

DOI:10.3969/j.issn.1001-4551.2022.09.003

基于知识图谱的旋转机械故障诊断方法 *

盛 林¹, 马 波^{1,2*}, 张 杨¹

(1. 北京化工大学 机电工程学院, 北京 100029; 2. 北京化工大学
高端机械装备健康监控与自愈化北京市重点实验室, 北京 100029)

摘要: 对旋转机械进行故障诊断时, 在输入征兆条件缺失的情况下, 采用传统的基于规则的故障诊断推理方法, 其诊断结果会出现较大的偏差。针对这一问题, 提出了一种基于知识图谱的旋转机械故障诊断推理方法。首先, 阐述了基于本体的旋转机械故障诊断知识表示方法, 通过构建旋转机械故障诊断知识本体表示模型进行了知识表达, 在此基础上构建了旋转机械故障诊断的知识图谱; 然后, 结合基于关系路径的知识图谱推理方法, 提出了基于知识图谱的旋转机械故障诊断方法, 利用旋转机械设备结构间关系进行了故障原因推理; 最后, 以核电厂主泵为例, 构建了主泵故障诊断的知识图谱, 对基于知识图谱的旋转机械故障诊断方法进行了验证。研究结果表明: 在输入征兆缺失的条件下, 采用该方法得到的故障诊断准确率达到 92.1%, 远高于传统的基于规则的故障诊断推理方法的准确率, 有效地解决了以往征兆缺失时故障诊断准确率低的问题; 同时, 知识图谱的应用也可为其他机械设备智能诊断方法提供一种新的思路。

关键词: 知识图谱构建; 输入征兆缺失; 基于本体的知识表示方法; 解析模型; 数据驱动; 基于规则的故障诊断方法

中图分类号: TH17; TH133; TM623

文献标识码:A

文章编号: 1001-4551(2022)09-1194-09

Fault diagnosis method for rotating machinery based on knowledge graph

SHENG Lin¹, MA Bo^{1,2}, ZHANG Yang¹

(1. College of Mechanical and Electrical Engineering, Beijing University of Chemical Technology, Beijing 100029, China; 2. Beijing Key Laboratory of High End Mechanical Equipment Health Monitoring and Self Recovery, Beijing University of Chemical Technology, Beijing 100029, China)

Abstract: In the fault diagnosis of rotating machinery, when the input symptom conditions were missing, the traditional rule-based fault diagnosis reasoning method would have a large deviation in the diagnosis results. Aiming at the problem, a rotating machinery fault diagnosis method based on knowledge graph was proposed. Firstly, an ontology-based knowledge representation method for rotating machinery fault diagnosis was described, and knowledge representation was carried out by constructing an ontology representation model for rotating machinery fault diagnosis knowledge, on the basis of which a knowledge graph for rotating machinery fault diagnosis was constructed. Then, combined with the path-based knowledge graph inference method, the diagnosis method based on knowledge graph of rotating machinery fault diagnosis was proposed, and the reasons of fault were inferred by using the relationship between structures of rotating machinery equipment. Finally, taking the main pump of nuclear power plant as an example, the knowledge map of main pump fault diagnosis was constructed, and the rotating machinery fault diagnosis method based on knowledge map was verified. The results of experimental validation show that the diagnostic accuracy of the method reaches 92.1% under the condition of missing symptoms. It is far better than the accuracy of the traditional rule-based fault diagnosis reasoning method, and effectively solves the problem of low diagnostic accuracy when the symptoms are missing. At the same time, the application of knowledge graph can also provide a new idea for other intelligent diagnosis methods of mechanical equipment.

Key words: knowledge graph construction; input symptom missing; ontology-based knowledge representation method; analytical models; data-driven; rule-based fault diagnosis method

收稿日期: 2022-03-14

基金项目: 国家自然科学基金资助项目(61673046, 52075030)

作者简介: 盛林(1997-), 男, 安徽亳州人, 硕士研究生, 主要从事旋转机械智能故障诊断方面的研究。E-mail: shenglin1234567890@126.com

通信联系人: 马波, 男, 教授, 硕士生导师。E-mail: mabo@mail.buct.edu.cn

0 引言

目前,旋转机械在现代工业生产领域已得到了广泛的应用。旋转机械一旦发生故障,将会造成很大的经济损失与社会危害^[1]。

为了提高旋转机械的可靠性,对旋转机械进行故障智能诊断研究具有重要的工程意义。

目前,传统故障诊断方法一般可以分为3大类:(1)基于解析模型的故障诊断方法;(2)基于数据驱动的故障诊断方法;(3)基于知识的故障诊断方法^[2]。

基于解析模型的故障诊断方法一般采用数学公式,将真实过程抽象成精确解析模型,通过计算模型输出值与实际测量值的残差来进行诊断。

刘志刚等人^[3]采用了候选最小冲突集,成功将基于模型的诊断方法应用到了牵引变电站的电气设备的故障诊断中。张永强等人^[4]基于 ARX 模型,提出了一种通过模型匹配的转子故障诊断方法。杨诚等人^[5]提出了一种新的 Volterra-PARAFAC 预测模型,用于对滚动轴承故障进行诊断,解决了该模型用于复杂机械系统非线性特征提取时估计参数过多的问题。

但是,该诊断方法依赖于对故障过程机理的深入了解,一旦解析模型与实际情况不符,则会造成较大的诊断偏差,对于机理复杂、工况多变的旋转机械设备适用性差。

基于数据驱动的故障诊断方法针对设备监测数据进行多方面的数据分析、处理,提取设备的故障特征,对故障进行诊断。该方法是否成功运用的关键在于对故障特征的提取是否准确。

苏乃权等人^[6]提出了一种基于高价值小样本的故障诊断 NN 模型进行故障诊断的方法,其具有特征提取准确、故障识别能力强的特点,有效地解决了旋转机械故障类型识别难的问题。廖玉波等人^[7]采用了基于 Fisher Score 与域间最大均值差异的特征选取方法,选取了判别性能和域不变性好的特征,构建了迁移深度置信网络;采用该方法后,明显提高了旋转机械故障诊断的准确率。马波等人^[8]提出了一种基于专家思维的多维度故障诊断方法,依据故障机理、故障响应特点及故障劣化规律,选择相关测点、多时间点的数据,构建了敏感参数矩阵,并生成了对应的故障矩阵和权重矩阵,进行了故障的诊断。WANG Qing-feng 等人^[9]提出了一种多敏感特征的滚动轴承故障诊断模型构建方法,利用了美国凯斯西储大学(CWRU)故障数据训练故障诊断模型,该方法具备较高的故障诊断精度。

上述基于数据驱动的故障诊断方法不依赖于精确

的机理模型,同时将计算机强大的计算能力与故障诊断结合在一起,对设备故障诊断具有一定的普适性。但是,采用该类方法得到的诊断结果由于缺少故障知识和过程知识的支撑,其解释性受到一定的限制^[10]。

基于知识的故障诊断方法具有良好的可解释性,不需要构建复杂的数学机理模型,同时还可以更新故障知识。因其具有一系列的优点,该诊断方法引起了业界科研人员的广泛关注。

张强等人^[11]提出了一种基于置信度的不确定性推理方法,对汽轮发电机组故障进行了规则推理,在诊断结果不确定或无结果时,采用案例推理机制进行了推理,有效地提高了汽轮发电机组的诊断效率。尚文等人^[12]采用了条件规则和故障树法相结合的诊断方法,增加了具体故障分析的条件规则,确定故障树每个分支的诊断选择,实现了对燃气轮机的快速、准确的诊断维护。YAN Chang-feng 等人^{[13]4448}建立了一种基于规则推理和案例推理的汽轮发电机组故障诊断系统,以基于规则的推理为案例推理提供支持,提高了故障诊断的效率。WAN Shan 等人^[14]提出了一种基于案例推理的机床维护规划系统,提高了机床维护计划的效率。

基于知识的故障诊断方法虽然无需针对旋转机械建立复杂的机理模型,且其结果的可解释性强,但是该方法仍缺乏对旋转机械故障诊断知识及其耦合知识联系进行进一步挖掘利用,且对诊断输入的准确性要求很高^{[15]1378},在输入征兆条件缺失的情况下,其诊断结果也会出现较大的偏差。

知识图谱概念的提出,最初是为搜索引擎服务的。随着人工智能技术的发展,知识图谱技术已在医疗领域^[16]、电商领域^[17]、领域知识管理^[18]等方面得到了应用。许多学者针对基于知识图谱技术的智能故障诊断方法进行了研究。

许祺^[19]采用深度学习技术,完成了对 CNC 故障诊断领域知识实体识别任务,建立了 CNC 故障诊断知识图谱,并结合知识图谱搜索算法,实现了故障诊断。赵倩^[20]采用数据驱动的增量式本体构建技术,建立了数控设备的故障本体模型,构建出了数控设备故障领域知识图谱,提高了历史故障知识利用率和故障诊断效率。车金立等人^[21]利用装备维修保障内部数据源进行了关键信息抽取,建立了装备维修保障的知识图谱,并通过装备维修保障知识图谱的应用,证明了知识图谱能支撑维修保障、辅助决策多种应用。

上述研究结果表明:将知识图谱技术运用到故障诊断领域,能够准确、全面地对故障诊断知识及其联系进行描述,同时还能为故障诊断推理提供新的解决

思路。

笔者采用基于本体的表示方法,对旋转机械故障诊断知识进行知识表示,建立旋转机械故障诊断知识图谱,并结合知识图谱推理方法,提出旋转机械的故障诊断方法,以有效地解决故障征兆缺失时诊断结果准确率低的问题。

1 理论背景

1.1 知识图谱

知识图谱本质上可以理解为一种揭示实体之间关系的语义网络,由形如“实体-关系-实体”三元组结构的数据进行相互连接组成^[22]。实体是知识图谱中最基本的元素,通过两两间的关系进行连接,进而形成结构化的知识网络。

由三元组作为基本组成结构的知识图谱示意图,如图 1 所示。

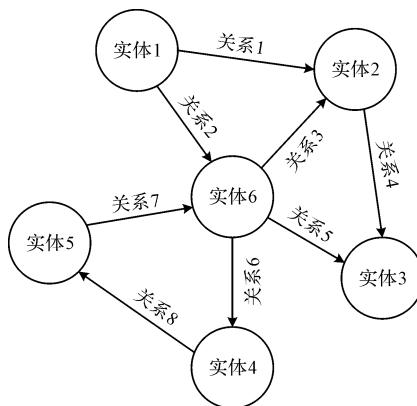


图 1 知识图谱示意图

1.2 基于本体的知识表示方法

基于本体的知识表示方法在计算机人工智能领域中,能够精确定义、表示某一领域的概念、概念属性、概念间关系以及关系属性,揭示概念之间的内在关系,使知识管理与共享更简便、灵活^[23],这些本体定义描述能够被计算机理解,同时也能被领域所接受。

根据 NAING MM 博士提出的六元素表示法^[24],可将知识本体(knowledge ontology, KO)定义为:

$$KO = \langle C, A^C, R, A^R, I \rangle \quad (1)$$

式中: C —不同概念的集合; R —不同关系的集合; A^C —概念属性的集合; A^R —关系属性的集合; I —概念实例的集合。对上述定义作进一步说明:

(1) 概念定义与实例定义

概念集合可以进一步表示为:

$$C = \{C_i | C_i = C_1, C_2, \dots, C_n, i = 1, 2, \dots, n\} \quad (2)$$

式中: n —本体表示模型中类概念的类别数。

概念实例集合 I 中,每一个实例都是本体概念的实例化表示,即:

$$I = \{I_t | I_t \in C_i, t = 1, 2, \dots, m\} \quad (3)$$

式中: m —实例集合 I 中概念实例个数。

(2) 关系定义

设 C_s, C_t 分别是概念集合 C 中的第 s, t 个概念,且 C_s, C_t 都包含于概念集合 C 中,对于任意的概念元素 C_t ,存在概念元素 C_s ($s \neq t$, 且 $1 \leq s, t \leq n$),满足:

$$C_s = R(C_t) \quad (4)$$

式中: R —概念元素 C_s, C_t 之间的关系,记作 $R(C_s, C_t)$ 。

在同一个概念集合中,使用这种映射关系 $R(C_s, C_t)$ 来表示概念集合中各概念之间的基本关系,如父类与子类的继承关系。各概念实例间关系继承式(4)表示的定义,也即实例元素 I_s, I_t 之间的关系可以记作 $R(I_s, I_t)$ 。

(3) 属性定义

对本体表示模型中的概念属性集合作如下定义:
 $A^C = \{title, id\}$ 。

其中: id —本体的 id 属性,为一数字数值,在知识图谱中数值唯一; $title$ —本体的名称属性,用于表示概念的名称。

对本体表示模型中的关系属性集合作如下定义:
 $A^R = \{type, id\}$ 。

其中: id —与概念属性中定义相同; $type$ —关系类别属性,用于表示关系的名称。

1.3 基于关系路径的知识图谱推理方法

在基于关系路径的知识图谱推理中,主要通过实体间的多步路径来寻找它们之间的语义关系^[25]。在知识图谱中,定义:

$$R(e) \equiv \{e': R(e, e')\} \quad (5)$$

式中: R —实体间的二元关系; e, e' —知识图谱中实体对; $R(e, e')$ —表示实体对 e, e' 存在关系 R 。

关系路径 P 由关系 R_1, R_2, \dots, R_n 组成,且对任意的整数 i ($1 < i < n - 1$),有:

$$range(R_i) \equiv domain(R_{i+1}) \quad (6)$$

式中: $domain(R)$ —关系 R 的定义域; $range(R)$ —关系 R 的值域。

令:

$$domain(R_1 R_2 \cdots R_n) = domain(R_1) \quad (7)$$

$$range(R_1 R_2 \cdots R_n) = range(R_n) \quad (8)$$

着重强调路径中每个步骤关联的关系类型时,将路径 $P = R_1 R_2 \cdots R_n$ 表示为:

$$T_0 \xrightarrow{R_1} \cdots \xrightarrow{R_n} \cdots T_n \quad (9)$$

式中: T_0 —可表示为 $T_0 = \text{dom}(R_1) = \text{dom}(P)$; T_1 —可表示为 $T_1 = \text{range}(R_1) = \text{dom}(R_2)$; 其余节点 T_i 以此类推。

在关系路径中,实体之间的关系一般是带有方向的,使用符号 R^{-1} 表示头实体与尾实体颠倒方向后的逆方向,与 R 互为逆关系,有 $A \xrightarrow{R_1} B$ 等价于 $B \xrightarrow{R_1^{-1}} A$ 。多级关系路径的示意图如图2所示。

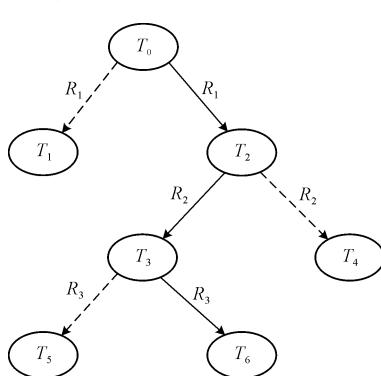


图2 多级关系路径示意图

图2中,实体 T_0 和 T_6 间的多级关系路径可以表示为:

$$T_0 \xrightarrow{R_1} T_2 \xrightarrow{R_2} T_3 \xrightarrow{R_3} T_6 \quad (10)$$

式中: T_2 —关系 R_1 的值域 $\text{range}(R_1)$; T_3 —关系 R_2 的值域 $\text{range}(R_2)$; T_6 —关系 R_3 的值域 $\text{range}(R_3)$ 。

2 基于知识图谱的旋转机械故障诊断方法

采用知识图谱技术构建旋转机械的故障诊断领域知识图谱,能够对设备故障诊断知识进行全面、准确地表达,同时能有效利用故障诊断知识间的关系,解决输入征兆缺失时,难以对旋转机械的故障进行准确诊断的问题。

笔者提出的基于知识图谱的旋转机械故障诊断方法包括两部分:(1)知识图谱构建;(2)基于知识图谱进行诊断推理。其具体步骤为:首先采用基于本体的知识表示方法构建知识图谱;然后利用基于知识图谱关系路径的推理方法进行诊断推理。

2.1 知识图谱的构建

2.1.1 知识本体表示

采用基于本体的知识表示方法,可将旋转机械故障诊断领域知识本体(rotating machine fault diagnosis ontology, RMFDO)表示如下:

$$\text{RMFDO} = \langle C, A^C, R, A^R, I \rangle \quad (11)$$

式中: C —本体概念的集合; R —本体关系的集合; A^C —

概念的属性; A^R —关系的属性; I —实体元素的集合。

可将旋转机械故障诊断知识分为5个不同类别的本体,本体概念集合表示为:

$$C = \{C_1, C_2, C_3, C_4, C_5\} \quad (12)$$

式中: C_1 —设备结构类本体概念; C_2 —测点类本体概念; C_3 —故障现象类本体概念; C_4 —故障原因类本体概念; C_5 —维修建议类本体概念。

RMFDO本体中不同类别概念间关系构成关系 R 的集合,可以表示为:

$$R = \{R_1, R_2, R_3, R_4, R_5, R_6\} \quad (13)$$

式中: R_1 —设备结构类与故障原因间的关系; R_2 —测点类与设备结构类之间的关系; R_3 —维修建议类与故障原因类之间的关系; R_4 —故障现象类与故障原因类之间的关系; R_5 —测点类与故障现象类之间的关系; R_6 —测点类与故障现象类之间的关系。

按照本体表示模型中的定义,上述各关系表示的语义关系如下:

(1) $R_1 = R_{\text{located}}(C_4, C_1)$ 表示故障发生在某个设备结构处;

(2) $R_2 = R_{\text{monitor}}(C_2, C_1)$ 表示测点监测某处设备结构;

(3) $R_3 = R_{\text{advice}}(C_4, C_5)$ 表示针对故障原因需要采取的维修建议;

(4) $R_4 = R_{\text{cause}}(C_4, C_3)$ 表示故障原因造成了某种故障现象出现;

(5) $R_5 = R_{\text{relative}}(C_2, C_3)$ 表示故障现象的异常指标由该测点进行监测;

(6) $R_6 = R_{\text{hasPhe}}(C_1, C_3)$ 某个设备结构处出现了故障现象。

在旋转机械故障诊断领域知识的本体表示模型中, A^C 和 A^R 分别定义为概念属性和关系属性,直接继承本体表示模型中的定义。

实例I表示知识实体元素的集合,各实体间的关系继承概念集间的关系集合 R 。

2.1.2 知识表示

旋转机械故障诊断领域知识图谱的结构关系可分为2大类:(1)本体概念层次图;(2)知识实体关系图。

该处笔者以主泵漏气阀的故障为例,展示旋转机械故障诊断领域知识图谱模式层与数据层之间的相互对应关系。

旋转机械故障诊断领域知识图谱,如图3所示。

笔者将旋转机械故障诊断知识表示为三元组结构: $\langle \text{实体}, \text{关系}, \text{实体} \rangle$,并采用图数据库对旋转机械故障诊断领域知识进行存储。图数据库以节点表示实

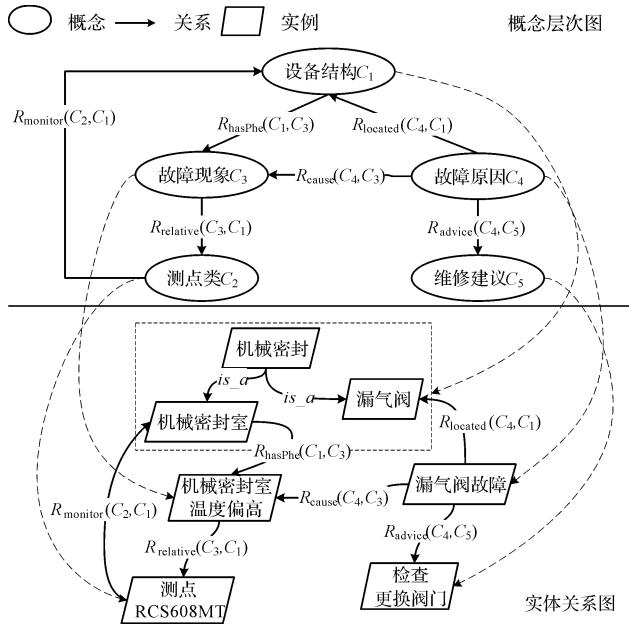


图 3 旋转机械故障诊断领域知识图谱

体,与三元组中实体相对应;以带方向的边表示知识间的关系,与三元组中关系相对应。

旋转机械故障诊断领域知识图谱实体关系的三元组示例,如表 1 所示。

表 1 实体关系三元组示例

实体 1	关系	实体 2
机械密封	is_a	机械密封室
机械密封	is_a	漏气阀
机械密封室	hasPhe	机械密封室温度偏高
机械密封室温度偏高	relative	测点 RCS608MT
测点 RCS608MT	monitor	机械密封室
漏气阀故障	located	漏气阀
漏气阀故障	advice	检查更换阀门
漏气阀故障	cause	机械密封室温度偏高

表 1 中,实体关系的三元组在图数据库中存储后,如图 4 所示。

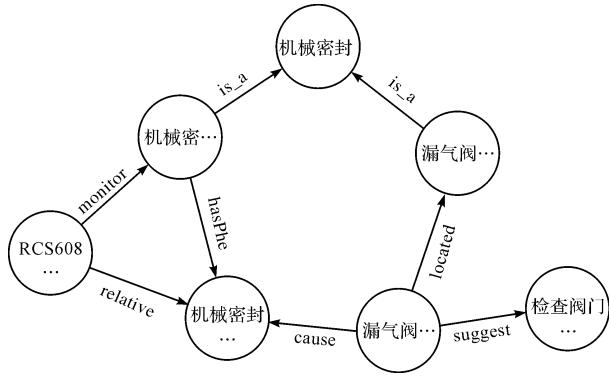


图 4 知识图谱示例

2.2 基于知识图谱的诊断推理方法

笔者根据旋转机械知识图谱的图结构特点,结合

基于关系路径的知识图谱推理方法,提出了基于知识图谱的旋转机械故障诊断推理方法。

其诊断推理方法流程图,如图 5 所示。

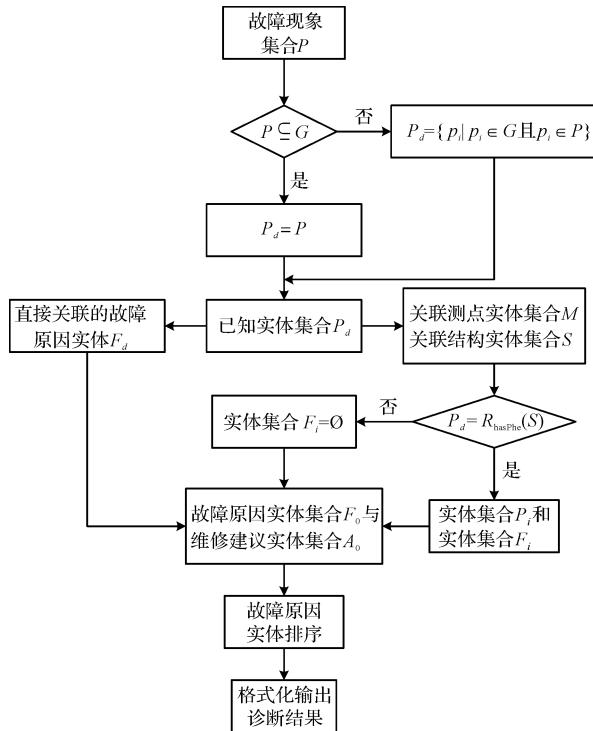


图 5 基于知识图谱关系路径的诊断推理流程

推理方法的详细步骤如下所述:

(1) 输入故障现象的集合 $P = \{p_1, p_2, \dots, p_n\}$, n 为正整数;

(2) 遍历故障现象集合 P ,是否满足 $P \subseteq G$ (其中 G 表示图谱中所有实体的集合),若满足该条件,则下一步用于推理的已知实体集合为 $P_d = P$;若不满足上述条件,对集合 P 进行操作,剔除集合 P 中不在知识图谱 G 中的实体元素后,得到实体集合 $P_d = \{p_i | p_i \in G \text{ 且 } p_i \in P\}$;

(3) 将实体集合 P_d 作为搜索用的已知实体集合,由已知实体集合 P_d 根据关系路径 $R_{cause}^{-1}(C_4, C_3)$,引入与实体集合 P_d 直接关联的故障原因实体集合 $F_d = range(R_{cause}^{-1}(C_4, C_3))$,直接关联原因的搜索路径可表示为 $P_d \xrightarrow{R_4^{-1}} F_d$;

(4) 由已知实体集合 P_d 根据关系路径 $R_{relative}^{-1}(C_2, C_3)$,引入与实体集合 P_d 相关联的关联测点实体集合 $M = range(R_{relative}^{-1}(C_2, C_3))$;根据关系路径 $R_{monitor}(C_2, C_1)$,引入关联设备结构实体的集合 $S = range(R_{monitor}(C_2, C_1))$;

(5) 验证关联结构实体集合 S 与故障现象集合 P_d 是否存在关系路径 $R_{hasPhe}(C_1, C_3)$,也即关系 $P_d =$

$\text{range}(R_{\text{hasPhe}}(C_1, C_3))$ 是否存在;

(6)若关系存在,由关联设备结构实体集合 S 根据关系路径 $R_{\text{hasPhe}}(C_1, C_3)$,引入间接关联故障现象实体集合 $P_i = \text{range}(R_{\text{hasPhe}}(C_1, C_3))$;由间接关联故障现象实体集合 P_i 根据关系路径 $R_{\text{cause}}^{-1}(C_4, C_3)$,引入与故障现象集合 P_d 间接关联的故障原因集合 $F_i = \text{range}(R_{\text{cause}}^{-1}(C_4, C_3))$;若不存在,则间接关联的故障原因集合 $F_i = \emptyset$;间接关联原因的搜索路径可表示为: $P_d \xrightarrow{R_5^{-1}} M \xrightarrow{R_2} S \xrightarrow{R_6} P_i \xrightarrow{R_4^{-1}} F_i$;

(7)取故障原因实体集合 $F_0 = F_d \cup F_i$,即 F_0 为直接关联故障原因集合 F_d 与间接关联的故障原因集合 F_i 的并集,由故障原因实体集合 F_0 根据关系路径 $R_{\text{advice}}(C_4, C_5)$,引入维修建议实体集合 A_0 ,有: $A_0 = \text{range}(R_{\text{advice}}(C_4, C_5))$;

(8)对故障原因集合 F_0 中的实体进行排序,排序方法如下:首先将直接关联原因放在间接关联原因之前;其次将直接关联原因中的各实体按照与实体集合 P_d 中的实体有直接关联路径的个数由多到少进行排序。排序后即得到故障原因实体集合 F_1 ,维修建议实体按照相同顺序排序得到实体集合 A_1 ;

(9)对故障原因实体集合 F_1 与维修建议实体集合 A_1 进行格式化,然后输出诊断结果。

3 实例验证

笔者以核电厂主泵为例,基于上述方法构建主泵故障诊断知识图谱,对该方法的可行性进行验证,对其诊断性能进行测试。

3.1 主泵故障诊断知识图谱构建

3.1.1 主泵故障诊断知识本体

(1)本体概念的建立

设备结构类 C_1 用于描述主泵结构的概念集合。根据主泵自身的结构组成,按照自顶向下的原则,可得到主泵各子系统、组件、部件、零件等层次结构,不同层次结构间使用父子间关系“*is_a*”表示。

部分设备结构概念本体如表 2 所示。

表 2 设备结构类概念本体

概念集	子系统	组件	部件	零件
设备结构类	轴承及油系统	轴承系统	组合轴承	主推力瓦
	密封及轴封注入系统	轴密封部分	机械密封	副推力瓦 推力盘 漏气阀 机械密封室
总计/个	6	12	16	66

测点类 C_2 用于描述监测主泵运行状态的各测点概念集合。

按照监测状态值类别的不同,可将测点分为温度测点、流量测点、压力测点等。

测点类概念本体如表 3 所示。

表 3 测点类概念本体

概念集	类别	测点本体
测点类	温度测点	测点 RCS653MT 测点 RCS645MT
	流量测点	测点 RCS150MV 测点 RCS151MV
	压力测点	测点 RCS606MP 测点 RCS601MP
	总计/个	6
		46

故障现象类 C_3 用于描述主泵发生故障时所表现出来征兆现象的概念集合。

按照征兆特征的不同,可将故障现象类概念进一步分为温度偏高、流量偏低等不同类别。

故障现象类概念本体如表 4 所示。

表 4 故障现象类概念本体

概念集	类别	故障现象本体
故障现象类	温度偏高	副推力轴承温度偏高 下径向轴承温度偏高
	流量偏低	机械密封室温度偏高 高压泄漏管线流量偏低 第一级机械密封流量偏低 电机空冷器冷却水流量偏低
	总计/个	10
		50

故障原因类 C_4 用于描述引发主泵故障的可能原因的概念集合。维修建议类 C_5 用于描述针对可能的故障原因而给出的建议的概念集合。

故障原因类概念本体与维修建议类概念本体示例,如表 5 所示。

表 5 故障原因类与维修建议类概念本体示例

概念集	概念本体	总计/个
故障原因类	泵轴不平衡	
	顶轴油管入口堵塞 轴承体损坏	32
维修建议类	停泵检修泵轴	
	解体更换组合轴承 更换副推力瓦	32

(2)本体关系的建立

根据旋转机械故障诊断知识本体表示,对主泵各本体概念间关系进行表示,如表 6 所示。

表 6 本体概念间关系示例

关系	定义域/domain	值域/range	语义关系
located	故障原因类	设备结构类	…故障位于…部位
monitor	测点类	设备结构类	…测点监测…部位
advice	故障原因类	维修建议类	…故障采用…措施维修
cause	故障原因类	故障现象类	…故障导致…现象发生
relative	测点类	故障现象类	…测点与…现象相关.
hasPhe	设备结构类	故障现象类	…部位发生…现象

3.1.2 主泵故障诊断知识表示

笔者根据所建立的主泵故障诊断知识本体,获取主泵故障诊断知识,并以三元组的形式进行表达(即相同类别的概念实例放在同一个表里,表的每列代表该类实体的属性值,每行代表该类实体的实例),同时定义好实体的标签;在此基础上,再建立三元组关系表,对关系进行标识。

笔者建立主泵故障诊断知识三元组实体表和关系表后,采用图形数据库 Neo4j 对三元组知识进行数据存储,完成主泵的故障诊断知识图谱构建。

主泵故障诊断知识图谱中整合的实体类型,如表 7 所示。

实体关系类型及相关统计信息,如表 8 所示。

构建完成后的主泵知识图谱部分关系、节点可视化图,如图 6 所示。

表 7 知识图谱实体类型及属性

实体类型	属性	举例
Structure	title,id	{ title: 上导轴承, id: 43 }
Sensor	title,id	{ title: RCS611MT, id: 112 }
Phenomenon	title,id	{ title: 上导轴承温度偏高, id: 212 }
Fault	title,id	{ title: 泵轴不平衡, id: 43 }
Suggest	title,id	{ title: 解体更换组合轴承, id: 197 }
总计/个		260

表 8 知识图谱实体关系类型及属性

实体关系类型	实体关系属性	举例
located	type	< 泵轴不平衡, type: located, 泵轴 >
monitor	type	< RCS150MV, type: monitor, 泵轴 >
advice	type	< 泵轴不平衡, type: advice, 停泵检修泵轴 >
cause	type	< 水润滑导轴承故障, type: cause, 泵轴振动值过大 >
relative	type	< RCS150MV, type: relative, 泵轴振动值过大 >
hasPhe	type	< 泵轴, type: hasPhe, 泵轴振动 1X 为主导频率 >
总计/个		479

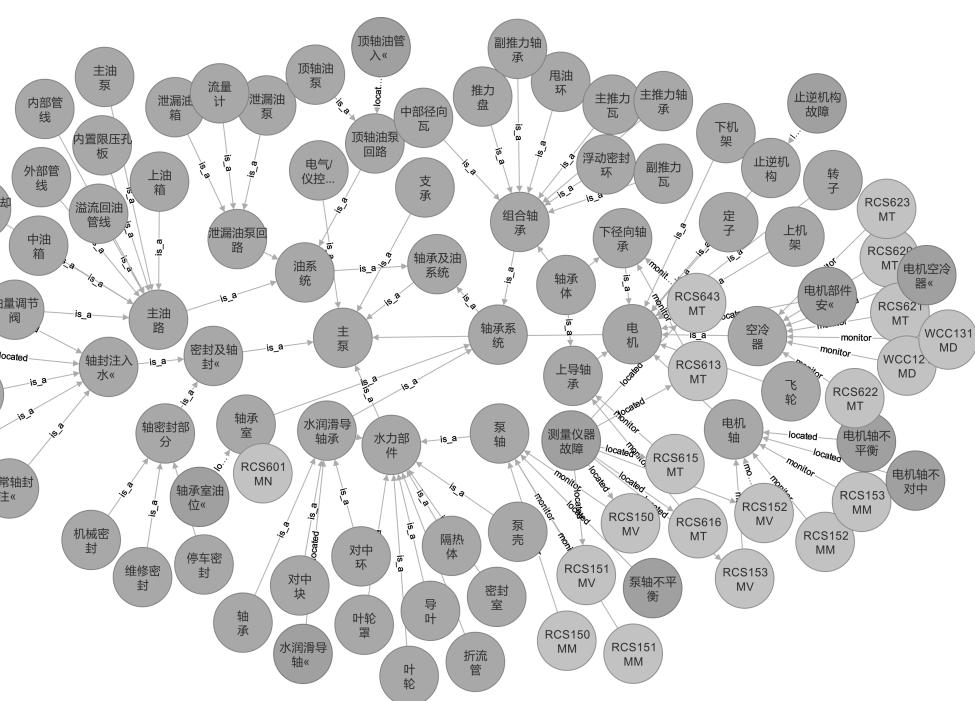


图 6 主泵知识图谱示例

3.2 基于知识图谱的诊断方法测试

为了对基于知识图谱的旋转机械诊断方法的诊断性能进行测试,笔者以某核电厂存储的主泵历史故障

案例数据为基础^[26],获取了 31 个征兆完整的故障案例,并在此基础上对测试用例进行了设计^{[15]1384}。测试用例设计步骤如下:

(1)从历史案例中获取各故障与征兆现象间的对应关系,每个故障对应有 n 个征兆;

(2)对各故障设置缺失 1 个征兆、缺失 2 个征兆…缺失 $n - 1$ 个征兆的情形,对余下的征兆进行组合,即得到测试用例。

该处以主推力瓦磨损故障对测试用例设计进行说明。该故障发生时可能出现的征兆现象,即:轴承室油位异常、中油箱温度偏高、主推力瓦温度偏高。不同征兆间的关系为“与”关系,即只有在上述征兆同时出现时,才可断定主推力瓦磨损故障发生。

用于验证诊断方法的测试用例信息,如表 9 所示。

表 9 测试用例

测试用例	示例		总计 /个
	征兆	原因	
征兆缺失	轴承室油位异常	主推力瓦磨损	202
	主推力瓦温度偏高	主推力瓦磨损	
	中油箱温度偏高	主推力瓦磨损	
	轴承室油位异常,中油箱温度偏高	主推力瓦磨损	
	轴承室油位异常,主推力瓦温度偏高	主推力瓦磨损	
	中油箱温度偏高,主推力瓦温度偏高	主推力瓦磨损	
征兆完备	轴承室油位异常,	主推力瓦磨损	31
	中油箱温度偏高,主推力瓦温度偏高		

由于输出的故障诊断结果存在包含多个可能诊断结果的情况,笔者将正确诊断结果排在输出诊断结果前两位的,认定为诊断正确。

诊断准确率计算方式:

$$c = \frac{n}{N} \quad (14)$$

式中: n —测试用例总数; N —诊断准确的测试用例数。

笔者将上述测试用例进行诊断验证,其中完整输入征兆现象的测试用例中,诊断准确的个数为 25 个,缺失征兆现象的测试用例中诊断准确的个数为 186 个。

诊断结果如表 10 所示。

表 10 诊断推理方法验证结果

测试类别	征兆完整	征兆缺失	总计
诊断准确数/个	25	186	211
测试用例数/个	31	202	233
准确率	80.6%	92.1%	90.6%

由表 10 可知:当输入征兆完整时,故障诊断准确率仅为 80.6%,这是因为在所构建的知识图谱中,故障现象与故障原因间存在一对多的映射关系,同时存在输入一条故障现象就满足诊断所需的完整故障现象

的情况。在这种情况下,笔者提出的方法会得到多条故障诊断结果,且多条诊断结果无法进一步根据已有信息进行排序。因此,反而不能得到准确的诊断结果。

3.3 方法对比

笔者将基于知识图谱的故障诊断方法与传统的基于规则的故障诊断推理方法进行对比分析,在征兆现象缺失的情况下,验证基于知识图谱的旋转机械故障诊断方法进行故障诊断的效果。

在整合的主泵故障诊断领域知识基础上,笔者对主泵故障诊断规则进行提取。主泵故障诊断规则可表示为如下形式:“IF 条件 1 AND 条件 2 AND … THEN 结论”,多个诊断前提条件间的与、或关系使用“AND”或者“OR”进行表示^{[13]4444-4445};上文中提及的主推力瓦磨损故障提取后的诊断规则可表示为:“IF 轴承室油位异常 AND 中油箱温度偏高 AND 主推力瓦温度偏高 THEN 主推力瓦磨损”。

根据整合后的主泵故障诊断知识,笔者提取出主泵故障诊断规则后,对上述 202 个缺失故障现象的测试用例进行诊断,诊断结果对比如表 11 所示(笔者提出的诊断方法为方法 1,传统的基于规则的故障诊断方法为方法 2)。

表 11 诊断结果对比

诊断方法	方法 1	方法 2
诊断准确用例/个	186	72
测试用例总数/个	202	202
诊断准确率/%	92.1	35.6

表 11 中的结果表明:方法 1 的诊断准确率为 92.1%,远高于方法 2 的诊断准确率;在征兆现象缺失时,笔者提出的方法的诊断效果远好于传统的基于规则的故障诊断推理方法,能够有效地解决征兆现象缺失时难以进行准确诊断的问题;

同时,结合表(10,11)中的诊断结果来看,基于知识图谱的旋转机械故障诊断方法的总体诊断准确率较高,达到 90.6%。

4 结束语

在对旋转机械进行故障诊断时,为了有效地解决故障征兆缺失时,采用传统的基于规则的故障诊断推理方法,进行故障诊断时出现的结果准确率低的问题,笔者采用本体知识表示方法对旋转机械故障诊断知识进行知识表达,构建旋转机械故障诊断知识图谱,并提出了基于知识图谱的旋转机械故障诊断方法,最后,以核电厂主泵为例,对该方法的有效性进行了验证,对其

诊断性能进行了测试。

研究结果表明：

(1) 在旋转机械故障诊断验证中,该方法的故障诊断准确率为 92.1%,远远高于传统的基于规则的故障诊断推理方法的准确率,可以有效解决以往因征兆缺失,而使故障诊断不准确的问题;

(2) 该方法通过知识图谱技术对设备结构间关系加以利用,并将其融入到诊断推理中。验证结果表明:该方法的测试用例的整体准确率为 90.6%,实现了对设备结构间关系的有效利用。同时,知识图谱的应用使该方法不失一般性,便于迁移运用到其他设备上,可为设备智能诊断方法提供新的思路。

在后续的工作中,笔者将在旋转机械诊断知识图谱的基础上,进一步对旋转机械故障诊断推理过程中存在的不确定性问题进行研究。

参考文献(References) :

- [1] 周君. 基于深度强化学习的旋转机械故障诊断方法研究[D]. 重庆:重庆交通大学机电工程学院, 2020.
- [2] VENKATASUBRAMANIAN V, RENGASWAMY R, YIN K, et al. A review of process fault detection and diagnosis: part i: quantitative model-based methods[J]. *Computers & Chemical Engineering*, 2003, 27(3): 293-311.
- [3] 刘志刚, 钟炜, 邓云川, 等. 牵引变电站故障的基于模型诊断方法[J]. 中国电机工程学报, 2010, 30(34): 36-41.
- [4] 张永强, 荆建平, 李亚伟, 等. 基于 AR 模型的转子典型故障诊断方法[J]. 噪声与振动控制, 2018, 38(6): 155-160.
- [5] 杨诚, 贾民平. 基于 Volterra-PARAFAC 模型的滚动轴承故障诊断方法[J]. 东南大学学报: 自然科学版, 2019, 49(4): 742-748.
- [6] 苏乃权, 蔡业彬, 张清华, 等. 基于高价值小样本的石化装置旋转机械故障诊断 NN 模型[J]. 机床与液压, 2021, 49(24): 190-194.
- [7] 廖玉波, 俞啸, 李伟生, 等. 基于深度置信网络的旋转机械迁移故障诊断[J]. 机电工程, 2022, 39(2): 193-201.
- [8] 马波, 高金吉, 江志农. 基于专家思维的多维度故障诊断方法[J]. 机械工程学报, 2017, 53(23): 32-38.
- [9] WANG Qing-feng, WANG Shuai, WEI Bing-kun, et al. Weighted k-nn classification method of bearings fault diagnosis with multi-dimensional sensitive features[J]. *IEEE Access*, 2021(9): 45428-45440.
- [10] 高洁. 基于贝叶斯网络的复杂工业过程故障诊断问题研究[D]. 杭州:浙江大学机械工程学院, 2019.
- [11] 张强, 刁昌锋, 王慧滨, 等. 基于规则与案例推理的汽轮发电机组故障诊断专家系统[J]. 电力科学与工程, 2018, 34(6): 52-59.
- [12] 尚文, 王维民, 齐鹏逸, 等. 基于条件规则与故障树法的燃气轮机故障诊断[J]. 机电工程, 2013, 30(7): 798-801, 814.
- [13] YAN Chang-feng, WANG Hui-bin, ZHOU Li-long, et al. Fault Diagnosis Expert System of Turbine Generator Sets Based on Rule Reasoning and Case Reasoning[C]//Applied Science, Materials Science and Information Technologies in Industry. Trans-Tech Publications Ltd., 2014: 4443-4448.
- [14] WAN Shan, LI Dong-bo, JAMES G, et al. A knowledge based machine tool maintenance planning system using case-based reasoning techniques[J]. *Robotics and Computer-Integrated Manufacturing*, 2019, 58(1): 80-96.
- [15] 文家富, 郭伟, 邵宏宇. 基于领域本体和 CBR 的案例知识检索方法[J]. 计算机集成制造系统, 2017, 23(7): 1377-1385.
- [16] 张利萍, 邢凯, 周慧, 等. 基于病情自述和知识图谱的疾病辅助诊断[J]. 计算机应用与软件, 2018, 35(2): 161-166.
- [17] 杜泽宇, 杨燕, 贺樸. 基于中文知识图谱的电商领域问答系统[J]. 计算机应用与软件, 2017, 34(5): 153-159.
- [18] 杨溢, 林煜明, 邹文静. 基于图模型的海量商品知识表示与管理[J]. 计算机应用与软件, 2018, 35(4): 6-9, 54.
- [19] 许祺. 基于知识图谱的 CNC 故障诊断系统[D]. 北京:北京邮电大学自动化学院, 2020.
- [20] 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.
- [21] 车金立, 唐力伟, 邓士杰, 等. 装备维修保障知识图谱构建方法研究[J]. 兵工自动化, 2019, 38(1): 15-19.
- [22] 徐增林, 盛泳潘, 贺丽荣, 等. 知识图谱技术综述[J]. 电子科技大学学报, 2016, 45(4): 589-606.
- [23] 苏正炼, 严骏, 陈海松, 等. 基于本体的装备故障知识库构建[J]. 系统工程与电子技术, 2015, 37(9): 2067-2072.
- [24] NAING M M, LIM E P, HOE-LIAN D G. Ontology-based Web Annotation Framework For Hyperlink Structures[C]//Proceedings of the Third International Conference on Web Information Systems Engineering (Workshops), 2002. Singapore: IEEE, 2002: 184-193.
- [25] 张美玉, 林崇, 简琤峰. 基于路径排序算法的 STEP 知识推理技术研究[J]. 浙江工业大学学报, 2020, 48(2): 126-132, 187.
- [26] 王秀峰, 唐国运, 刘星, 等. 气柱共振导致的核电站蒸气管道振动分析与机理研究[J]. 流体机械, 2022, 50(1): 85-91.

[编辑:全瑶]

本文引用格式:

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.

SHENG Lin, MA Bo, ZHANG Yang. Fault diagnosis method for rotating machinery based on knowledge graph[J]. *Journal of Mechanical & Electrical Engineering*, 2022, 39(9): 1194-1202.

《机电工程》杂志: <http://www.meem.com.cn>