

# 故障知识图谱技术体系研究综述

陈雪莹, 李书剑, 周成宁, 杨泰波, 刘才学

(中国核动力研究设计院, 成都 610213)

**摘要:** 随着设备复杂度的日益增加, 对设备的维护和故障诊断也提出了更高要求; 故障知识图谱作为一种新兴的故障诊断技术, 具有结构化存储、可视化展示、多源数据融合、实时更新等多方面优势; 为了深入了解故障知识图谱的研究思路, 把握其未来研究方向, 针对故障知识图谱各主要技术的研究现状进行了分析与总结; 从知识图谱的定义和发展历程出发, 引申至故障知识图谱的定义及其研究现状, 并对故障知识图谱的各层关键技术进行介绍, 分析了各关键技术的相关研究方法及其研究现状; 基于现今研究现状与未来技术发展趋势, 对故障知识图谱的未来研究方向作出了展望, 为故障知识图谱下一步的相关研究提供参考和启示。

**关键词:** 故障知识图谱; 知识表示; 知识抽取; 知识融合; 技术体系

## Review of Fault Knowledge Graph Technology System

CHEN Xueying, LI Shujian, ZHOU Chengning, YANG Taibo, LIU Caixue

(Nuclear Power Institute of China, Chengdu 610213, China)

**Abstract:** With the increasing complexity of equipment, it needs higher requirements for equipment maintenance and fault diagnosis. As a new fault diagnosis technology, fault knowledge graph has the advantages of structured storage, visual display, multi-source data fusion, and real-time update. In order to deeply understand the research idea of fault knowledge graph and grasp its future research direction, the research status of main technologies in fault knowledge graph is analyzed and summarized. From the definition and development process in knowledge graph, the definition and research status of fault knowledge graph are extended. And the key technology of each layer of fault knowledge graph is introduced, the research method of each technology and related research status is analyzed. Based on current research status and future technology development trend, the future research direction of fault knowledge graph is prospected, which provides reference and enlightenment for further research on fault knowledge graph.

**Keywords:** fault knowledge graph; knowledge representation; knowledge extraction; knowledge fusion; technology system

## 0 引言

随着工业 4.0 和智能制造的不断推进, 设备的复杂度日益增加, 故障诊断和维修的难度也随之提升。传统的故障诊断方法, 诸如依赖于专家经验或者规则库, 难以应对现如今大规模且复杂多变的故障情况, 专家经验等不易传承和共享, 知识积累速度缓慢, 且现场数据的采集和分析过程复杂耗时, 难以实现实时诊断。因此, 如何有效地整合和利用现有的故障诊断知识, 成为提升设备维护效率和降低运维成本的关键。而故障知识图谱 (FKG, failure knowledge graph) 作为结构化故障知识管理和应用的重要手段, 专门用于收集、整理、分析和

应用设备故障相关信息, 提供了规范化的语义表达, 从而有效组织并存储了设备故障诊断、预防、维护等多重相关经验与机理知识, 进而解决了故障知识碎片化和信息孤立化问题, 实现了故障信息的全面整合与高效利用, 为设备故障诊断技术提供了新思路与新方法<sup>[1]</sup>。

在国外, 欧美工业强国从 2015 年起系统推进故障知识图谱研究, 形成了三大技术路线: 一是着重于工业本体构建, 德国弗劳恩霍夫研究所开发了多级流建模 (MFM, multi-level flow modeling) 本体框架, 构建了涵盖设备结构、故障模式、维修策略的层次化本体库, 已在西门子燃气轮机诊断系统中实现了商业化应用; 二是侧重于多源数据融合的技术路线, 美国通用电气提出

收稿日期: 2024-12-31; 修回日期: 2025-02-28。

基金项目: 中国核动力研究设计院原创基金(一)(KJ CX-2023-YC1-019)。

作者简介: 陈雪莹 (1998-), 女, 硕士, 研究实习员。

引用格式: 陈雪莹, 李书剑, 周成宁, 等. 故障知识图谱技术体系研究综述[J]. 计算机测量与控制, 2025, 33(5): 1-12.

了 Predix 知识图谱平台,集成了传感器时序数据、维修工单文本、工程图纸等多模态数据,通过图神经网络实现故障传播路径推理,使风力发电机故障定位准确率提升 37%;三是着眼于动态知识更新技术,卡耐基梅隆大学研发的 DYNKG 系统,采用了增量学习机制实现了故障知识图谱动态化,在 NASA 航天器故障预测中实现了小时级知识更新,有效应对新型故障模式。在国内,于 2021 年制定了电力设备故障知识图谱行业标准,建立了包含 12 类本体、89 种关系类型的通用架构<sup>[2]</sup>,已在国家电网 110kV 变电站推广应用;阿里云工业大脑研发的 FKG 3.0 平台,实现日均处理 20 万条非结构化维修记录,通过知识抽取构建覆盖了 2 000+ 故障模式的知识图谱,在宝钢连铸机故障预测中降低非计划停机时间 42% 左右。综上,故障知识图谱技术的出现,不仅为故障诊断提供了更为全面和系统的信息支持,还通过智能化的手段,极大地提升了故障诊断的效率和准确性。除此之外,故障知识图谱还具有重要的理论意义。它不仅是一种技术手段,更是一种知识管理方法。通过对故障信息的结构化表示,故障知识图谱能够揭示故障之间的内在联系和规律,为故障机制的研究提供新的视角。同时,故障知识图谱还可以作为机器学习和深度学习的训练数据,进一步提升智能化诊断的效果。因此,故障知识图谱的研究不仅对实际应用具有重要意义,还在理论研究方面具有较大的潜力与前景。

目前,国内外也有针对故障知识图谱的相关综述研究。美国麻省理工学院研究团队从技术融合趋势分析角度进行综述,揭示了知识图谱与深度学习的融合率从 2018 年的 23% 提升至 2021 年的 68%,其中图神经网络(GNN, graph neural network)在故障传播推理中的应用论文数量年增长率达 142%<sup>[3]</sup>;中国电力科学研究院联合高校团队针对行业标准体系展开综述,将故障知识图谱建设水平划分为数据层、模型层、应用层三大阶段,评估显示国内 85% 企业处于数据层向模型层过渡阶段<sup>[4]</sup>;阿里研究院则在 2023 年发布的《工业知识图

谱白皮书》中针对故障知识图谱的落地时间进行综述与剖析,指出国内 76% 的故障知识图谱项目受限于领域专家参与度不足。综上,国内外已从故障知识图谱的技术融合趋势、行业标准体系、落地实践等多方面开展剖析与综述,具有极高的指导意义,但对故障知识图谱全部主要关键技术的研究方法与发展走向的综述研究略显欠缺。

因此,为了深入了解故障知识图谱技术的研究思路,本文将针对故障知识图谱的各关键技术的研究现状进行综述,首先基于知识图谱的定义引申至故障知识图谱,阐述、分析故障知识图谱的定义及研究现状;而后针对故障知识图谱的各关键技术进行介绍,分析了各技术的研究现状;最后对故障知识图谱未来研究及发展方向作出展望,为故障知识图谱下一步的相关研究提供参考和启示。

## 1 故障知识图谱的基本概念

### 1.1 知识图谱的定义与发展历程

知识图谱(KG, knowledge graph),简而言之,就是一种将不同种类的知识关联在一起所得到的关系图谱,其实质是揭示现实世界中实体之间的语义关系网络<sup>[5]</sup>。其中,知识描述的是数据特征,图谱则表示的是结构特点,其核心结构一般为“实体—关系—实体”构成的三元组。目前,知识图谱已在人机知识问答<sup>[6]</sup>、知识检索<sup>[7]</sup>、智能推荐系统<sup>[8]</sup>、文本信息理解<sup>[9]</sup>、机器翻译<sup>[10]</sup>等多种场景有效应用。

知识图谱的研究开始于 20 世纪 50 年代,其发展历程如图 1 所示:1955 年至 1977 年为知识图谱的起源阶段,在此阶段引文索引<sup>[11]</sup>、语义网络、知识工程等概念逐步提出,以实现知识组织与脉络梳理;1977 年至 2012 年是其发展阶段,知识本体、语义网、知识表示等概念被提出且得到快速发展,使知识更易于在机器与机器间、机器与人之间实现交换和加工;2012 年至今为其繁荣阶段,2012 年 11 月,Google 公司首先提出了

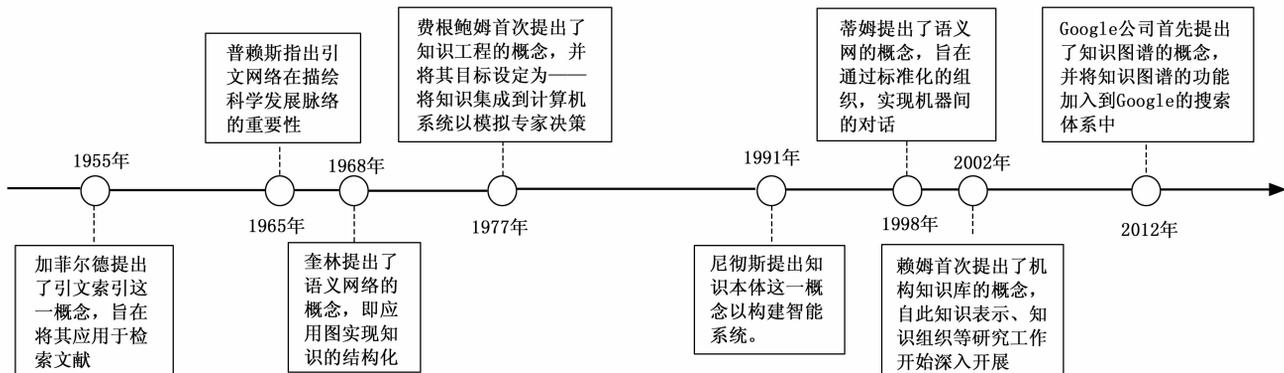


图 1 知识图谱的发展历程

知识图谱的概念, 并将知识图谱的功能加入到搜索体系中, 改善了其大规模知识管理功能和搜索引擎性能<sup>[12]</sup>。由此, 在计算机及人工智能的蓬勃发展下, 知识图谱涉及到的各关键技术问题均得到一定程度的解决和突破, 知识图谱成为知识服务领域的研究热点。国内外也有多个知识图谱项目落地, 如国外的 Dbpedia<sup>[13]</sup>, YAGO<sup>[14]</sup>, Freebase<sup>[15]</sup>, 国内的 CN-Dbpedia<sup>[16]</sup>, zhishi.me<sup>[17]</sup>等。

知识图谱的构建方法分为自底而上与自顶向下两种<sup>[18]</sup>。自底而上的构建方式是从数据层面出发, 通过数据驱动的方式自动或半自动地从数据(如文本、数据库等)中抽取知识, 此种方法强调从底层数据开始, 逐步挖掘知识, 识别实体和关系, 从而形成知识图谱结构, 其优势在于自动化程度高、灵活性与扩展性强, 但存在过度依赖数据质量、实体和关系抽取难度大等问题; 而自顶向下的构建方式是从概念和结构层面出发, 首先设计好知识图谱的架构, 然后填充具体知识内容, 即先确定宏观结构, 定义出主要的实体类型、关系类型以及它们之间的层次关系, 再基于上述定义去寻找、抽取和整理具体的数据, 此种方法优势在于结构化程度高、一致性好、可解释性强, 但存在灵活性较差和构建周期长的问题。目前也有诸多的知识图谱构建方案采用两种构建方式相结合的方法——采用自顶向下的方式构建知识本体库, 而后采用自底而上的方式抽取知识实现图谱扩展, 由此可灵活利用两种构建方式的优势<sup>[19]</sup>, 确保了本体的通用性与实用性<sup>[20]</sup>。

知识图谱的工作流程如图 2 所示, 一方面, 从数据源中抽取实体属性及实体间关系, 并对其进行归类整理, 从而构建传统三元组知识图谱; 另一方面, 用户输入其需要搜索的信息后, 知识图谱先对输入信息进行提取, 得到信息中包含的实体与属性信息, 而后在构建好的知识图谱中搜索所提取到的信息, 最后将查询到的属

性值返回到用户, 同时将所推荐的实体其他属性及与其有关系的实体一并返回。

### 1.2 故障知识图谱的定义和研究现状

基于知识图谱, 针对故障知识管理的应用——故障知识图谱近年已逐步发展起来。2015 年, 德国工业 4.0 白皮书首次提出了设备知识建模需求, 知识图谱开始向故障领域迁移; 2018 年, 张涛首次完整定义了“面向故障诊断的领域知识图谱”<sup>[21]</sup>; 2019 年, ISO 13374-4 国际标准正式纳入了故障知识图谱技术条款, 意味着其在国际上开始广泛应用, 且在研究领域形成一定共识<sup>[22]</sup>; 2020 年, IEEE PHM 会议确立了故障知识图谱标准架构; 同年, 阿里巴巴工业大脑发布工业故障知识图谱平台, 国内开始将故障知识图谱广泛用于工业实践领域。

故障知识图谱具体是指将故障信息、设备信息、维修经验、技术文档等多源异构数据通过图形化方式, 将实体(如设备、故障现象、维修方法)与关系(如因果关系、包含关系、步骤关系)结构化表示出来, 从而构建出用于故障诊断领域的知识库。故障知识图谱的工作模式与人类逻辑推理过程相似——通过规则或推理机制预测或识别故障模式; 同时其可将大量专家经验、历史数据等以结构化方式存储, 实现故障知识的共享与管理。将知识图谱融合至故障诊断领域具有以下优势: (1) 清晰的关系表示<sup>[23]</sup>: 故障知识图谱以图的形式表示实体及其之间的关系, 使得知识的表示更加清晰与直观; (2) 高效的检索和查询<sup>[24]</sup>: 利用故障知识图谱可以进行多维度的快速查询, 能够快速检索出与特定故障现象相关的多个实体及其关系, 也可基于多种条件进行综合性查询, 使得检索的灵活性与准确性得到大幅提高; (3) 实现知识集成与共享<sup>[25]</sup>: 故障知识图谱可以集成不同来源、格式的故障知识, 对其进行结构化存

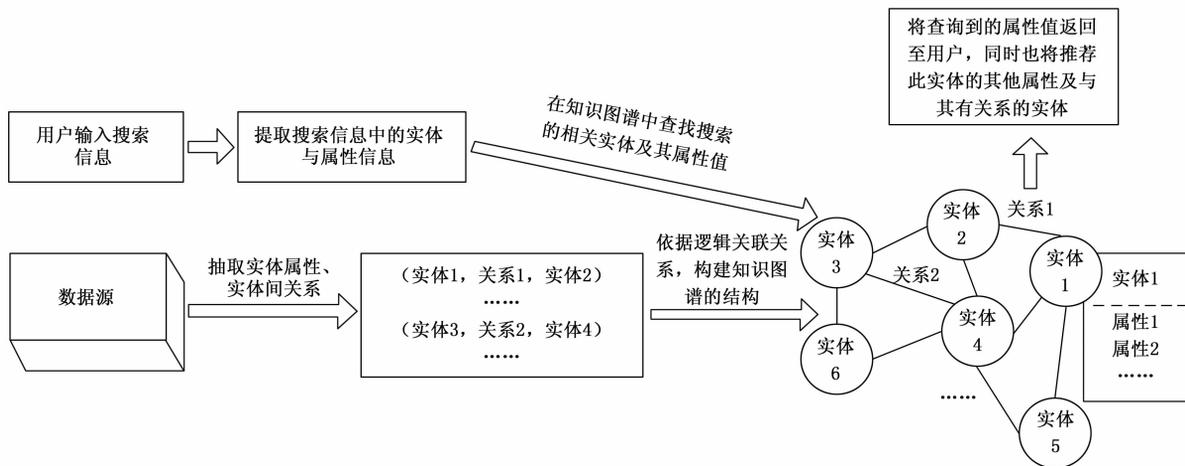


图 2 知识图谱的工作流程

储, 形成统一的知识库, 便于外部知识整合、管理与维护; (4) 可视化<sup>[26]</sup>: 故障知识图谱可以通过可视化工具展示复杂的故障关系和路径, 助于更直观地理解和分析故障现象及其关联原因。

现如今, 国内外诸多领域已先后开展故障知识图谱的相关构建研究。XIAO N 将电网调度中的大量文本记录进行结构化表示, 构建了用于电网故障辅助决策的故障知识图谱<sup>[27]</sup>; 盛林通过构建旋转机械故障知识图谱整合了旋转机械领域的故障知识、案例与专家经验, 发挥其故障原因推理作用<sup>[28]</sup>; 王晴雯充分利用了知识图谱的图结构对铁路信号设备的故障知识进行结构化表示, 从而大大提升了故障查询和存储效率<sup>[29]</sup>; TANG Y C 则将故障知识图谱应用于电力设备, 以提高电力设备多源异构故障知识的管理效率<sup>[30]</sup>。目前, 故障知识图谱的应用领域十分广泛, 特别是在工业设备维护<sup>[31]</sup>、智能制造<sup>[32]</sup>、航空航天<sup>[33]</sup>、交通运输<sup>[34]</sup>等领域, 为其故障诊断、预测维护、决策支持和故障知识管理等提供支撑。

## 2 故障知识图谱的关键技术及研究现状

故障知识图谱的构建及应用过程是一个系统而复杂的过程, 涉及多个步骤: 首先是获取构建故障知识图谱所需的数据并对其进行一定的预处理即知识表示, 其次从现有文本中通过知识抽取提取出关键信息, 而后针对这些关键信息进行融合后以一定形式进行存储, 从而形成故障知识图谱, 在故障知识图谱形成后, 其可用于知识检索返回需求信息, 也可再度进行知识推理对故障知识图谱进行进一步拓展与完善。综上, 故障知识图谱的关键技术环节如图 3 所示。

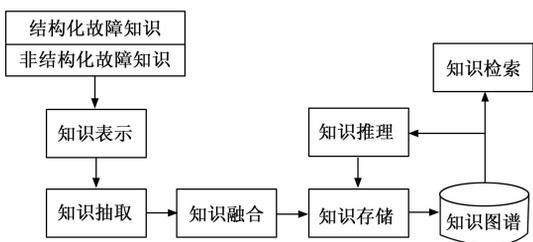


图 3 故障知识图谱的关键技术环节

其关键技术环节大致可分为以下几部分: (1) 故障知识表示、(2) 故障知识抽取、(3) 故障知识融合、(4) 故障知识存储、(5) 故障知识推理、(6) 故障知识检索<sup>[35]</sup>。本章将针对上述六个关键技术及其研究现状进行详细介绍, 目前而言, 故障知识图谱的六个关键技术及其热门研究方法如图 4 所示。

### 2.1 故障知识表示

对各种渠道获取的故障知识进行表示是构建故障知识图谱的第一步, 也是构建故障知识图谱的重要一

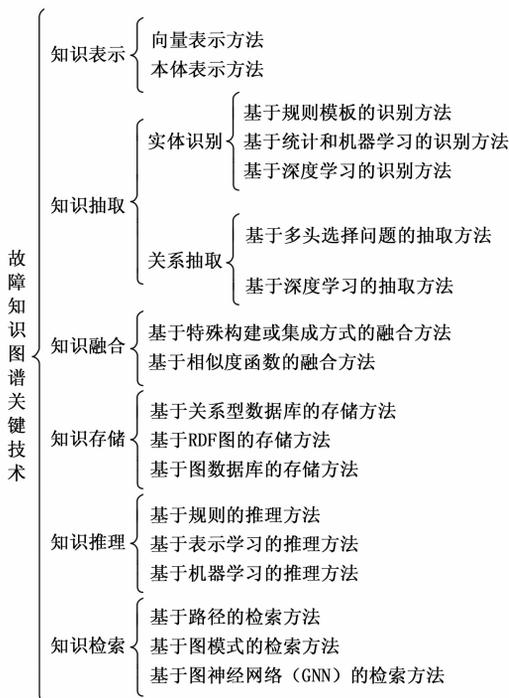


图 4 故障知识图谱的关键技术及其现有研究方法

环, 它为后续的逻辑推理和决策奠定了基础, 也对故障知识图谱的构建质量有着直接影响<sup>[36]</sup>。故障知识表示即为针对故障知识按照一定的逻辑、语言等进行转化、表示与存储, 以使其更高效地被理解、处理、利用。在故障知识图谱中, 知识表示涉及如何描述设备、故障、症状、信号特征表征、原因、解决方法等信息。

一般情况下, 设备的故障数据可划分为结构化数据与非结构化数据两种。其中, 结构化数据是指具有预定义格式、可通过固定字段存储于数据库或表格中的数据, 其典型特征为字段标准化且以数值/枚举类型为主、机器可读性强, 并且往往支持 SQL 查询。常见的结构化故障数据包括设备及其零部件的拓扑结构、传感器探测到的响应信息(以数值形式为主)以及相关的故障特征表征(如均值、方差、特征频率值等)、相应的故障代码与等级等; 而非结构化数据是指无固定格式、需要特定技术解析的异构数据, 其主要以自由文本为主、包含大量语义信息, 且存储形式多样, 往往需要 NLP/ML 等处理, 其主要包括故障件、故障状态、故障案例的相关阐述及说明等, 诸如维修报告文本、传感器波形图、沟通记录等多种形式。现如今, 设备结构愈加复杂, 设备在不同零部件上的故障数据呈多样性、复杂性、传递性等特点。同时, 故障知识涉及范围广, 但知识语料呈现出模糊性、碎片化等特点, 上述一系列问题增加了知识表达的难度。因此, 知识表示研究是构建故障知识图谱的关键技术之一。知识表示方法一般分为两种, 一是向量表示方法, 二是本体表示方法。

向量表示方法是将实体和关系转化为低维向量的表示方法,此种表示方法能够捕捉知识的语义相似性和隐含关系,在故障预测和模式识别中有较好的应用。田野基于磁悬浮轴承故障知识的相关特点,对故障文本数据进行分类,并利用 Jieba 分词库对其进行文本分词去噪,最后采用 word2vec 分布式编码<sup>[37]</sup>方式生成文本向量<sup>[38]</sup>,此方法提高了词向量生成效率和字符串匹配准确度,适用于设备部件领域故障知识的积累与诊断指导;张飞针对于故障知识存在大量“多现象—多原因—多方法”的多元耦合关系导致难以完整真实转化等问题,设计了一种基于知识超图的故障多元知识表示方法,将双向转换编码(BERT, bidirectional encoder representations from transformers)模型与超图卷积网络(HCN, hypergraph convolution network)相结合以获取故障知识的嵌入向量<sup>[39]</sup>,获得了更加完整的知识表示和更全面的检索效果,但此种方法在超图卷积的过程中,并未考虑故障知识的重要程度,可基于此方法并结合节点邻域信息重要度这一因素进一步提升知识表示的全面性,将更适用于后续的知识补全和知识问答等下游任务。

本体表示方法则结合了图结构和描述逻辑两方面的优势,其是一种更加结构化的语义网,除了定义实体和关系外,还包括实体的属性、类别、约束条件等<sup>[40]</sup>。因此,使用本体表示方法可以更精确地定义知识图谱的语义和结构,支持更复杂的推理操作。故障知识本体即为设备故障知识相关概念、属性等的规范化定义。简单而言,本体即为故障知识库的模板,本体的概念与关系规范了知识图谱中的节点与关系<sup>[41]</sup>。张欢欢使用本体这一形式化的知识表示方式来构建故障知识图谱的知识框架,通过对故障本体及其关系的实例化来产生、拓展故障知识<sup>[42]</sup>,此种本体+贝叶斯网络的混合架构平衡了故障知识图谱的精度和效率,但较依赖知识的形式化,如定义造纸机械中“断纸”事件涉及的数百个关联参数(如湿度、张力、辊速等)耗时极长,针对复杂机械效率较低;曾旻冬将骨架法和七步法两种本体构建方法结合起来,构建了一个多维燃气轮机故障知识本体表达模型<sup>[43]</sup>,此种方法增强了逻辑推理能力和知识追溯能力,但在动态性与实时性上仍存在短板,更适用于复杂故障模式诊断及长期维护知识沉淀等应用场景;赵倩则是在本体表示后增加了数据映射步骤,新增了累计次数作为实体关联,从而将传统的三元组形式转化为资源描述框架(RDF, resource description framework)四元组,丰富了本体中的实体与属性关系<sup>[44]</sup>,为精准维修提供指导,由于现象频次的引入,此方法适用于间歇性故障诊断及预防性维护,但在动态参数建模和实时响应性上略显不足,因此不适用于无预警信号的突发性故障

诊断;孙博引进了时间维度,在传统的三元组外新增了时序信息形成四元组,基于时间维度扩展与状态转移规则使故障预测更具有时效性<sup>[45]</sup>,此种特性使得该方法更适用于渐进性故障预测,如轴承磨损、密封老化等缓慢发展的故障模式,并且当存在多传感器时序关联的状态下,此种本体表示方法也可清晰表达因果关系,但引入的时序计算也会增加响应的推理复杂度,同时本体表示方法针对高频数据的处理也存在一定局限性。

## 2.2 故障知识抽取

故障知识抽取即为在来源不同、结构不同的数据中进行实体抽取<sup>[46]</sup>、关系抽取<sup>[47]</sup>等,从而获得相应的结构化数据<sup>[48]</sup>。实体识别就是将各类故障知识中识别出有价值的信息并进行标注,如设备名称、故障类型、部件等,以进行下一步处理<sup>[49]</sup>。实体关系抽取指的是在完成故障实体识别后,从故障知识中抽取得到故障实体间的关系与属性间的关系的过程,如“设备 A 导致故障 B”<sup>[50]</sup>。

实体识别方法一般包括基于规则和模板的方法<sup>[51]</sup>、基于统计和机器学习的方法<sup>[52]</sup>和基于深度学习的方法<sup>[53]</sup>;基于规则与模板的方法是最早的实体抽取方法,其首先通过关键词、词法和语法等先验知识实现规则模板的建立,而后利用规则模板匹配待抽取文本,进而提取满足要求的相应实体<sup>[54]</sup>,但此种方法实现时,其规则模板的编写极其依赖于先验知识,且编写难度大、通用性弱,难以适用于目前繁杂的故障知识库的抽取,故目前较少采用此类方法;基于统计和机器学习的实体识别方法一般是将实体进行一定形式的转换,并通过一定的统计机制来识别出频次高或比重大的实体,以完成实体识别;基于深度学习的实体识别方法是指利用深度学习算法从原始文本中自动提取出特定类型实体的过程,其特性在于其能够自动学习并提取特征,具有良好的适应性和可扩展性。

基于统计和机器学习的实体识别方法研究目前主要聚焦于实体的形式转换方法,以期提高实体识别的准确性。WANG Y 利用段图中的节点表示实体信息中的连续实体和非连续实体,从而将非连续实体的识别问题转为识别段图中最大团(maximal clique)问题<sup>[55]</sup>,由于最大团发现是一种全局推理方法,能够避免局部最优解,即综合考虑到了所有候选片段的关系,但最大团问题也存在着当候选片段数量较多时,计算效率显著下降的问题,导致计算复杂度增大,同时构建图的复杂性也会增加成本,因此此种方法更适合标注资源较丰富、需要高精度识别复杂实体的场景;DAI X 则是通过对嵌套实体和非连续实体的共性分析,将非连续实体转为嵌套实体,并利用堆栈结构,借助乘法注意力机制来捕获 stack 区与 buffer 区元素间所存在的非连续性依赖,基

于非连续性的依赖程度决策下一步的执行,从而抽取到非连续实体<sup>[56]</sup>,此方法可以灵活地处理不连续的实体,但可能需要大量的标注数据来训练模型,因此更适用于有一定故障知识研究基础且需要识别结构复杂实体的领域。

由于深度学习方法的不断发展,目前基于深度学习的实体识别方法是研究热度最高的知识抽取方法。尹昱东将(BiLSTM, bi-directional long short-Term memory)<sup>[57]</sup>—条件随机场(CRF, conditional random field)<sup>[58]</sup>、视觉几何组 16 层(Vgg16, visual geometry group 16)、BERT 模型<sup>[59]</sup>3 种用于实体抽取的模型进行测试分析比较,试验证明上述 3 种模型均能实现实体抽取功能,但其中 BERT 模型具备最好的识别效果<sup>[60]</sup>。BERT 模型的主要特点是双向编码,能够同时考虑上下文信息来生成每个词的词向量,从而更准确地理解词义和句子的语义,极大提高了实体识别的准确性。因此,目前大多数基于深度学习方法的实体识别研究多依据于 BERT 模型及其变种、结合模型。YE 在 BiLSTM-CRF 方法的基础上,引入了 BERT 语言训练机制处理自然语言文本,并将处理后所得到的向量作为 BiLSTM 网络的输入,实现了嵌套实体处理改进,成功提升了实体识别标注的准确性与效率<sup>[61]</sup>,相较于纯 BERT 模型大大节省了训练时间,但 BiLSTM 对长字段的依赖关系捕捉能力相对较差,且预训练词向量无法适应动态语境,因此该方法更适用于通用设备的故障诊断领域;稽文路通过轻量级 BERT (ALBERT, a lite bidirectional encoder representations from transformers)<sup>[62]</sup>机制替代 BERT 机制,用以解决数据稀疏所导致的中文分词精度较低的问题,而后采用词频—逆词频(TF-IDF, term frequency-inverse document frequency)<sup>[63]</sup>算法来统计文本信息中的词频以选取关键信息<sup>[64]</sup>,提升了故障知识图谱在低资源场景下的适应性与可解释性。

在关系抽取问题上,其解决方式一般有两种:一是将关系抽取问题转化为多头选择问题:HUANG W 将关系抽取任务转化为确定实体间的关系类型及从多个候选实体中选择正确的实体对任务<sup>[65]</sup>,利用更准确的实体边界为关系抽取提供更为可靠的输入,但此方法在关系语义建的显示建模略显不足,所以更适用于短文本关系抽取且故障实体密集的场景。二是基于深度学习的方法,如卷积神经网络(CNN, convolutional neural network)、循环神经网络(RNN, recurrent neural network)及其变体(如长短记忆网络(LSTM, long short-term memory、门循环控制单元(GRU, gated recurrent unit)等;FU T J 提出了 GraphRel 模型,利用双向图神经网络(BiGCN, bidirectional graph convolutional networks)实现关系抽取,提高了在数据集上的

模型精度<sup>[66]</sup>,大幅提升了重叠关系处理能力,但此模型在小样本场景表现欠佳,适合需要精细关系建模的垂直故障知识领域,但在用于标注资源有限的场景中需谨慎评估;孙亮在知识抽取的环节中,将 BiLSTM 实体抽取模型和 Attention-based BiLSTM 关系抽取模型相结合实现对故障知识库的构建<sup>[67]</sup>,提升了构建效率,同时实现了多模态关系对齐如故障文本描述与传感器数据的时空对齐,因而此方法特别适用于基于历史故障链的预测,但与此同时,在文本记录与传感器数据时间戳对齐方面的研究仍待进一步深化;而陈曦则是将 BERT 方法与融合多尺度注意力机制相结合实现关系抽取<sup>[68]</sup>,在关系抽取阶段注入了工况参数,提升了故障知识图谱的动态上下文感知能力,同时构建了 Markov 逻辑网络计算故障传播概率,可进一步预测二级故障,所以该方法格外适用于基于历史维修记录与后续故障关系挖掘,从而实现剩余寿命评估;蒋文充分利用了基于注意力机制的深度学习分类思想,在 BERT 模型的预训练基础上,将数控机床的故障文本特征向量输入至双向门控循环单元(BiGRU, bidirectional gated recurrent unit),从而学习故障文本的上下文信息特征,继而将此特征表示输入到 Attention 模型进行重要程度的加权分析,最后利用 softmax 函数输出关系类别,实现关系抽取<sup>[69]</sup>,提升了动态适应性,所以特别适用于配备完善传感系统的现代化智能机床故障诊断;陈云飞则采用标签传播算法,构建了实体相似矩阵,利用实体标签进行传播实现实体间的关系抽取<sup>[70]</sup>,在同类设备故障关系迁移学习具有极大优势,而在不同领域迁移上存在较大限制。栗佳初则将上述两种方式结合起来,利用多头选择判定关系,形成关系矩阵后,将其作为节点特征的邻接矩阵,最后基于邻接矩阵利用 BiGCN 更新节点特征,纠正错误的实体关系<sup>[71]</sup>,在双向关系推理和动态适应性方面都具备极大优势。

### 2.3 故障知识融合

故障知识融合是指基于一定规范对异构故障数据进行清理、整合、对齐<sup>[72]</sup>、消歧等操作,针对不同来源的同一实体、概念所描述、体现的信息、知识进行融合<sup>[73]</sup>,以进一步提高故障知识库的完整性、准确性和实用性。

故障知识的融合一般可从两个方面实施,一是在构建故障知识图谱时,采用特殊的构建方式或集成方式,通过一定的约束实现知识融合:唐获音借助于自顶而下依据知识构建本体与自底而上挖掘实体来优化本体相结合的双项约束方式,实现了航天器的多源异构故障知识的融合<sup>[74]</sup>,量子化特征映射的方法使得跨模态相似度计算精度大幅提升,但其劣势主要体现在实时性约束方面,因此更适用于长时延条件下的自主诊断;LU 针对

机械设备故障的多源数据, 提出了一种基于数据驱动的知识图谱迭代自动构建方法, 以用于各类数据知识融合<sup>[75]</sup>, 增强了认知推理能力与跨媒体融合能力, 但对数据质量较为敏感, 因此适用于多参数的设备故障知识融合。二是在获取知识并完成抽取后采用相似度函数对知识进行对齐以开展知识融合: 通常情况下, 一般多会采用余弦相似度 (CS, cosine similarity)<sup>[76]</sup> 算法实现知识融合, 但进一步的, 为了提升实体对齐效率, 也提出了更多的适用于知识融合的匹配算法: 韦伟基于变色龙算法 (CSA, chameleon swarm algorithm) 算法, 定义实体向量间的重叠比例, 并利用归一化语义相似度函数 (NSS, normalized semantic similarity) 对字词、短语等进行分析, 从而可以更全面、精确地衡量文本向量间的相似性, 是针对于大规模故障数据集实现实体对齐的一种有效方法<sup>[77]</sup>; 钟保强使用大数据分析实现对于 IT 设备的故障数据采集与集成, 基于匹配滤波方法完成故障信息融合后再引入知识图谱检测法以完成 IT 设备的故障分析<sup>[78]</sup>, 在多源异构数据融合和混合实体对齐方面具有良好表现, 针对混合环境下的异构设备故障分析具有高适配性。

## 2.4 故障知识存储

故障知识存储指的是结合场景、数据、需求等条件, 选择合适的故障知识存储方式, 以便于高效管理与利用故障知识, 目前故障知识图谱的存储一般采用关系型数据库<sup>[79]</sup>、RDF 图<sup>[80]</sup>或图数据库<sup>[81]</sup>。对于复杂查询而言, 图数据库的查询效率要高于关系型数据库和 RDF 图。传统的关系型数据库, 只能存储简单数据, 面对海量的数据和复杂的关系, 无法高效处理和存储表示; RDF 图的三元组存储方式会导致数据冗余问题, 尤其是在表示多级关系时, 需要存储多个三元组来表示同一种关系; 而图数据库利用图论思想处理复杂节点关系, 在海量节点的存储、管理和可视化等方面具有高效和灵活等优势。

常见的图数据库有 Neo4j、Virtuoso、GraphDB 等。Neo4j 因其强大的 Cypher 查询语言、高度成熟的生态系统和丰富的图算法库成为了故障知识图谱最常采用的图数据库管理软件<sup>[82]</sup>。Neo4j 是一个高性能的非关系型的图形数据库, 它将结构化数据存储于网状结构上, 其数据存储方式主要由节点 (node) 和边 (edge) 构成, 其中节点代表知识图谱的实体, 边代表知识图谱的关系, 关系是可以存在方向的, 即它是一个有向图结构的数据格式。Neo4j 支持分布式架构, 能够处理大规模的数据和高并发的查询请求, 同时其通过分区和幅值机制, 大大提高了故障数据的可用性和容错性; 并且内置了多种成熟的图算法 (如最短路径、社区检测、PageRank 等), 可直接用于图数据, 进行复杂的图分析与

处理; 与此同时, Neo4j 相较于其他图数据库知识存储方法, 拥有更为丰富的工具与库, 如 Neo4j Browser 用于交互式查询和数据可视化、Neovis.js 用于数据可视化、Neo4j ETL 用于数据的导入导出等。上述优势使得 Neo4j 成为故障知识存储的最优方法。

## 2.5 故障知识推理

针对于知识图谱仍有许多隐含信息尚未充分挖掘的情况, 故障知识推理基于已知的实体关系, 实现新知识的推理或错误知识的识别<sup>[83]</sup>。在故障知识图谱中, 知识推理可以通过图谱中的实体和关系, 推导出故障现象与故障原因之间的多级关系, 生成维修建议, 预测故障趋势等。知识推理技术进一步可划分为基于规则的知识推理、基于表示学习的知识推理、基于机器学习的知识推理。

基于规则的知识推理方法是根据预定义的逻辑规则, 通过推理引擎在图谱中寻找满足规则的路径或模式, 从而推导出新的知识。WANG 提出了 ProPPR (programming with personalized pagerank) 一阶概率逻辑模型进行链接预测, 将知识图谱相关信息保存为有向证明图的形式, 同时将边的权重与特征向量进行管理, 通过计算关系链接的权重实现对关系的评分, 从而完成故障推理<sup>[84]</sup>, 相较其余方法, 此方法内存占比更小, 诊断精确率更高, 但存在规则依赖局限和长程推理局限, 此种方法由于存在规则一图映射机制, 因此会在可编码为逻辑规则的中等规模故障知识领域表现更好。李聪提出了基于规则与案例的知识推理方法, 从历史故障案例中采用统计分析方法获得更为宏观的故障规律, 并基于此结合深度学习模型实现故障数据库的知识推理与更新<sup>[85]</sup>, 这种混合方法相较于纯规则推理和纯案例推理方法具有更高的推理效率和故障类型匹配率, 但此方法更依赖历史故障数据, 且知识维护成本较高, 因此更适合有一定历史案例库的多传感器数据融合的设备故障诊断场景。

基于表示学习的知识推理方法旨在将复杂的、高维的故障知识转化为低维的、有意义的向量表示 (嵌入), 从而捕捉数据中的关键特征和语义信息。在基于表示学习的知识推理方法中, 研究热点与重点在于向量嵌入方法, 热点方法包括 TransE<sup>[86]</sup>、TransH<sup>[87]</sup>、TransR<sup>[88]</sup>、TransD<sup>[89]</sup>、TransA<sup>[90]</sup> 等基于翻译的表示学习模型, 此类方法的参数效率高, 即一般情况下, 每个实体/关系仅需单个向量, 且对简单关系推理具有理论完备性, 但劣势在于需要精细的距离度量调参, 且无法建模多对多的复杂关系, 更适用于简单层级的关系推理。除此之外, DistMult<sup>[91]</sup>——基于矩阵的嵌入模型和 RotatE<sup>[92]</sup>——基于旋转向量的表示学习模型也是新兴的知识推理方法。基于矩阵的嵌入模型优势在于可精确捕捉

高阶交互模式, 针对对称关系建模友好, 但其存在着计算复杂度高、参数爆炸等问题, 适用于需要显式关系解释的领域复杂关系网络。基于旋转向量的表示学习模型天然支持对称/反对称/逆关系等多种关系模式的推理, 但同样的, 其也存在复杂度高、模长约束需要额外设计的问题, 因此适用于需要多重关系推理的复杂系统诊断。

基于机器学习的知识推理方法是指通过训练机器学习模型, 从图谱中学习出隐含的模式和关系, 从而实现故障诊断和预测。李志博将构建知识图谱的实体抽取与数据标注步骤应用到卷积神经网络的输入信息中以实现故障诊断, 并在实现故障诊断后, 利用故障知识图谱详细且有逻辑地展示故障信息, 进行辅助诊断, 并利用试验证明这一故障知识图谱与卷积神经网络结合的故障诊断模型具有较强的稳定性与泛化性<sup>[93]</sup>; 陈柯利用贝叶斯网络对故障进行逐级原因推理从而实现故障知识图谱的补全<sup>[94]</sup>, 贝叶斯网络支持先验知识注入且可自然处理不确定性推理, 可在一定条件下大幅提升诊断置信度, 但其对先验条件要求较高, 且难以处理连续变量, 因此更适用于先验知识较为全面的故障诊断场景; 马亚杰提出了一种基于知识图谱异构图注意力网络(KGHAN, knowledge graph heterogeneous graph attention network)模型的工业设备故障诊断知识图谱补全方法, 从两个方式——故障实体概念补全、故障关系链接出发, 实现对故障知识图谱的补全<sup>[95]</sup>, 在异构信息推理和可解释性上具有一定优势, 但计算复杂度和标注依赖是此方法的现有瓶颈, 此知识推理方法适用于多源异构数据并存的系统, 如 PHM、SCADA 系统等或存在较多级联故障的设备。

## 2.6 故障知识检索

故障知识检索, 顾名思义, 即利用某些条件, 在故障知识图谱中进行查询, 并返回需求信息。知识检索技术的高效性和准确性将直接影响到故障知识图谱的实际应用效果。目前, 针对于知识检索技术的研究一般均充分利用故障知识图谱的图结构, 包括基于路径的检索方法、基于图模式的检索方法和基于图神经网络的检索方法。

基于路径的检索方法是故障知识图谱中最常用的检索技术之一, 该方法通过图谱中的路径查询以实现路分析, 同时结合相应的策略、算法或模型等, 提高检索的准确性与智能性, 从而快速找到与特定故障现象相关的故障原因或维修方法。张永珍在利用基于路径的检索方法检索故障原因时, 采用了两种剪枝策略: 一是判断故障原因中是否存在父子节点, 若存在, 则把子节点表示的故障原因删除; 二是进行关联点检测, 依据检测结果对故障原因进行排除或确认<sup>[96]</sup>, 由于路径可直观显示

故障关联, 且能发现多跳关系, 捕捉复杂的故障模式, 但路径搜索耗时且可能存在路径爆炸问题, 因此更适用于以链式或树状故障传播模式的多层级设备网络场景。

基于图模式的检索方法是通过对图谱中的特定模式进行匹配, 找到符合特定条件的故障案例。刘鑫基于 Neo4j 图数据库和 SpringBoot 编程, 采用三元组倒排索引与图结构索引混合机制并结合动态排序算法实现了故障信息动态检索, 优化了实施反馈性能, 促进了故障诊断知识的积累、共享和利用<sup>[97]</sup>, 但此方法的检索准确率较依赖知识覆盖度, 因此不适用于图谱规模比较简单的故障知识检索; 谈群基于故障知识图谱利用 Noisyor 模型对故障根因进行定量分析, 并采用图推理分析充分利用图谱中的结构信息, 提高检索的准确性和相关性, 并依据熵理论对故障可能导致的现象进行优先级排序, 提高了故障知识的检索精度, 体现了知识图谱在故障诊断上的优势<sup>[98]</sup>。

基于图神经网络的检索方法是近年来的研究热点, 旨在通过训练图神经网络模型, 自动学习图谱中的复杂关系, 实现对故障的高效检索和诊断。杨檬嘉提出了两种基于图神经网络的知识检索方法, 一是针对图神经网络的过平滑问题, 设计并提出了基于知识图谱随机神经网络的推荐方法, 二是针对知识图谱常存在的过长尾问题, 设计并提出了一种基于关系学习的知识图谱推荐方法<sup>[99]</sup>, 上述两种方法具备一定的增强学习能力, 提升了检索质量, 但也对计算资源提出了一定需求, 因而适用于需要路径推理解释、知识更新频率单位为每日或每月的渐进式知识更新应用场景。

## 3 故障知识图谱关键技术体系研究的未来展望

随着大数据、人工智能、物联网等技术的不断进步, 故障知识图谱作为一种重要的智能化工具, 将不断演进和扩展, 助力工业智能化和数字化转型。以下是针对故障知识图谱的六个关键技术的未来研究内容及发展方向的探讨与展望。

(1) 在知识表示方面, 发展更灵活的本体构建方法, 实现更精细的知识表示, 同时在一定领域内制定一定的数据标准<sup>[100]</sup>, 包括数据格式标准、术语和词汇标准化等, 提高知识图谱的互操作性与通用性, 开发解释生成技术等以增强知识表示透明度及可解释性, 提高故障知识图谱的实用性、准确性和适应性是其未来发展方向; (2) 在知识抽取方面, 大型预训练语言模型在知识抽取任务中的应用已成为新趋势, 这些模型能够在大规模语料库上进行训练, 并具备强大的语义理解能力, 而从不同模态数据诸如图像、振动数据、音频等抽取信息与特征, 增强知识抽取的多维度能力是知识抽取技术亟需解决的热点问题之一, 目前可通过增量学习等方法,

不断优化和调整这些预训练语言模型,适应新的故障场景和实时数据的变化,以期显著提高知识抽取的效率和准确性,同时还需考虑到知识的安全合规性,研发诸如符合 GDPR/DSGVO 标准的隐私保护知识抽取算法也是未来用于工程实践的发展方向;(3)知识融合技术的发展方向则大体包括三方面:一是支持知识图谱的动态更新,即当有新的知识抽取时,可通过自适应学习或自动化工具等能够将其高效、自动地融合至现有知识图谱中,二是支持大规模、多节点的知识图谱构建与更新,提高融合效率与可扩展性,三是支持自动化的冲突解决,如基于可信度、上下文依赖的方法,提高冲突解决的智能化水平,降低故障知识图谱的构建成本;(4)在知识存储方面,随着知识图谱数据规模与种类的扩大,如何实现高效、低成本且能满足多样化数据统一管理需求的数据存储方案将是未来的研究热点与实践方向;(5)在知识推理方面,随着图谱规模的增大,路径的复杂度也随之提升,可能导致推理性能的下降,另一方面,基于规则与案例的推理方法在一定程度上会受到主观因素的影响,从而导致推理结果的偏差,未来可将深度学习与知识图谱相结合,通过深度学习算法实现更复杂、更精确的故障模式识别,同时提高推理的鲁棒性,此外采用自监督学习、增强学习等方式,通过与环境的交互不断调整推理策略,找到最优的解决路径,动态调整推理规则,提高其自我优化能力,实现更全面和准确的故障诊断;(6)在知识检索方面,如何准确理解用户的自然语言查询,尤其是在查询语义复杂或不明确的情况下如何实现精准查询是知识检索技术面临的挑战之一,另一方面,如何在结构复杂、数据量巨大的故障知识图谱中进行准确检索也是其亟待解决的问题,未来可考虑自然语言处理技术与各种模型相结合,以提高检索的精确度与智能化,提供更友善的用户界面,另外,可通过强化学习技术、小样本学习技术等深度学习方法来优化知识检索的过程,使故障知识图谱更好地服务于设备故障诊断。

综上,故障知识图谱技术仍有极大的研究与发展空间,未来可从其各关键技术研究出发,进一步提高故障知识图谱的自动化构建水平,减少人工干预的需求;探索不同领域知识的合作与融合,构建综合性的多领域故障知识图谱;研究实时性和动态更新技术,使图谱能更好地适应系统变化,快速反映最新的故障和诊断信息;开发更加智能化的用户交互界面,提供个性化的服务,使其朝着自动化、规模化、动态化、智能化的方向发展,为设备故障诊断与健康健康管理提供更加有力的支持。

#### 4 结束语

在现代工业的复杂系统中,设备故障诊断和预防是

保障其正常运行的重要环节。随着数据量的不断增长和信息技术的快速发展,传统的故障诊断方法已经难以满足高效、准确、及时的需求,故障知识图谱应运而生。故障知识图谱巧妙地将知识图谱的概念应用于故障诊断、管理,从而以图结构化的方式,整合多源异构的数据,实现故障信息的有效管理与智能应用,因此,针对故障知识图谱的研究显得愈发重要。

针对故障知识图谱,本文首先介绍了其基本概念与发展历程,随后,针对故障知识图谱的六个关键技术相关研究,包括故障知识表示、故障知识抽取、故障知识融合、故障知识存储、故障知识推理及故障知识检索等方面的研究方法进行了全面综述,最后针对故障知识图谱技术体系未来的发展方向进行展望。总体而言,故障知识图谱的构建是一个系统化、层次化的过程,涉及多个技术体系,而每个技术体系的研究与发展又与现代语言处理技术、智能算法、深度学习等研究密不可分。未来,随着人工智能技术的发展,故障知识图谱的应用也将更加广泛,其技术也将更智能化与自动化。

#### 参考文献:

- [1] QI Z X, WANG H Z, ZHANG H R. A dual-store structure for knowledge graphs [J]. IEEE Transactions on Knowledge and Data Engineering, 2020, 14 (8): 1104 - 1118.
- [2] 中国电力科学研究院. 电网设备知识图谱构建技术导则: DL/T 2725-2023 [S]. 北京: 中国电力出版社, 2023.
- [3] GUPTA A, Li B, CHEN C Y, et al. Knowledge graph meets deep learning: a decadal review [J]. IEEE Transactions on Industrial Informatics, 2021, 17 (12): 7895 - 7908.
- [4] 中国电力科学研究院. 电力领域知识图谱技术发展报告 [J]. 中国电机工程学报, 2022, 42 (24): 8765 - 8782.
- [5] 曹倩, 赵一鸣. 知识图谱的技术实现流程及相关应用 [J]. 情报理论与实践, 2015, 38 (12): 127 - 132.
- [6] CHEN Y R, LI H Y. DAM: Transformer-based relation detection for question answering over knowledge base [J]. Knowledge-Based Systems, 2020, 201 (9): 106077. 1 - 106077. 8.
- [7] WU Q, FU D, SHEN B, et al. Semantic service search in IT crowdsourcing platform: A knowledge graph-based approach [J]. International Journal of Software Engineering and Knowledge Engineering, 2020, 30 (6): 765 - 783.
- [8] KAUR M, SALIM F D, REN Y, et al. Joint modelling of cyber activities and physical context to improve prediction of visitor behaviors [J]. ACM Transactions on Sensor Networks, 2020, 16 (3): 1 - 25.
- [9] BABOUR A, KHAN J I, NAFA F, et al. Discovery engine for finding hidden connections in prose comprehension

- from references [J]. *International Journal of Advanced Computer Science and Applications*, 2021, 12 (1): 334 - 337.
- [10] AHMADNIA B, DORR B J, KORDJAMSHIDI P. Knowledge graphs effectiveness in neural machine translation improvement [J]. *Computer Science*, 2020, 21 (3): 299 - 318.
- [11] GARFIELD E. Citation Indexes for Science: A new dimension in documentation through association of ideas [J]. *Science*, 1955, 122 (3159): 108 - 111.
- [12] 李 涛, 王次臣, 李华康. 知识图谱的发展与构建 [J]. *南京理工大学学报*, 2017, 41 (1): 22 - 34.
- [13] BIZER C, LEHMANN J, KOBILAROV G, et al. Dbpedia-A crystal lization point for the web of data [J]. *Web Semantics: Science, Services and Agents on the World Wide Web*, 2009, 7 (3): 154 - 165.
- [14] SUCHANEK F M, KASNECI G, WEIKUM G. YAGO: A large ontology from wikipedia and word Net [J]. *Web Semantics: Science, Services and Agents on the World Wide Web*, 2008, 6 (3): 203 - 217.
- [15] BOLLACKER K, EVANS C, PARITOSH P, et al. Freebase: a collaboratively created graph database for structuring human knowledge [C] // New York: ACM, 2008: 1247 - 1250.
- [16] XU B, LIANG J, XIE C, et al. CN-DBpedia2: An extraction and verification framework for enriching Chinese encyclopedia knowledge base [J]. *Data Intelligence*, 2019, 1 (3): 271 - 288.
- [17] NIU X. Zhishi. me-weaving Chinese linking open data [C] // Heidelberg: The Semantic Web, 2011, 205 - 220.
- [18] 胡芳槐. 基于多种数据源的中文知识图谱构建方法研究 [D]. 上海: 华东理工大学, 2014.
- [19] 基于多数数据源的知识图谱构建方法研究 [J]. *福州大学学报 (自然科学版)*, 2017, 45 (3): 329 - 335.
- [20] 石 玉, 胡瑛婷. 基于知识图谱和模糊推理的机械故障诊断模型 [J]. *现代信息科技*, 2022, 6 (13): 72 - 76.
- [21] 张 涛, 李 伟, 王建军. 基于知识图谱与深度学习的旋转机械故障诊断 [J]. *机械工程学报*, 2018, 54 (23): 102 - 111.
- [22] American National standard Institute. Condition monitoring and diagnostics of machines-Data processing, communication and presentation-Part 4: Knowledge graph representation; ISO 13374-4 [S]. Geneva, International Organization for Standardization, 2019: 5 - 36.
- [23] 高佳鑫. 基于知识图谱的道岔转辙机故障诊断研究 [D]. 太原: 中北大学, 2022.
- [24] 高少帅. 基于知识图谱的高铁运维咨询问答技术研究与应用 [D]. 北京: 北京交通大学, 2022.
- [25] 王勇超, 罗胜文, 杨英宝, 等. 知识图谱可视化综述 [J]. *计算机辅助设计与图形学学报*, 2019, 31 (10): 1666 - 1676.
- [26] 张博文, 张敏杰, 侯田钰, 等. 变压器故障知识图谱构建关键技术研究及应用 [J]. *电力信息与通信技术*, 2022, 20 (10): 44 - 53.
- [27] XIAO N, PENG B, LI J S Y. Research on the construction and implementation of power grid fault handling knowledge graphs [J]. *Energy Reports*, 2023, 9 (Suppl. 2): 182 - 189.
- [28] 盛 林, 马 波, 张 杨. 基于知识图谱的旋转机械故障诊断方法 [J]. *机电工程*, 2022, 39 (9): 1194 - 1202.
- [29] 王晴雯, 张振海. 基于知识图谱的信号设备故障诊断方法 [J]. *铁道标准设计*, 2022, 66 (12): 149 - 156.
- [30] TANG Y C, LIU T T, LIU G Y, et al. Enhancement of power equipment management using knowledge graph [C] // Chengdu: Proceedings of the 2019 IEEE Innovative Smart Grid Technologies-Asia, 2019: 905 - 910.
- [31] 周安美, 于德介, 吴雪明, 等. 基于本体的大型风力发电机组故障智能诊断研究 [J]. *中国机械工程*, 2012, 23 (17): 2075 - 2079.
- [32] 刘佳伟, 王军生, 金 鹏, 等. 面向智能制造的知识图谱驱动设备故障诊断方法研究 [C] // 重庆: 第十四届中国钢铁年会, 2023: 1 - 11.
- [33] 范满意, 罗 凯, 马英杰, 等. 基于知识图谱的航空发动机 PHM 仿真验证平台设计 [J]. *计算机测量与控制*, 2023, 31 (6): 305 - 313.
- [34] 侯 通. 轨道电路故障文本挖掘及知识图谱构建研究 [D]. 成都: 西南交通大学, 2022.
- [35] 邵 浩, 张 凯, 李方圆, 等. 从零构建知识图谱: 技术与方法与案例 [M]. 北京: 机械工业出版社, 2021.
- [36] CHEN C, WANG T, ZHENG Y, et al. Reinforcement learning-based distant supervision relation extraction for fault diagnosis knowledge graph construction under industry 4.0 [J]. *Advanced Engineering Informatics*, 2023, 55 (1): 1 - 12.
- [37] Kusner M J, SUN Y, Kolkin N I, et al. From word embeddings to document distances [C] // Lille: International Conference on Machine Learning, 2015: 1 - 10.
- [38] 田 野, 萧 箐, 王继业, 等. 磁悬浮轴承故障知识图谱的创建与应用 [J]. *组合机床与自动化加工技术*, 2022, (9): 160 - 163.
- [39] 张 飞, 周 彬, 鲍劲松, 等. 基于超图嵌入的行车故障多元关系知识表示方法 [J]. *计算机集成制造系统*, 2024, 30 (2): 445 - 449.
- [40] 李晓波, 俎海东, 焦晓峰, 等. 基于本体的汽轮机组振动故障知识语义性表达 [J]. *热力发电*, 2021, 50 (10): 78 - 86.
- [41] 许驹雄, 李敏波, 刘孟珂, 等. 发动机故障领域知识图谱构建与应用 [J]. *计算机系统应用*, 2022, 31 (7): 66

- 76.
- [42] 张欢欢,洪蒙纳,李继庚. 基于知识图谱和贝叶斯推理的断纸故障诊断模型[J]. 造纸科学与技术, 2024, 43(2): 39-43.
- [43] 曾旻冬,李 宁,李红仁,等. 基于知识图谱的燃气轮机故障诊断知识库构建方法及维护[J]. 电力大数据, 2023, 26(4): 44-55.
- [44] 赵 倩. 数控设备故障知识图谱的构建与应用[J]. 航空制造技术, 2020, 63(3): 96-102.
- [45] 孙 博. 基于时序知识图谱的机电设备故障预测研究与实现[D]. 北京: 北京交通大学, 2021.
- [46] 薛 莲,姚新文,郑启明,等. 高铁列车车载设备故障知识图谱构建方法研究[J]. 铁道科学与工程学报, 2023, 20(1): 34-43.
- [47] 范 琪,章健军,王庚平,等. 基于知识图谱的变电站智能故障诊断研究[J]. 电子技术与软件工程, 2022, 20(1): 109-112.
- [48] 王 萌,王昊奋,李博涵. 新一代知识图谱关键技术综述[J]. 计算机研究与发展, 2022, 59(9): 1947-1965.
- [49] 邱云飞,邢浩然,李 刚. 矿井建设知识图谱构建研究综述[J]. 计算机工程与应用, 2023, 59(7): 64-79.
- [50] 黄 微,卢国强,赵 旭. 基于知识图谱的微博主题演变路径研究[J]. 情报理论与实践, 2022, 45(3): 173-181.
- [51] Rau L F. Extracting company names from text [C] // San Diego: Proc of the 7th IEEE Conference on Artificial Intelligence Application, 1991: 29-32.
- [52] LIU X, ZHANG S, WEI F, et al. Recognizing named entities in tweets [C] // Portland: Proc of the 49th Annual Meeting of the Association for Computational linguistics: Human Language Technologies, 2011: 359-367.
- [53] Peters M, Ammar W, Bhagavatula C, et al. Semi-supervised sequence tagging with bidirectional language models [C] // Vancouver: Proc of the 55th Annual Meeting of the Association for Computational Linguistics (ACL), 2017: 1-10.
- [54] 史海峰. 基于CRF的中文命名实体识别研究[D]. 苏州: 苏州大学, 2010.
- [55] WANG Y, YU B, ZHU H, et al. Discontinuous named entity recognition as maximal clique discovery [C] // Bangkok: Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing, 2021: 1-4.
- [56] DAI X, Karimi S, Hachey B, et al. An effective transition-based model for discontinuous NER [C] // Seattle: Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, 2020: 1-5.
- [57] SUN Q N, Jankovic M V, Bally L, et al. Predicting blood glucose with an LSTM and Bi-LSTM based deep neural network [C] // Belgrade: 2018 14th Symposium on Neural Networks and Applications (NEUREL), 2018: 1-5.
- [58] LI Y C, Yangkyi J, C Zong, et al. Research and implementation of Tibetan automatic word segmentation based on conditional random field [J]. Journal of Chinese Information Processing, 2013, 27(4): 52-58.
- [59] 杨 飘,董文永. 基于BERT嵌入的中文命名实体识别方法[J]. 计算机工程, 2020, 46(4): 40-45.
- [60] 尹昱东,王保建,李珂嘉,等. 基于模型的机床故障案例命名实体抽取方法比较研究[J]. 计算机测量与控制, 2024, 32(6): 27-34.
- [61] YE N, QIN X, DONG L, et al. Chinese named entity recognition based on character-word vector fusion [J]. Wireless Communications and mobile computing, 2020, 2020(3): 1-7.
- [62] LI X, DENG Q. Chinese position segmentation based on ALBERT-BiGRU-CRF Model [C] // Guilin: 2021 International Symposium on Computer Technology and Information Science, 2021: 116-120.
- [63] 唐 钰,唐加山. 一种改进的TF-IDF文本分类算法[J]. 信息技术与信息化, 2022(3): 13-16.
- [64] 嵇文路,邓 星,朱红勤,等. 基于知识图谱的报文故障分析与检索[J]. 应用科学学报, 2023, 41(3): 378-390.
- [65] HUANG W, CHENG X, WANG T, et al. Bert-based multi-head selection for joint entity-relation extraction [C] // Cham: Springer International Publishing, 2019: 713-723.
- [66] FU T J, LI P H, MA W Y. Graphrel: modeling text as relational graphs for joint entity and relation extraction [C] // Florence: Association for Computational Linguistics, 2019: 1409-1418.
- [67] 孙 亮. 基于知识图谱的穿越钻机故障知识库构建研究与应用[J]. 安全技术, 2022, 22(5): 28-35.
- [68] 陈 曦. 基于领域知识图谱的柴油发动机故障诊断研究[D]. 哈尔滨: 哈尔滨工业大学, 2021.
- [69] 蒋 文. 基于深度学习的数控机床故障知识图谱构建研究[D]. 包头: 内蒙古科技大学, 2022.
- [70] 陈云飞. 数据驱动的机床故障诊断知识图谱构建与预测维护研究[D]. 西安: 长安大学, 2021.
- [71] 栗佳初,朱永利. 基于双向图神经网络的变压器故障知识图谱构建[J]. 电力科学与工程, 2023, 39(9): 38-45.
- [72] 叶欣智,尚 磊,董旭柱,等. 面向配电网故障处置的知识图谱研究与应用[J]. 电网技术, 2022, 46(10): 3739-3748.

- [73] 赵晓娟, 贾 焰, 李爱平, 等. 多源知识融合技术研究综述 [J]. 云南大学学报: 自然科学版, 2020, 42 (207): 65-79.
- [74] 唐获音, 丁奕州, 王 轩, 等. 面向多源异构数据的航天器故障知识图谱构建方法 [J]. 空间控制技术与应用, 2023, 49 (4): 40-49.
- [75] LU Y C, WEN Y J, LI X, et al. Exploration of the construction and application of knowledge graph in equipment failure [C] // Shanghai: Science and Engineering Research Center, 2017: 147-152.
- [76] Mophan P, Sundaram M, Satpathy S D S. An efficient technique for cloud storage using secured de-duplication algorithm [J]. Journal of Intelligent & Fuzzy Systems: Applications in Engineering and Technology, 2021, 41 (2): 2969-2980.
- [77] 韦 伟, 郑 杨, 袁嘉梁, 等. 轨道交通设备故障知识图谱构建与应用研究 [J]. 中国新技术新产品, 2023 (17): 53-55.
- [78] 钟保强, 钟建棚, 余 俊, 等. 基于知识图谱的 IT 设备故障分析方法研究 [J]. 电子设计工程, 2022, 30 (14): 48-52.
- [79] 张 靖, 方 锐, 周 婕, 等. 基于知识图谱与优化数据架构的电力服务系统设计 [J]. 电子设计工程, 2023, 31 (20): 145-149.
- [80] 李 景, 李国鹏. RDF 标准在元数据描述中的应用研究 [J]. 标准科学, 2017, 2017 (8): 73-77.
- [81] FENG Y, ZHAI F, LI B F, et al. Research on intelligent fault diagnosis of power acquisition based on knowledge graph [C] // Xiamen: 2019 3rd International Conference on Electronic Information Technology and Computer Engineering, 2019: 1737-1740.
- [82] 姜惠娟, 郭文龙. 基于 Neo4j 的药膳方图数据库设计与优化 [J]. 中央民族大学学报 (自然科学版), 2019, 28 (3): 48-55.
- [83] CHEN X, JIA S, XIANG Y. A review: Knowledge reasoning over knowledge graph [J]. Expert Systems with Applications, 2020, 141 (1): 1-21.
- [84] WANG W Y, Mazaitis K, Cohen W W. Programming with personalized page rank: a locally groundable first-order probabilistic logic [C] // Sydney: Proceedings of the 22nd ACM international conference on Information & Knowledge Management, 2013: 2129-2138.
- [85] 李 聪, 石义官, 黄 权, 等. 基于深度学习的小口径弹药装配设备故障诊断专家系统 [J]. 兵工自动化, 2023, 42 (6): 20-26.
- [86] BORDES A, USUNIER N, GARCIA-DAN A, et al. Translating embeddings for modeling multi-relational data [J]. Curran Associates Inc, 2013, 2013 (1): 1-9.
- [87] WANG Z, ZHANG J, FENG J, et al. Knowledge graph embedding by translating on hyperplanes [C] // Quebec: Proceedings of the AAAI Conference on Artificial Intelligence, 2014: 1112-1119.
- [88] LIN Y, LIU Z, SUN M, et al. Learning entity and relation embeddings for knowledge graph completion [C] // Austin: Proceedings of the AAAI Conference on Artificial Intelligence, 2015: 2181-2187.
- [89] JI G, HE S, XU L, et al. Knowledge graph embedding via dynamic mapping matrix [C] // Beijing: Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing, 2015: 687-696.
- [90] JIA Y, WANG Y, LIN H, et al. Locally adaptive translation for knowledge graph embedding [C] // Phoenix: Thirtieth AAAI conference on artificial intelligence, 2016: 992-998.
- [91] VV T, NGUYEN T D, NGUYEN D Q, et al. A capsule network-based embedding model for knowledge graph completion and search personalization [C] // Minneapolis: Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, 2019: 2180-2189.
- [92] SUN Z, DENG Z H, NIE J Y, et al. Rotate: Knowledge graph embedding by relational rotation in complex space [J]. ArXiv, 2019, 2019 (1): 1-18.
- [93] 李志博, 李媛媛, 蔡 寅. 卷积神经网络与知识图谱结合的轴承故障诊断 [J]. 噪声与振动控制, 2024, 44 (2): 156-163.
- [94] 陈 柯, 谭屈山, 王 佳, 等. 基于知识图谱的柴油发动机故障诊断研究与系统设计 [J]. 现代信息科技, 2024, 8 (10): 112-117.
- [95] 马亚杰, 刘 洋, 姜 斌, 等. 基于异构图注意力的工业设备故障诊断知识图谱补全方法 [J]. 中国科学: 信息科学, 2024, 54 (2): 354-372.
- [96] 张永珍, 陈秀玲, 李 明. 高速公路机电设备智能运维系统建设 [J]. 中国交通信息化, 2024, 2024 (1): 114-117.
- [97] 刘 鑫. 面向故障分析的知识图谱构建技术研究 [D]. 北京: 北京邮电大学, 2019: 15-26.
- [98] 谈 群, 苗洪雷, 秦 拯. 基于知识图谱的水电站设备故障根因分析方法 [J]. 人民长江, 2024, 55 (2): 259-264.
- [99] 杨慕嘉. 基于图神经网络的知识图谱推荐算法研究 [D]. 北京: 北京邮电大学, 2020: 18-57.
- [100] 李书剑, 庞天枫, 杨泰波, 等. 反应堆关键设备状态数据标准化研究 [J]. 计算机测量与控制, 2023, 31 (6): 198-203.