引入带有卷积层的超图特征传递范式来捕获随时间和空间变化的全局信息, 用于细化特征表示。超图卷积层设计为

$$\mathbf{Y} = \sigma \left( \mathbf{W}\mathbf{X}\mathbf{D}_v^{-\frac{1}{2}}\mathbf{H}\mathbf{M}\mathbf{D}_e^{-1}\mathbf{H}^T\mathbf{D}_v^{-\frac{1}{2}} \right) = \sigma(\mathbf{W}\mathbf{X}\mathbf{G}) \quad (10)$$

式中:  $\mathbf{H}$  表示超图的关联矩阵;  $\mathbf{D}_v$  和  $\mathbf{D}_e$  分别表示顶点  $v$  的度和超边  $e$  的度的对角矩阵;  $\mathbf{X}$  表示初始图节点特征矩阵;  $\mathbf{Y}$  表示卷积后的图节点特征矩阵;  $\mathbf{W}$  表示用于节点嵌入的可学习权重矩阵; 利用  $\mathbf{G} = \mathbf{D}_v^{-\frac{1}{2}}\mathbf{H}\mathbf{M}\mathbf{D}_e^{-1}\mathbf{H}^T\mathbf{D}_v^{-\frac{1}{2}}$  作为超图卷积核提取图节点特征;  $\mathbf{M}$  表示超图权重的可学习对角矩阵, 为表示所有超边的权重相等将它初始化为单位矩阵;  $\sigma$  为非线性激活函数。

按式(13)计算时间 Transformer 块的输出特征, 表示为

$$\mathbf{Z} = \mathbf{A}\mathbf{V} \quad (13)$$

式中,  $\mathbf{Z} \in \mathbb{R}^{N \times d_f}$ 。

将  $\mathbf{Z}$  输入空间 Transformer 块中按式(11)一式(13)进行计算, 获取相应的输出特征  $\mathbf{Z}_{sp} \in \mathbb{R}^{N \times d_f}$ 。在实现过程中, 架构中也应用了层归一化、残差连接和多头机制。

最后, 将经过多层由时间和空间 Transformer 块构成的层结构输出  $\mathbf{Z}_{final} \in \mathbb{R}^{N \times d_f}$ , 输入一个全连接的回层(fully connected layer, FC)预测故障类型  $\mathbf{P} \in \mathbb{R}^{1 \times 12}$ , 其中维度 12 代表本文需要预测的故障类型总数。

$$\mathbf{P} = \text{FC}(\mathbf{Z}_{final}) \quad (14)$$

## 4 二次设备故障诊断

### 4.1 数据预处理

为了提高模型的精度, 降低数据差异化的影响, 利用 Min-Max 法对输入数据进行归一化处理<sup>[21]</sup>。

Min-Max 法转换函数如式(15)所示。

$$X'_a = \frac{X_a - X_{\min}}{X_{\max} - X_{\min}} \quad (15)$$

式中,  $X_{\max}$ 、 $X_{\min}$  分别表示数据集中最大、最小值。该函数可以对数据集中任一数据  $X_a$  进行线性变换, 经变换后数据  $X'_a$  的取值在  $[0,1]$  范围内。

按照经验公式, 为避免欠拟合或过拟合, 隐藏层神经元个数一般设置为

$$\begin{cases} V = \sqrt{(h+q)} + \gamma \\ V = \log_2(h) \end{cases} \quad (16)$$

式中:  $V$  为隐藏层神经元个数;  $h$  为输入层神经元个数;  $q$  为输出层神经元个数<sup>[22]</sup>;  $\gamma$  为随机常数,  $\gamma \in [1,10]$ 。

### 4.2 故障诊断过程

二次设备故障诊断过程如图 6 所示, 具体诊断步骤如下。

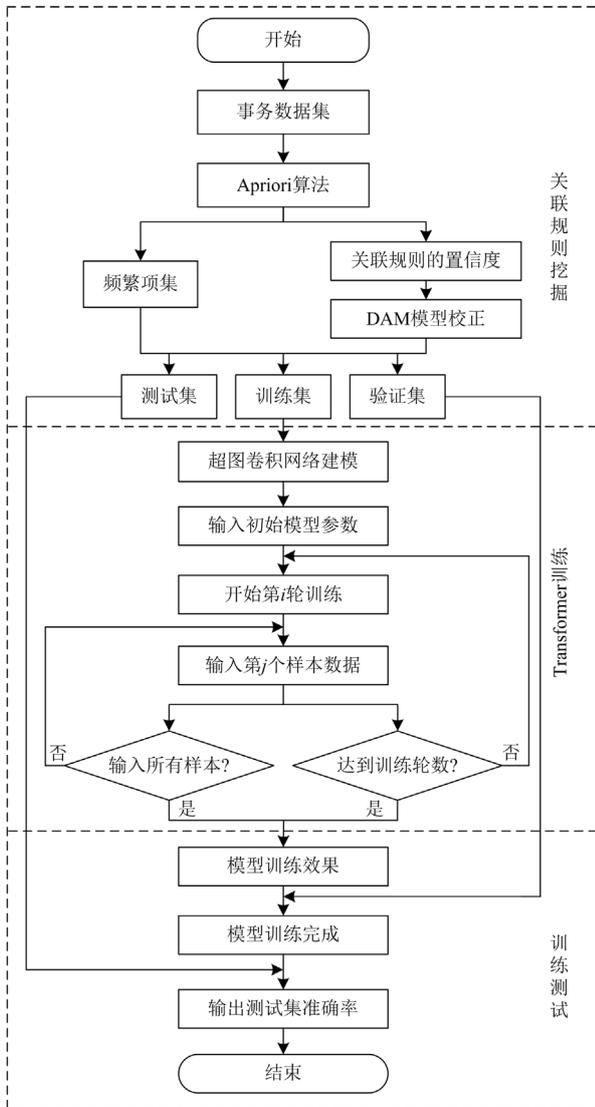


图 6 故障诊断流程

Fig. 6 Fault diagnosis process

1) 采集历史二次设备故障数据, 建立二次设备故障特征信息的事务数据集, 选择训练样本, 利用 Apriori 算法根据设定的最小支持度、最小置信度生成频繁项集及关联规则的置信度。

2) 依据 DAM 模型提取关联规则中逻辑节点之间的关系:

若逻辑节点之间为单一源关系, 利用式(3)、式(4)校正故障元件的置信度;

若逻辑节点之间为同源关系, 利用式(5)一式(7)校正故障元件的置信度;

若逻辑节点之间为上层同源关系, 利用式(8)、式(9)校正故障元件的置信度。

3) 根据关联规则构建关系超图, 并执行超图卷积网络对异常告警信息与故障类型间的高阶关系建模。

4) 根据关系超图, 基于 Transformer 网络进一步捕捉故障特征的上下文信息。

5) 设定模型参数, 使用训练集对上述模型进行训练, 直至收敛。

6) 将测试集数据送入模型中, 得到故障诊断结果。

## 5 算例分析

### 5.1 数据处理

本文以二次回路典型间隔为例, 间隔内的二次设备包括保护装置、合并单元、智能终端、智能录波器等<sup>[23]</sup>, 采集某区域电网近一年内的 22 830 条二次设备运行数据, 对异常告警信息和故障类型相关数据进行梳理分析, 用 T、V、E、H、F 分别指代自检告警信息、SV 通道告警信息、GOOSE 通道告警信息、采样告警信息、故障类型, 对采集的数据进行筛选和整理, 如表 1 所示。

表 1 原始数据表

Table 1 Raw data table

T	V	E	H	F
自检异常	SV 总告警	GOOSE 总告警	PT 断线	合并单元 DSP 模块故障
同步异常	SV 采样链路中断	GOOSE 数据异常	CT 断线	GOOSE 插件故障
装置闭锁	采集端口通信中断	GOOSE 链路中断	CT 断线	CT 端子箱端子不紧固
自检异常	SV 采样数据异常	采集端口通信中断	—	纵联通道故障
装置闭锁	SV 总告警	GOOSE 数据异常	同期电压异常	合并单元配置错误
⋮	⋮	⋮	⋮	⋮

为了提高数据挖掘效率, 针对原始数据建立事务数据集。分别用  $T_n$ 、 $V_n$ 、 $E_n$ 、 $H_n$ 、 $F_n$  代表相应数据类型下具体的子类型,  $n$  为子类型的编号, 如  $T_1$  代表“自检告警信息”类中的“自检异常”。

依据表 1 的原始数据将事务数据集转化为事实表, 对事实表进行布尔编码。如表 2 所示, 表中每一行代表一个事务, 每一列代表一个项目, 数字 1 指事务中出现该项目, 数字 0 指事务中没有该项目。

表 2 事实表

Table 2 Fact table

序号	$T_1$	$T_2$	$T_3$	$T_4$	$V_1$	$V_2$	$V_3$	$V_4$	$E_1$	$E_2$
1	1	0	1	0	1	1	1	0	1	0
2	0	1	0	0	0	1	0	1	0	0
3	1	1	1	0	1	0	0	0	0	1
4	0	0	0	0	1	0	0	1	1	1
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

序号	$E_3$	$E_4$	$H_1$	$H_2$	$H_3$	$H_4$	$F_1$	$F_2$	$F_3$	$F_4$
1	1	0	0	0	0	1	1	1	0	0
2	0	1	1	1	0	0	0	0	0	0
3	0	1	0	0	1	1	1	0	0	1
4	1	0	1	1	0	0	0	0	0	0
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

需要说明的是, 故障类型在二次设备故障数据中并未直接给出, 需要通过以下方式获取。

1) 自检类: DAM 模型中的 IED 装置类型+以“xx 插件/模块故障”命名的异常告警信息, 如“合并单元 DSP 模块故障”;

2) 定检类: 智能录波器人工定检报告文件中的“检查结果”, 如“CT 端子箱端子不紧固”;

3) 推理类: 故障检修记录文档中的“原因分析”, 如“35 kVxx 线 333 断路器保护装置 CPU 插件故障, 导致 35 kVxx 线路保护采样异常”, 此类故障类型需要进行信息抽取和人工校验, 得到“断路器保护 CPU 插件故障”和“线路保护采样异常”。

## 5.2 实验结果

### 5.2.1 关系挖掘参数设置

针对 22 830 条原始数据集, 取前 13 698 组数据作为训练集, 中间 4566 组数据作为验证集, 后 4566 组数据作为测试集。依据 Apriori 算法进行关联规则挖掘时, 最小支持度和最小置信度的值对最终故障诊断的准确率有较大影响。为了保证故障诊断有最高的准确性, 从上述训练样本中选取前 1800 组平均分成 3 组, 得到 3 个实验数据集, 探索合适的最小支持度、最小置信度, 结果分别如图 7、图 8 所示。

从图 7、图 8 可知, 随着最小支持度、最小置

信度值的增加, 故障诊断准确率均呈现先上升后下降的趋势, 当最小支持度为 0.6、最小置信度为 0.75 时, 数据集 1—3 的故障诊断准确率均为最大。所以试验中最小支持度设为 0.6、最小置信度设为 0.75。

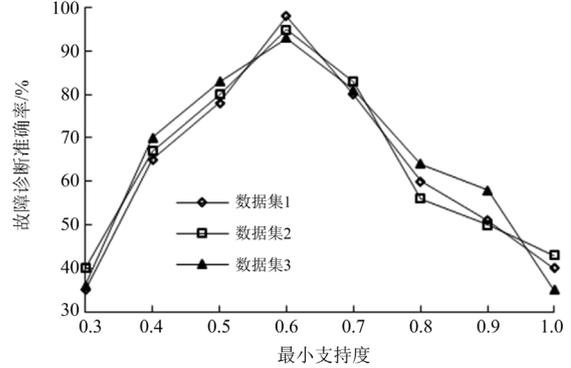


图 7 最小支持度对故障诊断准确率的影响

Fig. 7 Influence of minimum support on fault diagnosis accuracy

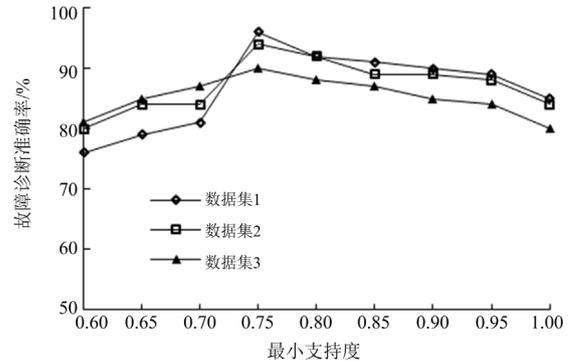


图 8 最小置信度对故障诊断准确率的影响

Fig. 8 Influence of minimum confidence on fault diagnosis accuracy

将二次设备故障特征信息与故障区域对应的变量结合, 形成事务数据集。二次设备故障特征信息与故障区域作为事务数据集的前项与后项, 分析它们之间的相关性, 利用 Apriori 算法搜索满足最小支持度、最小置信度的频繁项集, 生成关联规则, 根据 DAM 模型确定关联规则中故障区域内的逻辑关系, 依据式(3)一式(9), 校正故障元件的置信度, 最终得到 67 条关联规则, 选取其中置信度较高的 12 条展示如表 3 所示。

### 5.2.2 关系超图增强 Transformer 参数设置

将关联规则和经 DAM 模型校正的结果作为输入向量导入到关系超图增强 Transformer 中, 并将故障类型进行编码, 故障类型编码如表 4 所示。

选取的训练样本中, 作为输入的异常告警信息有 64 种元素, 需要预测的输出故障类型有 12 种。本文

表 3 故障特征信息与故障类型的关联规则

Table 3 Association rule between fault characteristics and fault types

编号	故障特征信息	故障类型	校正的置信度/%
1	T <sub>1</sub> 、T <sub>2</sub> 、T <sub>3</sub> 、V <sub>1</sub>	合并单元 DSP 模块故障	87
2	T <sub>3</sub> 、E <sub>2</sub> 、E <sub>4</sub>	智能终端配置错误	84
3	T <sub>3</sub> 、V <sub>3</sub> 、E <sub>1</sub> 、E <sub>3</sub>	线路保护 SV 插件故障	83
4	T <sub>1</sub> 、T <sub>3</sub> 、V <sub>1</sub> 、V <sub>3</sub>	合并单元配置错误	83
5	T <sub>1</sub> 、T <sub>3</sub> 、V <sub>1</sub> 、E <sub>1</sub> 、	合并单元 I/O 模块异常	80
6	V <sub>4</sub> 、E <sub>4</sub>	纵联通道故障	80
7	T <sub>1</sub> 、T <sub>3</sub> 、V <sub>1</sub> 、V <sub>3</sub> 、E <sub>1</sub>	智能终端 I/O 模块异常	79
8	T <sub>2</sub> 、T <sub>3</sub>	线路保护 CPU 插件故障	79
9	T <sub>3</sub> 、V <sub>3</sub> 、E <sub>1</sub>	线路保护 GOOSE 插件故障	77
10	T <sub>1</sub> 、T <sub>3</sub> 、V <sub>1</sub> 、V <sub>3</sub>	合并单元采样模块故障	76
11	E <sub>1</sub> 、E <sub>2</sub> 、E <sub>4</sub>	线路保护配置错误	76
12	T <sub>3</sub> 、V <sub>1</sub> 、V <sub>2</sub> 、E <sub>1</sub> 、E <sub>2</sub>	线路保护 I/O 模块异常	75

表 4 故障类型编码

Table 4 Fault location code

编号	故障类型	编号	故障类型
1	合并单元 DSP 模块故障	7	线路保护 I/O 模块异常
2	合并单元 I/O 模块异常	8	线路保护 GOOSE 插件故障
3	合并单元配置错误	9	线路保护 SV 插件故障
4	合并单元采样模块故障	10	智能终端配置错误
5	线路保护配置错误	11	智能终端 I/O 模块异常
6	线路保护 CPU 插件故障	12	纵联通道故障

设置超图卷积神经网络的层数为 2，而 Transformer 为标准结构。试验中对模型性能观察，超图卷积的神经元最终调整为 20 维。此外，兼顾模型稳定性与训练效果，模型训练阈值设为 0.5。

将上述相关数据代入式(10)一式(14)，经过层层迭代生成输出层结果。通过调整初始学习率、隐藏层数优化网络，迭代次数设为 2000 次，将最终故障诊断的准确率作为评判标准，具体结果如图 9、图 10 所示。

由图 9 可知，对比超图卷积层数分别为 1、2、3 时的准确率，当隐藏层数为 2 时，故障诊断准确率明显偏高；对比初始学习率分别为 0.01、0.05、0.1、0.5 时的准确率，当初始学习率为 0.5 时，故障诊断准确率明显偏高。因此，本文设定隐藏层数为 2，初始学习率为 0.5。

由图 10 可知，在不同初始学习率下，模型输出的故障诊断准确率结果最终都会收敛。当其值为 0.5 时收敛速度最快，当迭代次数达到 7000 时，故障诊

断准确率都趋于平稳，考虑模型的训练效率，迭代次数最终选为 5000 次。

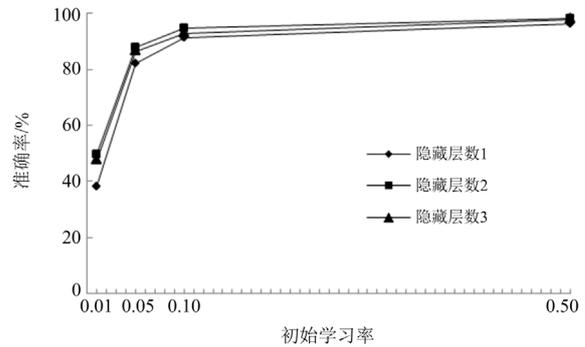


图 9 不同参数下的故障诊断准确率

Fig. 9 Fault diagnostic accuracy under different parameters

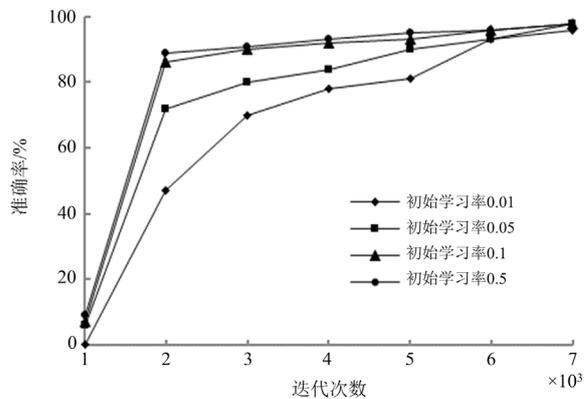


图 10 网络优化情况

Fig. 10 Network optimization situation

### 5.2.3 模型整体性能对比

为验证本文所提模型的性能，将测试集数据分别输入本领域常用的支持向量机(support vector machine, SVM)、循环神经网络(recurrent neural network, RNN)、深度神经网络(deep neural network, DNN)、Transformer 网络等模型、本文模型中，设置隐藏层数、迭代次数等主要参数均一致，用“错判数”表示输出错误故障类型的次数，“准确率”表示输出故障类型和与之关联的故障特征信息的综合正确率，结果如表 5 所示。

由表 5 可知，在相同的测试集中，本文模型的故障诊断准确率至少提高了 8%，说明基于关系超图 Transformer 网络对智能站复杂网络环境下二次设备的故障特征辨识精度有较大提升。而由表 6 可知，在推理用时方面本文模型与 SVM、RNN 等模型的差距很小，但准确率的提高能够有效减少人工干预的耗时，从而提高故障处理的整体效率。

表 5 不同模型训练效果

Table 5 Training effects of different models

故障 编号	SVM 错判数	RNN 错判数	DNN 错判数	Transformer 错判数	本文模型 错判数	准确率/%				
						SVM	RNN	DNN	Transformer	本文模型
1	54	15	17	8	2	43.32	85.26	84.04	90.25	98.36
2	50	16	20	9	1	48.16	82.09	80.51	90.06	99.04
3	50	20	21	10	0	47.85	80.36	80.02	88.86	98.39
4	55	26	18	7	1	43.18	78.45	86.79	91.02	98.61
5	53	19	13	8	1	46.52	81.72	87.92	91.56	99.71
6	54	28	17	9	2	44.39	73.57	84.51	91.34	98.06
7	51	29	24	11	0	49.03	70.31	78.83	87.32	99.03
8	49	17	15	5	0	50.15	81.92	85.26	92.37	98.47
9	50	21	16	6	1	47.35	80.15	85.03	91.48	99.25
10	55	25	17	6	1	44.20	79.82	84.33	91.16	98.07

表 6 不同模型推理用时

Table 6 Inference time of different models

模型	推理用时
人工干预	23.5 h
SVM	0.13 s
RNN	0.19 s
DNN	0.17 s
Transformer	0.25 s
本文模型	0.25 s

## 6 结论

针对智能变电站海量、驳杂、离散的异常告警信息, 本文提出的基于关系超图 Transformer 的二次设备故障诊断算法, 克服了故障诊断过程中信息质量不确定、复杂告警信息关联不明确等问题, 实现准确定位故障元件和诊断故障类型, 主要结论如下所述。

1) 基于 Apriori 算法对二次设备故障特征信息进行筛选, 有效去除冗余信息干扰, 可以建立故障特征信息与故障区域之间的关联规则。

2) 根据 DAM 模型中的逻辑关系, 可以校正故障区域中故障元件的置信度, 还可以排除关联规则中误报的故障特征信息。

3) 将关联规则输入超图, 可以对智能站二次设备故障特征信息间的复杂高阶关系进行建模。

4) 与常规深度学习模型相比, 使用 Transformer 可以捕捉到丰富的上下文信息, 具有更高的故障诊断准确率。

## 参考文献

[1] 卓振宇, 张宁, 谢小荣, 等. 高比例可再生能源电力系统关键技术及发展挑战[J]. 电力系统自动化, 2021, 45(9): 171-191.  
ZHUO Zhenyu, ZHANG Ning, XIE Xiaorong, et al. Key technologies and developing challenges of power system with high proportion of renewable energy[J]. Automation of Electric Power Systems, 2021, 45(9): 171-191.

[2] TAVAKOLI M, NAFAR M. Human reliability analysis in maintenance team of power transmission system protection[J]. Protection and Control of Modern Power Systems, 2020, 5(4): 270-282.

[3] 张宸滔, 郑永康, 卢继平, 等. 基于图神经网络的智能变电站二次回路故障定位研究[J]. 电力系统保护与控制, 2022, 50(11): 81-90.  
ZHANG Chentao, ZHENG Yongkang, LU Jiping, et al. Fault location of secondary circuits in a smart substation based on a graph neural network[J]. Power System Protection and Control, 2022, 50(11): 81-90.

[4] 尹相国, 张文, 路致远, 等. 面向智能变电站二次设备的故障诊断方法研究[J]. 电测与仪表, 2020, 57(3): 39-45.  
YIN Xiangguo, ZHANG Wen, LU Zhiyuan, et al. Research on fault diagnosis method for secondary equipment of intelligent substation[J]. Electrical Measurement & Instrumentation, 2020, 57(3): 39-45.

[5] 闫梦秋, 杨轶俊, 赵航. 基于改进 OCSVM 的智能变电站数据流异常检测方法研究[J]. 电力系统保护与控制, 2022, 50(6): 100-106.  
YAN Mengqiu, YANG Yijun, ZHAO Fang. A data stream anomaly detection method based on an improved OCSVM smart substation[J]. Power System Protection and Control, 2022, 50(6): 100-106.

[6] 王洪彬, 徐亨, 童晓阳, 等. 基于结构熵权法与故障树的智能变电站保护系统扰动度在线评估方法[J]. 电网技术, 2019, 43(5): 1772-1787.  
WANG Hongbin, XU Heng, TONG Xiaoyang, et al. The online disturbance degree assessment method of protection systems in intelligent substation based on the structure entropy weight method and fault trees[J]. Power System Technology, 2019, 43(5): 1772-1787.

[7] 李祖明, 孙仲明, 顾桥根, 等. 基于继电保护装置态势感知及辅助决策的智能运维系统[J]. 电力系统保护与控制, 2020, 48(19): 142-150.  
LI Zuming, SUN Zhongming, GU Qiaogen, et al. Smart operation and maintenance system based on situational awareness and assistant decision-making of relay protection devices[J]. Power System Protection and Control, 2020,

- 48(19): 142-150.
- [8] 王文焕, 郭鹏, 祝洁, 等. 基于故障树及贝叶斯网络的继电保护系统风险评估及故障定位方法[J]. 电力科学与技术学报, 2021, 36(4): 81-90.  
WANG Wenhuan, GUO Peng, ZHU Jie, et al. Fault positioning and risk assessment method of relay protection based on fault tree and Bayesian network[J]. Journal of Electric Power Science and Technology, 2021, 36(4): 81-90.
- [9] 曹磊, 徐磊, 杨菲, 等. 基于关联规则挖掘的路面损坏状况影响因素分析[J]. 计算机系统应用, 2021, 30(1): 186-193.  
CAO Lei, XU Lei, YANG Fei, et al. Influencing factors analysis of pavement damage based on mining association rules[J]. Computer Systems & Applications, 2021, 30(1): 186-193.
- [10] 黄剑湘, 林铮, 刘可真, 等. 考虑换流站海量事件的关联规则挖掘分析方法[J]. 电力系统保护与控制, 2022, 50(12): 117-126.  
HUANG Jianxiang, LIN Zheng, LIU Kezhen, et al. Association rule mining analysis method considering massive events in a converter station[J]. Power System Protection and Control, 2022, 50(12): 117-126.
- [11] 徐洲常, 王林军, 刘晋玮, 等. 基于多层降噪处理的轴承故障特征提取方法[J]. 机床与液压, 2021, 49(16): 174-179.  
XU Zhouchang, WANG Linjun, LIU Jinwei, et al. Bearing fault feature extraction method based on multi-layer noise reduction[J]. Machine Tool & Hydraulics, 2021, 49(16): 174-179.
- [12] GUO Junchao, SHI Zhanqun, ZHEN Dong, et al. Modulation signal bispectrum with optimized wavelet packet denoising for rolling bearing fault diagnosis[J]. Structural Health Monitoring, 2022, 21(3): 984-1011.
- [13] 黄迅迪, 庞雄文. 基于深度学习的智能设备故障诊断研究综述[J]. 计算机科学, 2023, 50(5): 93-102.  
HUANG Xundi, PANG Xiongwen. Review of intelligent device fault diagnosis based on deep learning[J]. Computer Science, 2023, 50(5): 93-102.
- [14] FAN Litao, NIE Ding, JIANG Jigang. Research on fault location in distribution networks based on graph convolutional neural networks[C]//IEEE 3rd International Conference on Electrical Engineering, Big Data and Algorithms (EEBDA), February 27-29, 2024, Changchun, China: 192-196.
- [15] LIAO Xiaowei, XU Yong, LING Haibin. Hypergraph neural networks for hypergraph matching[C]//IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada: 1246-1255.
- [16] SUN Lina. An improved Apriori algorithm based on support weight matrix for data mining in transaction database[J]. Journal of Ambient Intelligence and Humanized Computing, 2020, 11(2): 495-501.
- [17] 周家玉, 侯慧娟, 盛戈峰, 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.
- [18] 俞伊丽, 张展耀, 接晓霞, 等. 基于知识图谱与SCD文件的智能变电站二次检修安全措施自动生成技术研究[J]. 电力系统保护与控制, 2024, 52(2): 129-142.  
YU Yili, ZHANG Zhanyao, JIE Xiaoxia, et al. Automatic generation technology of secondary safety measures in an intelligent substation based on a knowledge graph and SCD files[J]. Power System Protection and Control, 2024, 52(2): 129-142.
- [19] 陈蒙蒙, 乔志伟. 基于融合通道注意力的Uformer的CT图像稀疏重建[J]. 计算机应用, 2023, 43(9): 2948-2954.  
CHEN Mengmeng, QIAO Zhiwei. Sparse reconstruction of CT images based on Uformer with fused channel attention[J]. Journal of Computer Applications, 2023, 43(9): 2948-2954.
- [20] LIM B, ARIK S O, LOEFF N, et al. Temporal fusion transformers for interpretable multi-horizon time series forecasting[J]. International Journal of Forecasting, 2021, 37(4): 1748-1764.
- [21] 李海勇, 田君杨, 蒋连钊, 等. 云边协同的集控式继电保护设备智能运维方法[J]. 电力信息与通信技术, 2021, 19(10): 38-45.  
LI Haiyong, TIAN Junyang, JIANG Liandian, et al. Centralized intelligent operation and maintenance method of relay protection equipment based on cloud-edge collaboration[J]. Electric Power ICT, 2021, 19(10): 38-45.
- [22] 张全明, 兰泉妮, 刘柳君, 等. 基于组合赋权-云模型的广义需求侧资源网荷互动水平评估[J]. 武汉大学学报(工学版), 2023, 56(6): 717-724.  
ZHANG Quanming, LAN Quanni, LIU Liujun, et al. Grid-load interactive level evaluation of generalized demand-side resources based on combination weighting-cloud model[J]. Engineering Journal of Wuhan University, 2023, 56(6): 717-724.
- [23] 叶远波, 李端超, 谢民, 等. 基于知识图谱的二次设备测试自动配置方法[J]. 电力系统保护与控制, 2022, 50(12): 162-171.  
YE Yuanbo, LI Duanchao, XIE Min, et al. Automatic configuration method of secondary equipment test based on a knowledge graph[J]. Power System Protection and Control, 2022, 50(12): 162-171.

收稿日期: 2023-11-19; 修回日期: 2024-04-25

作者简介:

周海成(1983—), 男, 硕士, 高级工程师, 研究方向为电力系统继电保护与控制; E-mail: ppcczhc@163.com

石恒初(1983—), 男, 硕士, 高级工程师, 研究方向为电力系统继电保护管理; E-mail: 93324244@qq.com

曾令森(1986—), 男, 通信作者, 本科, 高级工程师, 研究方向为电力系统调度自动化。E-mail: 284436007@qq.com

(编辑 许威)