

http://bhxb.buaa.edu.cn jbuua@buaa.edu.cn

DOI: 10.13700/j.bh.1001-5965.2022.0801

基于时序知识图谱的电力设备缺陷预测

纪鑫^{1,2}, 武同心^{1,*}, 杨智伟¹, 余婷¹, 李君婷¹, 何禹德¹

(1. 国家电网有限公司大数据中心, 北京 100031; 2. 北京航空航天大学 计算机学院, 北京 100191)

摘 要: 随着电力设施规模的日渐增长, 对于电力设备的运行监测成为电力系统管理的一个重要内容。电力设备的缺陷预测是电力系统运行监测的关键步骤。为解决对大规模电力系统中的电力设备进行缺陷预测的问题, 结合人工智能技术, 提出一种基于时序知识图谱的电力设备缺陷预测模型。通过注意力机制对多模态信息进行融合, 利用关系感知的图神经网络和循环神经网络得到实体和关系的时序表示, 基于时序表示对电力设备进行缺陷预测。提出基于图神经网络的时序知识图谱推理方法能够充分利用多模态信息, 提升电力设备缺陷预测的准确率。实验表明: 所提模型性能优于基线模型。

关键词: 时序知识图谱; 图神经网络; 缺陷预测; 电力系统; 电力设备

中图分类号: TM933

文献标志码: A

文章编号: 1001-5965(2024)10-3131-08

电力网络的高速发展及其规模的逐渐增大对电力设备的可靠性提出了更高的要求, 对于潜在的电力设备缺陷及早地发现显得尤为重要^[1]。面向电网运行积累的大量设备运维数据, 深入挖掘设备运维数据特征, 感知设备运行态势, 是新型电力系统精细化发展的重要方向。针对电力设备的缺陷预测需要全面地掌握电力设备的各种运行数据与环境参数, 以便对其运行状态进行合理的评估, 进而预测可能发生的故障。

电力系统中的各种数据和变量常以非结构化的形式存储, 计算机难以理解其中的语义信息。知识图谱是一种将非结构化的知识和数据转化为结构化知识的数据库, 其用图的形式表示知识, 图上的每个节点表示实体, 实体可能会有自己对应的属性和特征; 图上的边表示实体之间的对应关系; 整张知识图谱包含了知识库中所有知识的映射, 并能很好地被计算机所理解。近年来, 知识图谱被成功地应用于搜索^[2]、推荐^[3]和问答系统^[4]等任务中。

上述知识图谱只关注静态的信息, 图谱中的关系和节点不会随着时间变化, 然而在现实世界中时序信息非常重要, 很多结构和关系只在特定时间段中有效。将时序信息融入到知识图谱中, 这样的知识图谱称为时序知识图谱, 也就是说, 时序知识图谱将静态知识图谱的三元组扩充为四元组, 在每一个时间片上都存在一个静态图谱。与普通知识图谱相比, 时序知识图谱增加了一个时间维度, 能够更好地建模现实世界中的知识。

针对电力设备的缺陷预测问题, 本文将其转换为时序知识图谱上的链接预测(推理)问题。将电力设备和可能发生的缺陷抽象为知识图谱上的节点, 将设备与其发生的历史缺陷之间的对应关系抽象为知识图谱之间的关系, 另外, 将电力设备的属性、运行状态等信息作为节点的多模态属性。通过对这样的知识图谱进行学习, 预测电力设备节点在未来时刻与缺陷节点之间可能存在的链接, 完成对相应电力设备的缺陷预测, 另外, 由于电力设备缺

收稿日期: 2022-09-19; 录用日期: 2022-10-03; 网络出版时间: 2023-02-01 16:48

网络出版地址: link.cnki.net/urlid/11.2625.V.20230201.1047.002

基金项目: 国家电网有限公司大数据中心科技项目 (52999021N005)

*通信作者. E-mail: tongxin-wu@sgcc.com.cn

引用格式: 纪鑫, 武同心, 杨智伟, 等. 基于时序知识图谱的电力设备缺陷预测 [J]. 北京航空航天大学学报, 2024, 50 (10): 3131-3138.

Ji X, Wu T X, Yang Z W, et al. Power equipment defect prediction based on temporary knowledge graph [J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50 (10): 3131-3138 (in Chinese).

陷的出现存在时序性,因此,引入时序特征,以形成时序知识图谱,时序特征是离散的,在每一个时间片上都根据之前时间片的信息去预测缺陷。

知识图谱技术是以图形的方式展示实体与属性之间的关系,有效整合数据,形成知识驱动的管理和运行模式,将其应用在电力行业领域,将大量电力数据凭借知识抽取、推理、检索等功能转化为电力知识的应用,实际知识图谱技术就是人工智能与大数据结合的产物。知识图谱链接预测又称知识图谱推理。给定一个知识图谱,知识图谱推理的任务是预测出当前知识图谱缺失的三元组集合。对于时序知识图谱来说,时序知识图谱的推理可以视作在特定时间节点的静态知识图谱进行推理。

由于知识图谱的广泛应用及命名实体识别(named entity recognition, NER)在知识图谱构建中的基础性作用,目前对于NER的研究已经比较成熟,无论是基于规则等的传统NER方法,还是基于深度学习的NER方法,都具有一套相对充分和完整的理论和技术。

另一方面,在电力领域中的设备属性常具有多模态的特性^[5-8],例如,一个电力设备的图片属于视觉模态;电力设备的描述和作用等属于文本模态;电力设备的参数等属于数字模态。如何充分地利用这些多模态信息来得到更具辨识度的实体表示也是缺陷检测任务的关键点。

针对电力设备的缺陷检测任务,本文构造了基于多模态的电力设备缺陷时序知识图谱数据集。其中,包含多个时间段的多种电力设备实体和对应的缺陷类型。每个电力设备还有相对应的多模态属性信息。本文提出一个基于图神经网络的时序知识图谱推理模型,首先,利用注意力机制对实体节点的多模态信息进行融合;其次,利用图神经网络学习节点表示;最后,基于节点对的表示预测电

力设备可能会出现的缺陷。实验结果表明,本文模型性能优于基线模型。

1 电力设备缺陷检测识别框架

1.1 多模态数据融合

如图1所示,本文针对多模态数据提出一种基于注意力机制的特征融合方法。

为获取实体节点的视觉特征,将实体节点的每张图片转换为特征向量。本文使用在Imagenet数据集上预训练过的ResNet50^[9-10]网络来提取图片的特征。ResNet网络中引入了残差链接结构,使得网络可以更深,学习到的特征表达能力更强,本文使用层数为50的网络结构,将最后一层的输出作为图片的特征。总结来说,提取到的视觉特征为

$$E_v = R_{50}(i_{imgi}) \tag{1}$$

式中: E_v 为图片的特征向量; R_{50} 为使用ResNet50网络提取图片特征; i_{imgi} 表示第*i*张图片。

实体节点也存在着许多文本类的特征,如属性描述等信息。为从文本中提取有用的信息,使用预训练语言模型Bert^[11]作为编码器。Bert是2018年Google推出的大规模文本预训练模型。Bert由基于transformer架构的多个encoder block堆叠而成,其在许多nlp任务上的性能都提升明显。相较于传统的word2vec^[12]等算法,经过海量文本预训练的Bert能够在得到的文本表征中引入更多的语义信息,表示能力更强。文本特征为

$$E_t = B_{ert}(t_{exti}) \tag{2}$$

式中: E_t 表示文本的特征向量; B_{ert} 表示使用Bert模型编码文本; t_{exti} 表示第*i*段文本。

数值特征指的是电力设备参数等包含数值的离散信息。首先,需要将离散特征转换为连续的特征表示,径向基函数(radical basis function, RBF)^[13]




图1 多模态数据融合

Fig. 1 Multi-modal data fusion

正好满足本文的需求。RBF 可以拟合任意分布, 具有收敛快、泛化能力强的优点。本文使用的是高斯径向基函数, 设离散的数字特征为 $\mathbf{x}_i$, 则根据 RBF 得到的连续数值特征为

$$\mathbf{E}_n = \phi(r) \mathbf{I} = e^{-(\varepsilon r)^2} \mathbf{I} \quad (3)$$

$$r = \|\mathbf{x} - \mathbf{x}_i\| \quad (4)$$

式中: $\mathbf{E}_n$ 为数值特征向量; $\phi(r)$ 表示 RBF; r 为输入特征与中心特征之间的距离, 表示当前特征值; $\mathbf{I}$ 为单位向量; $\mathbf{x}_i$ 为第 i 个中心特征值; ε 为 RBF 的参数。

除众多的属性特征之外, 实体节点本身也具有相应的特征表示, 对于这一类的特征, 使用随机初始化的特征嵌入 $\mathbf{E}_e$ 表示。相应的, 也对关系设置了相应的嵌入向量 $\mathbf{R}$ 。

在得到上述多模态特征之后, 需要考虑如何有效地将多模态信息融合。考虑到不同模态的特征位于不同的表征空间中, 因此, 本文利用变换矩阵将不同模态的信息变换到同一表征空间中:

$$\mathbf{E}'_v = \mathbf{W}_v \mathbf{E}_v + \mathbf{b}_v \quad (5)$$

$$\mathbf{E}'_t = \mathbf{W}_t \mathbf{E}_t + \mathbf{b}_t \quad (6)$$

$$\mathbf{E}'_n = \mathbf{W}_n \mathbf{E}_n + \mathbf{b}_n \quad (7)$$

$$\mathbf{E}'_e = \mathbf{W}_e \mathbf{E}_e + \mathbf{b}_e \quad (8)$$

式中: $\mathbf{E}'_v$ 、 $\mathbf{E}'_t$ 、 $\mathbf{E}'_n$ 、 $\mathbf{E}'_e$ 表示经过线性变换后的特征向量; $\mathbf{W}_v$ 、 $\mathbf{W}_t$ 、 $\mathbf{W}_n$ 、 $\mathbf{W}_e$ 表示特征变换的权重矩阵; $\mathbf{b}_v$ 、 $\mathbf{b}_t$ 、 $\mathbf{b}_n$ 、 $\mathbf{b}_e$ 表示特征变换的偏置项。

使用一个基于注意力^[14]的融合机制聚合所有特征:

$$(\alpha'_v, \alpha'_t, \alpha'_n, \alpha'_e) =$$

$$\text{Softmax}(\mathbf{a}^T \mathbf{E}'_v, \mathbf{a}^T \mathbf{E}'_t, \mathbf{a}^T \mathbf{E}'_n, \mathbf{a}^T \mathbf{E}'_e) \quad (9)$$

式中: α'_v 、 α'_t 、 α'_n 、 α'_e 为注意力系数; $\mathbf{a}^T$ 为可学习的注意力向量。最终的融合的特征为

$$\mathbf{E} = \alpha'_v \mathbf{E}'_v + \alpha'_t \mathbf{E}'_t + \alpha'_n \mathbf{E}'_n + \alpha'_e \mathbf{E}'_e \quad (10)$$

1.2 时序知识图谱推理

图 2 为时序知识图谱推理, 主要包括节点表示学习和时序特征建模 2 个部分。

由于知识图谱是一个图结构, 近年来, 随着图神经网络的兴起, 有很多关于知识图谱推理的研究将图神经网络应用于模型中^[14-18], 本文使用关系图神经网络 (relational graph convolutional network, RGCN)^[18]来学习每个时间戳中静态知识图谱的实体表示。RGCN 相比于传统的图神经网络模型, 增加了对关系数据的建模, 其计算过程为




图 2 时序知识图谱推理

Fig. 2 Temporary knowledge graph completion

$$\mathbf{h}_i^{l+1} = \sigma(\mathbf{W}_0^l \mathbf{h}_i^l + \sum_{r \in M} \sum_{j \in P(i)} \frac{1}{|P(i)|} \mathbf{W}_r^l \mathbf{h}_j^l) \quad (11)$$

式中: $\mathbf{h}_i^{l+1}$ 为第 $l+1$ 层的节点; $\mathbf{h}_j^l$ 为经过第 l 层 RGCN 计算之后的节点; σ 为激活函数; $\mathbf{W}_0^l$ 和 $\mathbf{W}_r^l$ 为第 l 层的权重矩阵; $\mathbf{W}_r^l$ 为对不同关系的映射; M 为关系集合; $P(i)$ 为与节点 i 相邻的节点集合。

经过 RGCN 层之后, 得到图谱中每个节点的更新表示。考虑到时序信息, 本文选择序列模型循环神经网络 (recurrent neural network, RNN)^[19]来建模时序关系:

$$\mathbf{N}_t = \mathbf{R}_{\text{NN}}(\mathbf{N}_{t-1}, \mathbf{h}_t^e) \quad (12)$$

$$\mathbf{R}_t = \mathbf{R}_{\text{NN}}(\mathbf{R}_{t-1}, \mathbf{h}_t^r) \quad (13)$$

式中: $\mathbf{N}_t$ 和 $\mathbf{R}_t$ 分别为第 t 个时间段的实体表示矩阵和关系表示矩阵。

基于成对的节点表示, 本文将电力设备实体节点与缺陷实体节点之间的链接存在性的条件概率建模为

$$p(o|s, r, \mathbf{N}_t, \mathbf{R}_t) = \sigma(\mathbf{N}_t \phi(s, r, \mathbf{r}_t)) \quad (14)$$

式中: s 为头实体, 即电力设备节点; $\phi(s, r, \mathbf{r}_t)$ 表示三元组评分函数; o 为尾实体, 即缺陷节点; σ 为 sigmoid 函数:

$$\sigma = \frac{1}{1 + e^{-x}} \quad (15)$$

1.3 损失函数

使用交叉熵损失函数来进行端到端的模型优化, 具体的损失函数如下:

$$L = \sum_t \sum_{e \in \mathcal{E}} \sum_{i \in V} y_{t+1,i} \log_2 p_i(o|s, r, \mathbf{N}_t, \mathbf{R}_t) \quad (16)$$

式中: $\mathcal{E}$ 为时间片集合; V 为节点集合; $y_{t+1,i}$ 为真实标签; $p_i(o|s, r, \mathbf{N}_t, \mathbf{R}_t)$ 为模型预测的条件概率。

2 数据集与实验设置

本文使用的数据集来自公司的电力设备缺陷事件,这其中存在着多模态数据,还有时间序列信息,因此,本文将其建模为时序的多模态图谱,每个时间片上都是一个静态的多模态知识图谱。

具体来说,在时间片 τ 对应的多模态知识图谱,包含电力设备的多模态信息(如设备图片、参数等)及设备缺陷等,任务目标是根据过去时间片的图谱信息去预测未来某个时间片上电力设备可能发生的缺陷。

2.1 数据预处理

数据集中大部分的数据都存在着数据格式不统一的问题。为后续的模式学习,需要对数据进行必要的清洗。

1) 图像数据预处理。在电力领域的多模态知识图谱中,图片的尺寸和分辨率的分布常是不一致的^[20-23]。另一方面,由于拍摄设备的限制,图片所表示的实体可能在图片中所占的比例很小。因此,先将所有图像统一裁剪到 224 像素×224 像素大小,再将图片输入到目标检测网络中,将目标实体所在的图片区域作为最终的图像数据。

2) 文本数据预处理。数据集中的文本数据存在着大量的噪声,如特殊符号等。先利用 Nltk 工具去除文本中的所有特殊字符,去除标点符号。由于预训练语言模型对于输入的长短有限制,所以还对所有文本进行截断处理,超出限制最长的文本只保留前缀。

3) 数值数据预处理。针对电力设备的属性等离散的数值特征,先进行预处理,去除无关的文本字符,后对所有数值进行正规化,防止出现偏离过多的数值对模型学习造成不良的影响。

2.2 数据统计

经过预处理之后,本文构建了用于缺陷检测的时序多模态知识图谱,对数据集进行了初步的统计。如表 1 所示,本文的知识图谱包含 7 个时间段的 2 106 个三元组,其中,每个三元组包含电力设备机器及其产生的缺陷类型。

图谱的总体统计如表 2 所示,图谱共包含三元组 4 488 个,共包含 2 463 个实体节点(电力设备节点和缺陷节点),还包含 3 077 条多模态属性。

为方便模型学习与验证,将完整的数据集按照边划分为训练集、验证集和测试集,总的比例为 6:2:2。

2.3 实验设置

本文所有模型与实验都是基于 Pytorch, Pytorch 是一个具有自动求导功能的开源深度学习框架^[24-26]。

表 1 电力设备及其缺陷类型

Table 1 Electrical equipment and type of defect event			
序号	电力设备	缺陷类型	三元组数量
1	主变压器	堵塞,进水,污秽,滑档,生锈,喷油,油温过高,漏油等	1 147
2	变压器	堵塞,进水,污秽,滑档,生锈,喷油,油温过高,漏油等	534
3	联变变压器	生锈,无油位,无防雨罩,未绝缘包扎等	160
4	站用变压器	氧气含量超标	220
5	电抗器	连接处震动,压力低,数据未上传,封堵,硅胶变色,乙炔超标等	1 234
6	高压电抗器	乙炔、甲烷超标,漏油,操作不当等	456
7	干式电抗器	缺少绝缘试验报告	567
8	其他子部件	生锈,缺少实验报告,无防雨罩,脏污,堵塞,封堵不当等	170

表 2 数据类型和数量

Table 2 Type and quantity of dataset		
三元组数	节点数	属性数
4 488	2 463	3 077

Resnet 网络采用的是 Pytorch 官方的实现,并加载了基于 Imagenet 数据集预训练的模型参数。Bert 网络采用的是开源自然语言处理库 Hugging Face,这个库提供了大量预训练语言模型的实现。知识图谱推理方面,本文模型基于官方的 RGCN 代码实现。其中,隐藏层的维度为 256。RNN 基于 Pytorch 的官方实现,隐藏层的维度为 512。

在训练时,每个小批次的训练样本的大小为 64,随机丢弃概率为 0.1, RGCN 的层数为 4, RNN 的层数为 2,总的训练 epoch 数为 100,优化器采用 Adam,为防止过拟合,设置正则化系数为 0.01。同时,本文还采用了 early stop 的策略,当模型在验证集上的表现连续 3 次无法提升时,就提前停止训练。

关于模型的评价指标,本文采用平均排名(mean rank, MR)、平均倒数排名(mean reciprocal ranking, MRR)、击中率排名第 1 的比例(Hits@1)、击中率排名前 10 的比例(Hits@10)这 4 个指标,4 个指标都是在知识图谱推理中常见的评价指标。所有的实验都在 NVIDIA GTX-1080 Ti GPU 上进行训练。详细的模型参数如表 3 所示。

表 3 模型主要参数

Table 3 Main parameters of model		
参数名	参数介绍	参数值
Learning rate	初始学习率	0.05
Total epochs	总训练轮次	50
Dropout rate	随机丢弃概率	0.1
Regularizer	正则化系数	0.01
Batch size	每批次训练样本的大小	64
Num layers	网络层数	4
Hidden dim	隐藏层维度	256

3 实 验

3.1 基线模型

本文选择的基线模型主要包括以下 4 种类型:

1) DisMult 模型^[27]、ConvE 模型^[28]和 RotatE 模型^[29], 这些模型属于静态知识图谱推理方法, 在本文实验中, 被应用于每个时间戳对应的静态知识图谱, 然后做出预测;

2) TA-DistMult 模型^[30]和 HyTE 模型^[31], 是基于插值设置的时序知识图谱推理模型;

3) Dyngraph2vecAE 模型^[32]、tNodeEmbed 模型^[33]、EvolveGCN 模型^[34]和 GCRN 模型^[35], 都是基于同构图的外推推理模型;

4) Know-Evolve 模型^[36]、DyRep 模型^[37]和 RE-Net 模型^[38], 是外推式的时序知识图谱推理模型。

对于所有模型都使用了相同的多模态信息融合方法, 所有的隐藏层向量的维度大小设置为相同的 256, 以便进行公平的比较。

3.2 主 实 验

对于电力设备缺陷检测的主实验, 将其转换为时序知识图谱的链接预测任务。预处理后的知识图谱先经过基于注意力的信息融合得到初始实体表示, 然后知识图谱通过基线模型和本文模型, 本文使用 MR、MRR、Hits@1、Hits@10 来评测实验效果。

MR 的计算式如下:

$$M_R = \frac{1}{|S|} \sum_{i=1}^{|S|} r_{anki} \tag{17}$$

式中: $|S|$ 为三元组集合的大小; r_{anki} 为第 i 个三元组的排名。

MRR 的计算式如下:

$$M_{RR} = \frac{1}{|S|} \sum_{i=1}^{|S|} \frac{1}{r_{anki}} \tag{18}$$

Hits@ n 表示排名小于 n 的三元组的占比, 计算式如下:

$$H_n = \frac{1}{|S|} \sum_{i=1}^{|S|} \begin{cases} 1 & r_{anki} \leq n \\ 0 & r_{anki} > n \end{cases} \tag{19}$$

为减少实验的偶然性误差, 本文对每一个模型都重复实验了 10 次, 报告 10 次实验的平均值, 如表 4 所示。

从实验结果可知, 相比于基线模型, 本文模型在 MR、MRR、Hits@1、Hits@10 指标上都显著优于其他基线模型, 其值分别为 21.34%、68.22%、57.82% 和 82.50%。通过对实验结果的分析可以得出, 本文

表 4 缺陷检测性能

Table 4 Defect prediction performance

基线模型	MR/%	MRR/%	Hits@1/%	Hits@10/%
DisMult ^[27]	51.37	61.83	50.92	72.38
ConvE ^[28]	33.83	52.11	36.83	69.24
RotatE ^[29]	42.82	44.33	48.85	70.76
TA-DistMult ^[30]	34.23	65.37	53.21	71.72
HyTE ^[31]	42.78	53.49	56.19	72.25
Dyngraph2vecAE ^[32]	36.72	50.02	59.72	70.82
tNodeEmbed ^[33]	41.83	62.38	50.48	71.63
EvolveGCN ^[34]	32.28	62.82	54.05	72.32
GCRN ^[35]	36.83	52.23	51.21	76.22
Know-Evolve ^[36]	44.32	66.73	51.92	75.38
DyRep ^[37]	35.83	54.35	44.83	69.24
RE-Net ^[38]	35.73	68.77	56.48	70.58
本文模型	21.34	68.22	57.82	82.50

模型通过基于注意力机制的多模态信息融合机制学习到多模态的实体信息, 再通过 RGCN 和 RNN 模型学习时序信息, 能够很好地对于电力设备可能发生的缺陷进行预测。

3.3 消融实验

为验证本文模型中各个模块的有效性, 本文进行了消融实验。消融实验是指删除一个模型的一个或多个模块, 并与未消融地模型进行对比实验, 通过比较性能差异来研究深度学习模型中各个组件的必要性。

本文针对模型设置了以下消融实验。首先, 基于注意力的多模态融合, 分别验证图片、文字、数值等多模态信息对模型的影响。其次, 探讨在 RGCN 中是否对不同的关系设置不同的权重。最后, 对上述 2 个组件进行消融实验, 将该模型作为基线模型进行对比分析。

对于每个消融实验, 本文采取了相同的超参数, 每次实验同样重复进行 10 次, 取所有实验结果的平均值作为最终的结果。消融实验的结果如表 5 所示。

从实验结果来看, 视觉、文本、数值等多模态

表 5 消融实验结果

Table 5 Results of ablation experiments

消融模块	MR/%	MRR/%	Hits@1/%	Hits@10/%
基线模型	44.56	49.17	44.58	74.31
只消融视觉模态	42.61	51.23	45.18	75.21
只消融文本模态	28.88	65.17	52.58	79.31
只消融数值模态	29.43	64.76	51.62	78.66
消融RGCN关系矩阵	25.73	66.14	55.91	80.55
完整模型	21.34	68.22	57.82	82.50

信息无论是消融哪个模块,关于电力设备缺陷预测的 MR、MRR、Hits@1、Hits@10 指标均有明显下降,说明多模态信息的引入对于本文模型具有重要的作用。

从多模态信息的比较来看,文本模态对于模型性能的提升作用更加明显,说明了文本信息在本文的缺陷检测任务中更为重要,可能是因为电力设备的文本信息中包含了大量的关于运行状态的信息,这些信息对预测未来时间段内电力设备的预测非常有益,而本文提取文本信息使用的 Bert 预训练模型能够提取蕴含在文本中的有益信息。

在消融了 RGCN 的关系映射矩阵之后,缺陷检测任务的性能下降也比较明显,由于本文不对不同的关系设置不同的映射,那么模型就会对所有关系平等看待,这显然是不合理的,因为来自不同关系的特征对于当前节点的贡献应当不同,实验结果也验证了本文的假设。

4 结 论

1) 本文提出基于图神经网络和时序知识图谱推理的模型在电力设备缺陷检测任务中表现出色。MR 为 21.34%、MRR 为 68.22%、Hits@1 为 57.82%、Hits@10 为 82.50%。

2) 本文提出基于注意力机制的多模态信息融合方法能够有效提升节点表征的表达能力。融合图片、文字、数值等多模态信息后,节点特征更加丰富,有助于提升缺陷检测的准确性。

3) 引入时序特征后,模型能够更准确地预测未来时间段内电力设备可能发生的缺陷。时序信息的引入使模型能够更好地建模电力设备缺陷的时间依赖性,从而提高预测的准确性。通过对比实验可以看出,包含时序特征的模型在各项评价指标上均显著优于不包含时序特征的基线模型。

参考文献 (References)

[1] 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 T J, QIAO J, HAN X, et al. Research and application of artificial intelligence in operation and maintenance for power equipment[J]. High Voltage Engineering, 2020, 46(2): 369-383 (in Chinese).

[2] 田莹, 陈杭雪. 推荐任务中知识图谱嵌入应用研究综述[J]. 计算机科学与探索, 2022, 16(8): 1681-1705.
TIAN X, CHEN H X. Survey on applications of knowledge graph embedding in recommendation tasks[J]. Journal of Frontiers of Computer Science and Technology, 2022, 16(8): 1681-1705 (in Chinese).

[3] 董天波. 基于知识图谱的智能问答系统实现与应用[J]. 数字技术

与应用, 2022, 40(3): 165-167.

DONG T B. Realization and application of intelligent question answering system based on knowledge map[J]. Digital Technology & Application, 2022, 40(3): 165-167 (in Chinese).

[4] LI J, SUN A X, HAN J L, et al. A survey on deep learning for named entity recognition[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(1): 50-70.

[5] 田玲, 张谨川, 张晋豪, 等. 知识图谱综述: 表示、构建、推理与知识超图理论[J]. 计算机应用, 2021, 41(8): 2161-2186.
TIAN L, ZHANG J C, ZHANG J H, et al. Knowledge graph survey: Representation, construction, reasoning and knowledge hypergraph theory[J]. Journal of Computer Applications, 2021, 41(8): 2161-2186 (in Chinese).

[6] 付雷杰, 曹岩, 白瑛, 等. 国内垂直领域知识图谱发展现状与展望[J]. 计算机应用研究, 2021, 38(11): 3201-3214.
FU L J, CAO Y, BAI Y, et al. Development status and prospect of vertical domain knowledge graph in China[J]. Application Research of Computers, 2021, 38(11): 3201-3214 (in Chinese).

[7] 陈烨, 周刚, 卢记冬. 多模态知识图谱构建与应用研究综述[J]. 计算机应用研究, 2021, 38(12): 3535-3543.
CHEN Y, ZHOU G, LU J C. Survey on construction and application research for multi-modal knowledge graphs[J]. Application Research of Computers, 2021, 38(12): 3535-3543 (in Chinese).

[8] 张吉祥, 张祥森, 武长旭, 等. 知识图谱构建技术综述[J]. 计算机工程, 2022, 48(3): 23-37.
ZHANG J X, ZHANG X S, WU C X, et al. Survey of knowledge graph construction techniques[J]. Computer Engineering, 2022, 48(3): 23-37 (in Chinese).

[9] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2015-04-10) [2022-05-10]. <http://arxiv.org/abs/1409.1556>.

[10] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2016: 770-778.

[11] DEVLIN J, CHANG M W, LEE K, et al. BERT: Pre-training of deep bidirectional transformers for language understanding [EB/OL]. (2019-05-24) [2022-05-10]. <http://arxiv.org/abs/1810.04805>.

[12] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space[EB/OL]. (2013-09-17) [2022-05-10]. <http://arxiv.org/abs/1301.3781>.

[13] CHEN S, COWAN C F N, GRANT P M. Orthogonal least squares learning algorithm for radial basis function networks[J]. IEEE Transactions on Neural Networks, 1991, 2(2): 302-309.

[14] CAI L, YAN B, MAI G C, et al. TransGCN: Coupling transformation assumptions with graph convolutional networks for link prediction[C]//Proceedings of the 10th International Conference on Knowledge Capture. New York: ACM, 2019: 131-138.

[15] SHANG C, TANG Y, HUANG J, et al. End-to-end structure-aware convolutional networks for knowledge base completion[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 3060-3067.

[16] NATHANI D, CHAUHAN J, SHARMA C, et al. Learning attention-based embeddings for relation prediction in knowledge graphs

- [EB/OL]. (2019-06-04) [2022-05-10]. <http://arxiv.org/abs/1906.01195>.
- [17] XU X R, FENG W, JIANG Y S, et al. Dynamically pruned message passing networks for large-scale knowledge graph reasoning [EB/OL]. (2020-04-07) [2022-05-10]. <http://arxiv.org/abs/1909.11334>.
- [18] VOLODYMYR M, NICOLAS H, ALEX G. Recurrent models of visual attention[J]. *Advances in Neural Information Processing Systems*, 2014, 27(2): 2204-2212.
- [19] ZAREMBA W, SUTSKEVER I, VINYALS O. Recurrent neural network regularization[EB/OL]. (2015-02-19) [2022-05-10]. <http://arxiv.org/abs/1409.2329>.
- [20] CAO Y X, LIU Z Y, LI C J, et al. Multi-channel graph neural network for entity alignment[EB/OL]. (2019-08-26) [2022-05-10]. <http://arxiv.org/abs/1908.09898>.
- [21] ZHANG Q H, SUN Z Q, HU W, et al. Multi-view knowledge graph embedding for entity alignment[EB/OL]. (2019-06-06) [2022-05-10]. <http://arxiv.org/abs/1906.02390>.
- [22] GUO L B, SUN Z Q, HU W. Learning to exploit long-term relational dependencies in knowledge graphs[EB/OL]. (2019-05-13) [2022-05-10]. <http://arxiv.org/abs/1905.04914>.
- [23] SUN Z Q, WANG C M, HU W, et al. Knowledge graph alignment network with gated multi-hop neighborhood aggregation[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(1): 222-229.
- [24] ADAM P, SAM G, SOUMITH C, et al. Automatic differentiation in pytorch[J]. *Advances in Neural Information Processing Systems*, 2017, 3(6): 1401-1412.
- [25] ADAM P, SAM G, FRANCISCO M, et al. Pytorch: An imperative style, high-performance deep learning library[J]. *Advances in Neural Information Processing Systems*, 2019, 32(13): 611-624.
- [26] VISHNU S. Deep Learning with PyTorch: A practical approach to building neural network models using PyTorch[M]. Birmingham: Packt Publishing Ltd, 2018.
- [27] SCHLICHTKRULL M, KIPF T N, BLOEM P, et al. Modeling relational data with graph convolutional networks[C]//*Proceedings of the European Semantic Web Conference*. Berlin: Springer, 2018: 593-607.
- [28] DETTMERS T, MINERVINI P, STENETORP P, et al. Convolutional 2D knowledge graph embeddings[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2018, 32(1): 1811-1818.
- [29] SUN Z Q, DENG Z H, NIE J Y, et al. RotatE: Knowledge graph embedding by relational rotation in complex space[EB/OL]. (2019-02-26) [2022-05-10]. <http://arxiv.org/abs/1902.10197>.
- [30] GARCÍA-DURÁN A, DUMANČIĆ S, NIEPERT M. Learning sequence encoders for temporal knowledge graph completion[C]//*Proceedings of the Conference on Empirical Methods in Natural Language Processing*. Stroudsburg: Association for Computational Linguistics, 2018: 4816-4821.
- [31] DASGUPTA S S, RAY S N, TALUKDAR P. HyTE: Hyperplane-based temporally aware knowledge graph embedding[C]//*Proceedings of the Conference on Empirical Methods in Natural Language Processing*. Stroudsburg: Association for Computational Linguistics, 2018: 2001-2011.
- [32] GOYAL P, CHHETRI S R, CANEDO A. Dyngraph2vec: Capturing network dynamics using dynamic graph representation learning[J]. *Knowledge-Based Systems*, 2020, 187: 104816.
- [33] URIEL S, IDO G, KIRA R. Node embedding over temporal graphs[C]//*Proceedings of the International Joint Conference on Artificial Intelligence*. Amsterdam: Morgan Kaufmann, 2019: 4605-4612.
- [34] PAREJA A, DOMENICONI G, CHEN J, et al. EvolveGCN: Evolving graph convolutional networks for dynamic graphs[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(4): 5363-5370.
- [35] SEO Y, DEFFERRARD M, VANDERGHEYNST P, et al. Structured sequence modeling with graph convolutional recurrent networks[C]//*Proceedings of the International Conference on Neural Information Processing*. Berlin: Springer, 2018: 362-373.
- [36] RAKSHIT T, HANJUN D, YICHEN W, et al. Know-Evolve: Deep temporal reasoning for dynamic knowledge graphs[C]//*International Conference on Machine Learning*. New York: ACM, 2017: 3462-3471.
- [37] TRIVEDI R, FARAJTABAR M, BISWAL P, et al. Representation learning over dynamic graphs[EB/OL]. (2018-03-16) [2022-05-10]. <https://arxiv.org/abs/1803.04051>.
- [38] JIN W, QU M, JIN X S, et al. Recurrent event network: Autoregressive structure inference over temporal knowledge graphs[C]//*Proceedings of the Conference on Empirical Methods in Natural Language Processing*. Stroudsburg: Association for Computational Linguistics, 2020: 6669-6683.

Power equipment defect prediction based on temporary knowledge graph

JI Xin^{1, 2}, WU Tongxin^{1, *}, YANG Zhiwei¹, YU Ting¹, LI Junting¹, HE Yude¹

(1. Big Data Center, State Grid Corporation of China, Beijing 100031, China;

2. School of Computer Science and Technology, Beihang University, Beijing 100191, China)

Abstract: Power system management now includes monitoring power equipment operation, which is crucial given the growing size of power facilities. Defect prediction of power equipment is a key step in power system operation monitoring. In order to solve the problem of defect prediction for power equipment in large-scale power systems, we propose a defect prediction model for power equipment based on a temporary knowledge graph. The attention mechanism fuses the multimodal data, and the relationship-aware graph neural network and recurrent neural network are then employed to extract the temporal representation of entities and relations. Finally, we perform defect prediction of power equipment based on the temporal representation. The method proposed in this paper can make full use of multimodal information to improve the accuracy of power equipment defect prediction. Experimental results show that the model has considerable performance improvement compared to the baseline model.

Keywords: temporary knowledge graph; graph neural network; defect prediction; power system; power equipment