



基于知识图谱和多任务学习的工业生产关键设备故障诊断方法

卞嘉楠¹, 冒泽慧^{1*}, 姜斌¹, 马亚杰¹, 刘文静^{2,3}

1. 南京航空航天大学自动化学院, 南京 211106

2. 北京控制工程研究所, 北京 100190

3. 空间智能控制技术重点实验室, 北京 100190

* 通信作者. E-mail: zehuimao@nuaa.edu.cn

收稿日期: 2022-02-07; 修回日期: 2022-04-13; 接受日期: 2022-05-14; 网络出版日期: 2023-04-11

科技创新 2030—“新一代人工智能”重大项目 (批准号: 2020AAA0109305) 和思源联盟 2021 年开放基金项目 (批准号: HTKJ2021KL502020) 资助

摘要 针对工业生产关键设备故障数据稀疏的问题和故障诊断的需求, 本文提出了一种基于知识图谱和多任务学习的工业生产关键设备故障诊断模型 MKFD (multi-task learning for knowledge graph-enhanced fault diagnosis), 通过对故障根因的推断实现故障诊断. 设计了多任务学习框架, 并构造了一种改进十字绣单元用于实现框架内子任务之间的信息共享. 利用运维数据构建故障现象-故障根因关联矩阵, 使用多层感知机搭建知识图谱嵌入模型; 分别将关联矩阵嵌入和知识图谱嵌入作为多任务学习框架中的两个子任务, 通过子任务的交替学习, 优化 MKFD 模型参数, 实现对故障根因的推断, 从而达到故障诊断的目的. 最后, 基于国内某工业企业的运维数据所构建的两个工业生产关键设备故障知识图谱对上述方案进行了验证实验, 结果证明所提出的方法具有良好的性能.

关键词 故障诊断, 知识图谱, 多任务学习, 工业生产关键设备, 推荐系统

1 引言

随着工业生产制造逐渐向信息化、智能化方向发展, 工业生产关键设备作为生产的驱动力, 其自动化程度日益提高, 但是恶劣的工作环境和长时间的运行, 导致工业生产关键设备易发生故障, 使操作人员的人身安全难以得到保障, 企业的经济效益受到影响. 因此, 对工业生产关键设备进行及时有效的故障诊断具有至关重要的意义.

故障诊断技术经过 50 多年的发展, 已成为保证系统可靠和安全的重要途径, 主要方法有基于模型、基于数据和基于知识的故障诊断, 其中基于模型的方法 (如文献 [1, 2] 等), 依赖于模型的准确性,

引用格式: 卞嘉楠, 冒泽慧, 姜斌, 等. 基于知识图谱和多任务学习的工业生产关键设备故障诊断方法. 中国科学: 信息科学, 2023, 53: 699–714, doi: 10.1360/SSI-2022-0060
Bian J N, Mao Z H, Jiang B, et al. Fault diagnosis method of critical industrial equipment based on knowledge graphs and multi-task learning (in Chinese). Sci Sin Inform, 2023, 53: 699–714, doi: 10.1360/SSI-2022-0060

还需要对故障建模. 基于数据的方法 (如文献 [3~6] 等) 不需要模型, 但需要历史数据, 且依赖于故障数据标签的准确性 [7]. 实际中, 大部分工业生产关键设备没有数学模型, 且数据采集也是近年来才开始进行的. 目前的设备故障诊断主要采用人工查询维修手册的方式, 或者专家系统辅助的方法, 通过人工观测到设备运行的异常后再查询专家系统.

工业生产关键设备运行过程中会不断产生新的运行与检修记录, 爆炸式的数据增长增加了知识维护的难度, 不同型号设备的运维工单分散在不同的数据库、电子文件和线下文档中, 其结构化水平较低. 而工业生产关键设备专家系统主要依赖于人工获取知识和人工维护, 更新和维护的成本较高, 很多新产生的故障现象和故障诊断信息并不能及时添加, 难以适应大规模、知识更新快的故障诊断场景. 与传统的专家系统相比, 知识图谱可将专家知识等非结构化数据进行规范化存储, 且不依赖于手工构建, 形式更加灵活, 可扩展性更好 [8]. 目前, 基于知识图谱的故障诊断相关研究尚处于起步阶段, 已有的研究工作主要包括面向民用航空领域故障诊断的知识图谱技术 [9,10]、针对电网故障诊断的知识图谱技术 [11] 等, 现有的研究工作主要使用的知识图谱图内推理技术在故障诊断场景中面临很大的挑战. 一方面, 故障知识具有显著的长尾分布特点, 即大部分知识都位于长尾部分; 另一方面, 仅有少量的节点拥有足够多的连接, 而大量的节点只有少量的连接, 甚至有很多孤立的节点, 对故障诊断任务产生不利影响. 基于知识图谱的推荐系统能够利用半结构化和非结构化先验知识, 由故障现象推断故障根因, 实现故障诊断.

将知识图谱与推荐算法融合主要有基于路径和基于嵌入两种类型的方法 [12]. 基于路径的方法以 FMG (meta-graph based recommendation fusion) [13], PGPR (policy-guided path reasoning) [14] 为代表, 这种方法能够充分利用知识图谱的图属性, 但是严重依赖于手工设计的元路径, 很难适应复杂的实际应用场景. 此外, 当任务场景或是知识图谱发生变动时, 需要重新构造元路径, 模型的迁移性和泛化性较差. 因此基于路径的方法不适宜应用到数据结构复杂、更新速度快的工业关键设备故障诊断场景中. 基于嵌入的方法使用知识图谱嵌入 (knowledge graph embedding, KGE) 算法预处理知识图谱, 并将学习得到的实体表示合并到推荐框架中. 知识图谱嵌入将实体和关系嵌入到连续的向量空间中, 同时保持其结构 [15,16]. 近年来, 研究人员提出了大量的知识图谱嵌入方法, 包括翻译距离模型, 如 Trans 系列 [17~20] 和语义匹配模型 [21,22] 等, 但上述方法在面对数据稀疏性问题时, 存在嵌入结果准确性较差的问题. 对于工业生产关键设备故障诊断场景, 需要依据故障描述数据稀疏的特点以及故障根因推断的需求设计知识图谱嵌入算法.

本文针对工业生产关键设备故障诊断现状, 考虑将工业生产关键设备故障知识图谱与推荐算法相结合, 引入基于知识图谱的推荐系统用于对故障根因进行推断, 将错综复杂的故障诊断知识与经验形成数字化的知识链条, 并在后续的故障诊断应用场景中快速地辅助运维人员进行故障根因推断以及故障排除, 为工业生产关键设备运维的自动化和智能化发展提供一种新思路. 本文的主要贡献如下.

(i) 将知识图谱和推荐算法相结合, 引入工业生产关键设备故障诊断领域, 能够有效解决领域内故障数据稀疏的问题并辅助专业人员进行现场故障诊断.

(ii) 通过引入改进的十字绣单元构建多任务学习框架, 能够提升模型的可迁移性和泛化性, 从而有效应对工业生产关键设备故障诊断领域知识和经验结构复杂、更新速度快的问题.

2 问题描述

本文主要基于知识图谱, 构建推荐系统, 实现从故障现象到故障根因的有效推荐, 即故障诊断. 首先, 就知识图谱介绍其基本原理.

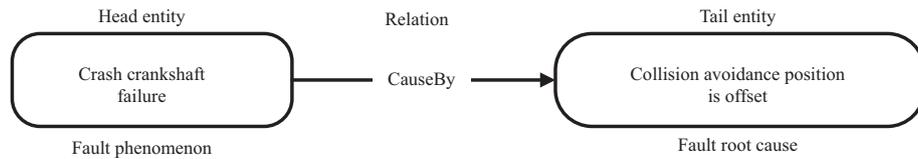


图 1 工业生产关键设备故障知识图谱三元组示意图

Figure 1 A triple of the critical industrial equipment fault knowledge graph

2.1 工业生产关键设备故障知识图谱

面向工业生产关键设备故障诊断的知识图谱属于领域知识图谱,可以用于描述工业生产关键设备运维领域的专家经验和知识,表达其属性以及内在联系.工业生产关键设备故障知识图谱的内容质量关乎工业生产过程的效率和安全问题,因此需要拥有比通用知识图谱更高的准确性.

与通用知识图谱的架构相类似,工业生产关键设备故障知识图谱以三元组 $\mathcal{G} = \{H, R, T\}$ 的形式表示,其中 H 表示所有头实体 h 的集合, R 表示所有关系 r 的集合, T 表示所有尾实体 t 的集合.本文使用工业企业生产过程中积累的不同型号工业生产关键设备的结构化、半结构化和非结构化数据构建知识图谱.所构建的工业生产关键设备故障知识图谱中包含故障现象、故障根因、零部件、维修方法等多种实体类型,使用三元组的形式存储于图数据库中.例如,针对某设备防撞部件的一条故障现象-故障根因三元组,如图 1 所示,其中故障现象为知识图谱中的头实体,属于集合 H ;故障根因为尾实体,属于集合 T .

此外,一种故障现象一般存在多种故障根因,如何从多种结果中选出最可能的一种,或对这些可能的故障根因进行优先级排序,这对运维人员进行现场故障诊断具有重要作用.

2.2 故障现象 - 故障根因关联矩阵

从故障现象找出故障根因,实现故障诊断,是通过推荐系统完成的,而传统的推荐系统构建不需要依赖知识图谱,直接利用运行数据和故障工单所记录的不同种类故障发生时的现象和进行故障诊断时所使用的方法流程和故障根因分析.这些故障现象和故障根因构成的对应关系可用图 2 表示.

在推荐系统中,考虑实际处理的情况,需要依据不同故障现象与相应的故障根因构建故障现象-故障根因关联矩阵.

将 M 种故障现象描述为 $\mathcal{F} = \{f_1, f_2, \dots, f_M\}$,将 N 种故障根因描述为 $\mathcal{S} = \{s_1, s_2, \dots, s_N\}$,将故障现象和故障根因分别作为矩阵的行和列,可以得到故障现象-故障根因关联矩阵 $\mathbf{U} \in \mathbb{R}^{M \times N}$.当故障根因将导致当前故障时,矩阵中的对应元素值为 1,否则为 0,则关联矩阵 \mathbf{U} 中的第 i 行,第 j 列元素可以表示为

$$\mathbf{U}[i, j] = \begin{cases} 1, & \text{if cause } (i) \text{ can cause fault } (j), \\ 0, & \text{otherwise,} \end{cases} \quad (1)$$

其中 $i \in \{1, 2, \dots, M\}$ 且 $j \in \{1, 2, \dots, N\}$.关联矩阵中的故障现象与工业生产关键设备故障知识图谱中的故障现象头实体构成关联关系,故障根因与知识图谱中的故障根因尾实体构成关联关系.关联矩阵的示意图如图 3 所示.

若只使用故障现象-故障根因关联矩阵 \mathbf{U} 构建推荐系统,就忽略了知识图谱中的丰富故障信息,从而将会使系统故障诊断准确率不高.因此,我们研究如何将知识图谱本身具备的知识和规则与历史故障现象-故障根因关联矩阵 \mathbf{U} 联系,构建推荐系统.

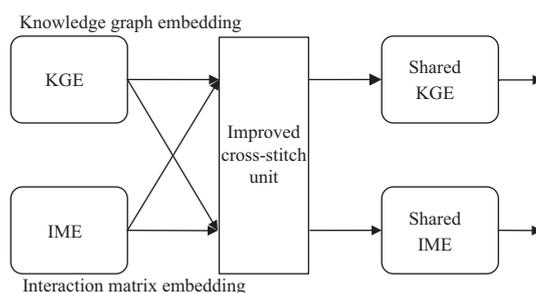


图 4 MKFD 总体框架图

Figure 4 Framework of the MKFD

s 能够导致故障现象 f 的概率 \hat{y}_{fs} :

$$\hat{y}_{fs} = \mathcal{F}(f, s | \Theta), \quad (2)$$

其中 $\mathcal{F}(\cdot)$ 为 MKFD (multi-task learning for knowledge graph-enhanced fault diagnosis) 模型函数, Θ 表示模型中的可训练参数集合. 根据预测概率的大小对结果进行排序, 给出故障诊断工作结果, 以提升故障诊断的准确率和效率, 实现智能运维.

3 方法

本节将提出一种基于知识图谱和多任务学习的工业生产关键设备故障诊断模型 MKFD. MKFD 模型主要包含 3 个部分: 改进十字绣单元、关联矩阵嵌入模块以及知识图谱嵌入模块, 其总体框架如图 4 所示, 输入为工业生产关键设备故障知识图谱 (KGE) 和故障现象 - 故障根因关联矩阵 (IME), 输出为故障根因的推断序列. 推断序列指的是一个故障现象可能存在一系列导致它的根因, 在推断结果中对这一系列根因按照可能性大小进行排序所得到的结果序列.

3.1 改进十字绣单元

针对多任务学习框架, 需要采用交替学习的方式进行模型训练. 原始的十字绣单元的表达力不足, 需要对其进行改进, 并将改进后的十字绣单元用于训练推荐模型.

对于相关联的任务 A 和 B, 常见的多任务学习是为两个任务设计相同的编码器提取输入数据的特征, 再使用不同的解码器单独训练, 得到最终结果. 这种方式需要遍历所有可能的网络结构来确定编码器的深度, 并且所得的最优结构泛化性较差, 针对上述问题, Misra 等^[23]于 2016 年提出了十字绣单元 (cross-stitch network, CSN), 通过学习输入特征矩阵的线性组合对共享关系进行建模.

在十字绣单元的每一层, 从 A 和 B 两个任务中学习得到特征矩阵的线性组合. 设输入第 l 层的 A 和 B 两个任务的特征矩阵分别是 x_A 和 x_B , 那么计算得到特征矩阵的线性组合 \tilde{x}_A 和 \tilde{x}_B :

$$\begin{bmatrix} \tilde{x}_A^{ij} \\ \tilde{x}_B^{ij} \end{bmatrix} = \begin{bmatrix} \alpha_{AA} & \alpha_{AB} \\ \alpha_{BA} & \alpha_{BB} \end{bmatrix} \begin{bmatrix} x_A^{ij} \\ x_B^{ij} \end{bmatrix}, \quad (3)$$

其中 (i, j) 表示特征矩阵中元素的位置, $\alpha_{..}$ 为线性组合参数.

十字绣单元使用线性组合参数 $\alpha_{..}$ 来建模两个任务的共享关系, 在图像领域取得了较好的效果, 然而面对参数量相对较少的文本特征提取任务, 选择标量作为参数不足以表达两个任务之间的交互

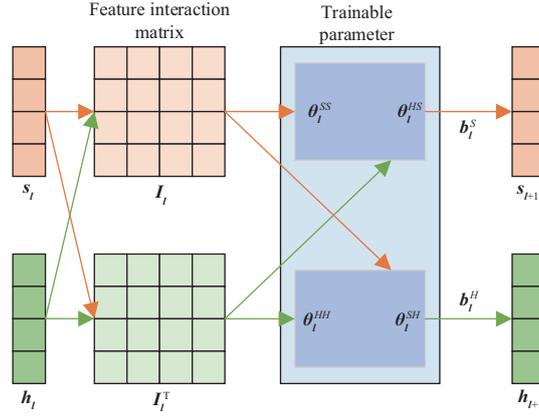


图 5 (网络版彩图) 改进十字绣单元结构

Figure 5 (Color online) Structure of improved cross-stitch unit

关系. 基于这种考虑, 我们设计了改进十字绣单元, 使用向量的点积运算来代替标量, 从而在更细粒度的层面上建模关联矩阵中的故障根因与工业生产关键设备故障知识图谱中与其相关联头实体的交互关系.

改进十字绣单元采用多层结构, 用于提取故障现象 – 故障根因关联矩阵中的故障根因与工业生产关键设备故障知识图谱中与其相关联的头实体的交互关系, 改进十字绣单元的结构如图 5 所示.

将故障现象 – 故障根因关联矩阵中的故障根因与工业生产关键设备故障知识图谱中与其相关联的头实体的向量表示为 $s_l \in \mathbb{R}^d$ 以及 $h_l \in \mathbb{R}^d$, 则改进十字绣单元的第 l 层的特征交互矩阵 I_l 可以表示为

$$I_l = s_l h_l^T = \begin{bmatrix} s_l^{(1)} h_l^{(1)} & \dots & s_l^{(1)} h_l^{(d)} \\ \dots & \dots & \dots \\ s_l^{(d)} h_l^{(1)} & \dots & s_l^{(d)} h_l^{(d)} \end{bmatrix}, \quad (4)$$

$$I_l^T = h_l s_l^T = \begin{bmatrix} h_l^{(1)} s_l^{(1)} & \dots & h_l^{(1)} s_l^{(d)} \\ \dots & \dots & \dots \\ h_l^{(d)} s_l^{(1)} & \dots & h_l^{(d)} s_l^{(d)} \end{bmatrix}, \quad (5)$$

其中 $I_l \in \mathbb{R}^{d \times d}$, $I_l^T \in \mathbb{R}^{d \times d}$ 表示特征交互矩阵及其转置, d 表示词向量的维度.

通过将特征交互矩阵 I_l 进行降维处理以保证特征向量的维度保持不变, 将其投影到词向量的表示空间中, 输出第 $l+1$ 层的故障排除措施和头实体的特征向量:

$$s_{l+1} = I_l \theta_l^{SS} + I_l^T \theta_l^{HS} + b_l^S, \quad (6)$$

$$h_{l+1} = I_l \theta_l^{SH} + I_l^T \theta_l^{HH} + b_l^H, \quad (7)$$

其中 $\theta_l^{SS} \in \mathbb{R}^d$, $\theta_l^{HS} \in \mathbb{R}^d$, $\theta_l^{SH} \in \mathbb{R}^d$, $\theta_l^{HH} \in \mathbb{R}^d$ 为模型的可训练参数, $b_l^S \in \mathbb{R}^d$, $b_l^H \in \mathbb{R}^d$ 为偏置向量.

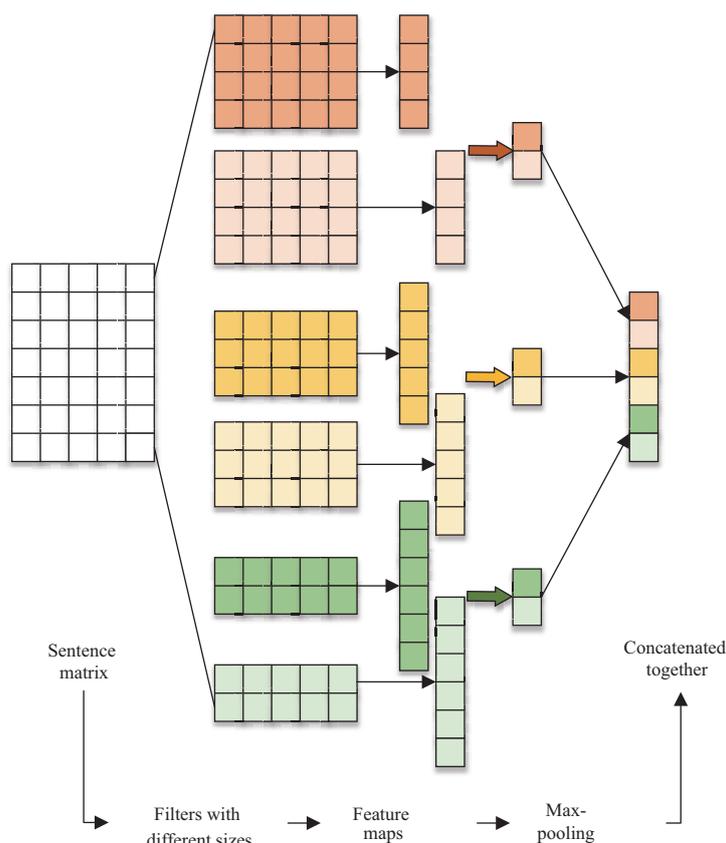


图 6 (网络版彩图) 文本一维卷积神经网络

Figure 6 (Color online) Textual one-dimensional convolutional neural network

为了方便表示, 将改进十字绣单元记为

$$[s_{l+1}], [h_{l+1}] = I(s_l, e_l), \quad (8)$$

其中 $[s]$ 表示故障根因文本向量通过改进十字绣单元的输出, $[h]$ 表示头实体文本向量通过改进十字绣单元的输出.

设计改进十字绣单元能够模拟关联矩阵中的故障根因与工业生产关键设备故障知识图谱中与其相关的头实体的交互关系, 并且控制两个任务之间的信息转移.

3.2 关联矩阵嵌入模块

多任务学习模型 MKFD 中, 关联矩阵嵌入模块用于抽取故障现象和故障根因的交互特征, 其输入是故障现象 - 故障根因关联矩阵中的故障现象和故障根因的向量表示, 分别使用改进十字绣网络和文本一维卷积神经网络提取故障根因和故障现象的特征, 将所提取的特征送入多层感知机中, 得到预测概率, 输出故障根因.

对于故障现象的向量表示, 使用文本一维卷积神经网络^[24] 提取其特征, 一维卷积神经网络的结构如图 6 所示, 输入为故障现象文本的嵌入向量, 输出为其特征向量.

设故障现象文本通过词向量嵌入映射为低位稠密向量表示, 词向量 f 的维度为 d , 文本长度为 n , 那么文本矩阵的维数为 $n \times d$, 定义为 $F \in \mathbb{R}^{n \times d}$, 使用 $F[i:j]$ 表示 F 的第 $i \sim j$ 行元素组成的子矩

阵. 假设有一个由权重矩阵 \mathbf{W} 参数化的卷积窗口, 区域高度为 a , 宽度为 d , 使用卷积窗口对 \mathbf{f} 的子矩阵反复执行卷积计算得到输出 $\mathbf{o} \in \mathbb{R}^{n-a+1}$, 可表示为

$$o_i = \mathbf{w} \cdot \mathbf{F}[i : i + a - 1], \quad (9)$$

其中 $i = 1, \dots, n - a + 1$, \cdot 表示点积运算. 使用 ReLU 激活函数进一步运算得到输出 \mathbf{o} 的特征映射 $\mathbf{c} \in \mathbb{R}^{n-a+1}$:

$$c_i = f(o_i + b), \quad (10)$$

其中 b 为偏置, $f(\cdot)$ 为 ReLU 激活函数.

设计 d 个不同大小的卷积窗口对文本矩阵进行特征提取, 将所得的特征映射经过最大池化层后进行拼接, 得到故障现象文本的特征向量 $\mathbf{f}_{fm} \in \mathbb{R}^d$.

对于故障现象 - 故障根因关联矩阵中的故障根因文本, 使用改进十字绣网络对其进行特征提取. 每一个故障根因 \mathbf{s} 与其在工业关键设备故障知识图谱中相关联的头实体进行信息交互, 通过多任务学习的方式提取故障根因的特征向量, 记为 $\mathbf{s}_{fm} \in \mathbb{R}^d$.

在得到故障现象和故障根因的特征向量之后, 推出某故障根因可能导致当前故障的预测概率 \hat{y}_{fs} , 表示为

$$\hat{y}_{fs} = \sigma(f_{\text{IMG}}(\mathbf{f}_{fm}, \mathbf{s}_{fm})), \quad (11)$$

其中 f_{IMG} 对参数执行内积运算, $\sigma(\cdot)$ 为激活函数.

3.3 知识图谱嵌入模块

知识图谱嵌入模块的输入是工业生产关键设备故障知识图谱中的头实体和关系的向量表示, 与关联矩阵嵌入模块相类似, 分别使用改进十字绣单元和文本一维卷积神经网络抽取头实体和关系的特征, 使用抽取所得的头实体和关系的特征预测尾实体.

嵌入表示是深度学习领域的一项重要技术, 通过嵌入可以将复杂结构的数据投影到向量空间中, 从而在投影空间中发现数据间的潜在联系. 在知识图谱领域, 知识的向量表示有利于刻画那些关联信息不明确的知识, 通过将图结构中隐含的关联信息映射到欧氏空间, 使得原本难以发现的关联信息变得显而易见.

多任务学习模型 MKFD 的知识图谱嵌入模块采用和关联矩阵嵌入模块相类似的结构, 其输入为工业生产关键设备故障知识图谱中三元组的头实体以及关系. 首先使用改进十字绣单元提取头实体文本的特征向量 \mathbf{h}_{fm} , $\mathbf{h}_{fm} \in \mathbb{R}^d$. 然后使用多层感知机提取关系文本的特征向量:

$$\mathbf{r}_{fm} = \mathcal{M}(\mathcal{M}(\dots \mathcal{M}(\mathbf{r}))) = \mathcal{M}^L(\mathbf{r}), \quad (12)$$

其中 $\mathcal{M}(\mathbf{r}) = \sigma(\mathbf{W}_M \mathbf{r} + \mathbf{b}_M)$ 是由多个全连接层构成的深度神经网络, \mathbf{W}_M 为网络的权重参数, \mathbf{b}_M 为偏置项, $\sigma(\cdot)$ 为非线性激活函数. 最后将提取得到的特征进行组合, 使用多层感知机预测尾实体, 尾实体的预测向量为 $\hat{\mathbf{t}}$:

$$\hat{\mathbf{t}} = \mathcal{M}^K(\mathbf{h}_{fm}, \mathbf{r}_{fm}). \quad (13)$$

对于每一个三元组, 定义一个评分函数 $\text{score}(h, r, t)$, 通过内积函数 f_{KGE} 计算三元组的得分:

$$\text{score}(h, r, t) = f_{\text{KGE}}(\mathbf{t}, \hat{\mathbf{t}}) = \sigma(\mathbf{t}^T \hat{\mathbf{t}}), \quad (14)$$

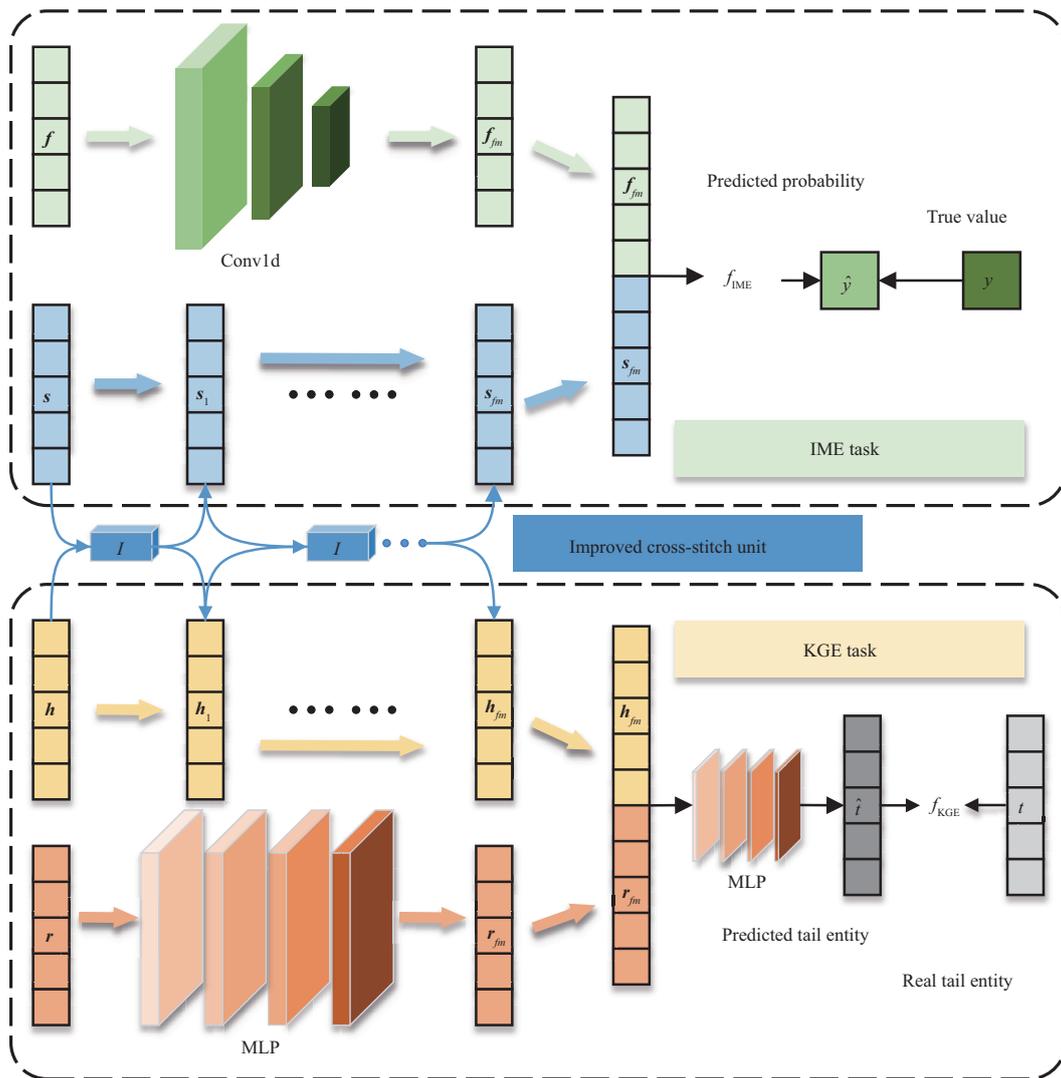


图 7 (网络版彩图) MKFD 模型结构图

Figure 7 (Color online) Structure diagram of the MKFD model

其中 t 为真实的尾实体, \hat{t} 为预测的尾实体. 如果待预测的尾实体 t 得分最高, 则说明向量表示学习的效果良好.

3.4 损失函数及算法

MKFD 模型由上述 3 个模块组成, 其结构如图 7 所示, 输入为工业生产关键设备故障知识图谱和故障现象 - 故障根因关联矩阵, 输出为故障根因的推断序列.

使用交替迭代学习的多任务学习方法训练模型. 对所有的故障预测概率和三元组评分函数累加得到损失函数, 采用简单的梯度下降优化方法, 随机初始化所有实体和关系的向量表示, 然后迭代优化向量中的参数. 优化的目标是让真实的三元组得分尽可能高, 而让不存在的三元组的得分尽可能小.

Algorithm 1 The training strategy for the MKFD

Repeat

Input Fault phenomenon–fault root cause interaction matrix U and fault knowledge graph \mathcal{G} ;

Initialize all parameters;

for t steps **do**

 Sample minibatch of true and false interactions from U ;

 Update parameters of $\hat{y}_{fs} = \mathcal{F}(f, s | \Theta)$;

end for

Sample minibatch of true and false triples from \mathcal{G} ;

Update parameters of $\hat{y}_{fs} = \mathcal{F}(f, s | \Theta)$;

Until Convergence of all parameters;

Return \hat{y}_{fs} .

在输入样本的每个批次上最小化损失函数:

$$\mathcal{L} = \sum_{f \in \mathcal{F}, s \in \mathcal{S}} \mathcal{J}(\hat{y}_{fs}, y_{fs}) - \lambda \left(\sum_{(h, r, t) \in \mathcal{G}} \text{score}(h, r, t) - \sum_{(h', r, t') \in \mathcal{G}} \text{score}(h', r, t') \right), \quad (15)$$

其中 \mathcal{J} 为交叉熵损失函数, (h', r, t') 为不属于故障知识图谱的错误三元组, λ 为控制两个子任务权重的超参数. 当损失函数的值稳定不再下降后, 停止训练.

由于高层特征一般都与特定任务高度相关, 不适宜继续共享特征, 考虑到模型的可迁移性, 改进的十字绣单元只能存在于底层, 以防止造成特征负迁移.

在实际操作中, 我们采用交替训练的方式. 交替学习是一种较为创新和前沿的思路, 其实际运用和时间开销介于依次学习^[25]和联合学习^[26]中间. 与可以直接使用实体向量的依次学习和需要从零开始的交替学习不同, 交替训练将两种学习方式进行融合, 其特征学习模块可以直接参与下一次的训练过程.

在算法设计上, 首先固定关联矩阵嵌入模块的参数, 训练故障知识图谱嵌入模块的参数; 然后固定故障知识图谱嵌入的参数, 训练关联矩阵嵌入模块的参数, 得到算法 1.

4 实验

为了验证本文提出的基于知识图谱和多任务学习的工业生产关键设备故障诊断模型 MKFD 的有效性, 使用国内某工业企业生产过程中积累的不同型号的工业生产关键设备运维的结构化、半结构化和非结构化数据构建故障知识图谱. 基于所构建的知识图谱和与之匹配的故障现象–故障诊断关联矩阵, 训练 MKFD 模型并与多种方法进行对比实验.

在所收集的约 5800 个三元组样本中, 随机选择其中的 60% 用于训练 MKFD 模型, 将剩余 40% 平均分为两份, 分别作为验证集和测试集. 所设计的 MKFD 模型共有 4 个超参数需要选择, 分别是用于提取关系文本特征向量的多层感知机的层数 L 、用于预测尾实体向量的多层感知机的层数 K 、每轮训练中关联矩阵嵌入的次数 t 和控制两个子任务权重的超参数 λ . 根据经验规律, 我们将 L 和 K 设为 2, 将 t 设为每轮 2 次, 将 λ 设为 0.1.

表 1 RDF 三元组
Table 1 RDF triples

Serial number	Head entity	Tail entity	Relation
1	Manipulator failure	Manipulator trip	ProblemToCause1
2	Manipulator trip	Encoder failure	Casue1ToCause2
3	Encoder failure	Encoder wiring is damaged	Cause2ToCause3

4.1 工业生产关键设备故障知识图谱的构建

针对领域知识图谱具有边界清晰、关系明确的特点,采用自顶向下的方法构建故障知识图谱,构建流程包括本体构建、实体抽取和分类、数据存储和图谱构建。

首先,根据各类运维数据情况和故障排除措施推荐任务的需求构建本体,包括确定实体类型和关系类型。其中实体类型包括故障现象、故障原因、维修方法、零部件、故障程度等,各类实体之间具有明确规定的关系。在完成本体构建之后,将半结构化和非结构化数据进行序列标注,并划分训练集和测试集,使用训练集训练通用深度自注意力网络,使用测试集测试模型的训练效果。对于抽取完成的实体进行类型标注,训练实体分类模型循环卷积网络,并使用训练完成的模型对所有从运维数据中抽取出的实体进行分类。将分类完成的实体按照本体模型中规定的关系类型组成 RDF (resource description framework) 三元组,存储为 csv 格式文件。表 1 展示了用于构成故障知识图谱的 RDF 三元组。

本文使用 Neo4j 图数据库^[27~29]完成故障知识图谱的搭建。由于 Neo4j 图数据库没有面向 RDF 数据的直接接口,通过使用 py2neo 库搭建接口,实现在 Neo4j 图数据库中批量导入 RDF 类型的数据,无损地将 RDF 数据存储于 Neo4j 图数据库中。完成 RDF 数据导入后,对各属性关系进行调节,对可视化效果,如节点与关系的颜色、显示的主属性等进行调整,完成故障知识图谱的搭建和可视化。后续可以随着需求的变化而增加节点、关系及其属性,且增删操作不会影响到原来数据的正常使用。为方便验证模型的迁移性能和泛化性能,依据工业企业所提供的故障数据分别构建了两个不同的工业生产关键设备故障知识图谱,两个故障知识图谱共用相同的本体库,但所描述的工业生产关键设备对象不同,在规模上也具有一定的差异。故障知识图谱 1 包含 1972 个实体和 5347 条关系,故障知识图谱 2 包含 3825 个实体和 7281 条关系。构建完成的工业生产关键设备故障知识图谱的片段如图 8 所示。

4.2 对比方法

对于工业生产关键设备故障诊断任务,我们将所提出的模型与以下的先进方法进行比较,包括传统的基于相似度的方法和基于知识图谱的方法。

- FM (factorization machine) 是由 Rendle 等^[30]提出的一种基于矩阵分解的机器学习算法,其主要用于解决数据稀疏的任务场景中数据特征的组合问题。
- BPR (Bayesian personalized ranking)^[31]是基于贝叶斯后验优化的个性化排序算法。该模型可以从关联矩阵中训练出多个矩阵,通过某一个故障现象与不同故障根因的因果关系获得此故障现象与多个故障根因的潜在对应关系。
- CFKG (collaborative filtering based on knowledge graph)^[32]与 MKFD 模型使用交替迭代的多任务学习方式训练模型不同,CFKG 模型通过知识表示学习方法嵌入异质实体,将知识图谱和关联矩阵嵌入统一的空间中进行训练,从而实现故障现象和潜在故障根因关系的挖掘。
- CKE (collaborative knowledge base embedding)^[26]通过结合结构信息、文本数据、图像数据等知识库中的信息提升系统的准确性。其中,结构信息采用 TransR 来得到实体的向量特征,文本数据与图

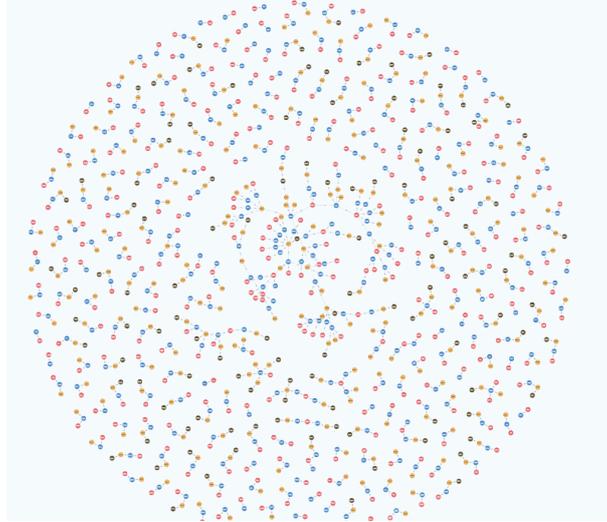


图 8 (网络版彩图) 工业生产关键设备故障知识图谱片段

Figure 8 (Color online) Fragment of a critical industrial equipment fault knowledge graph

像数据分别使用栈式降噪自编码 (stacked denoising auto-encoder, SDAE) 与栈式卷积自编码 (stacked convolutional auto-encoder, SCAE) 来提取出向量特征.

4.3 评价指标

为了量化模型的性能, 本文使用 AUC (area under curve)、准确率 (Precision)、召回率 (Recall) 和 F1 值作为点击率预测的评价指标, 使用 Precision@K, Recall@K, F1@K 作为最优推荐的评价指标.

Precision@K 用于描述模型给出的概率最大的 K 种故障根因中, 会导致当前故障现象的故障根因所占的比例, 其计算公式为

$$\text{Precision@}K = \frac{\sum_{i=1}^N |R(i) \cap T(i)|}{\sum_{i=1}^N |R(i)|}, \quad (16)$$

其中 i 表示第 i 次推荐; $R(i)$ 表示第 i 次推荐中, 推荐的故障根因列表; $T(i)$ 表示第 i 次推荐中, 会导致当前故障现象的故障根因列表; K 为所推荐故障根因列表的长度; N 表示总推荐次数.

Recall@K 用于描述所有会导致当前故障现象的故障根因在模型所给的概率最大的 K 种故障根因中所占的比例, 其计算公式为

$$\text{Recall@}K = \frac{\sum_{i=1}^N |R(i) \cap T(i)|}{\sum_{i=1}^N |T(i)|}. \quad (17)$$

F1@K 是上述两种评价指标的调和平均值, 能够综合考虑两种评价指标, 其计算公式为

$$\text{F1@}K = \frac{2 \times \text{Precision@}K \times \text{Recall@}K}{\text{Precision@}K + \text{Recall@}K}. \quad (18)$$

4.4 实验结果

实验基于两个由工业生产关键设备的运维数据分别构建的故障知识图谱. 分别使用点击率预测指标和最优推荐指标对各种模型的性能进行评价, 点击率预测评价结果如表 2 和 3 所示, 最优推荐评价结果如图 9(a) 和 (b) 所示.

表 2 点击率预测评价结果 (故障知识图谱 1)

Table 2 Model performance comparison based on fault knowledge graph 1

Model	Precision	Recall	F1-score	AUC
FM	0.725	0.765	0.745	0.797
BPR	0.739	0.728	0.733	0.799
CFKG	0.746	0.732	0.739	0.801
CKE	0.748	0.732	0.741	0.806
MKFD	0.778	0.766	0.772	0.852

表 3 点击率预测评价结果 (故障知识图谱 2)

Table 3 Model performance comparison based on fault knowledge graph 2

Model	Precision	Recall	F1-score	AUC
FM	0.726	0.768	0.746	0.802
BPR	0.731	0.755	0.743	0.792
CFKG	0.767	0.732	0.743	0.819
CKE	0.761	0.736	0.748	0.819
MKFD	0.778	0.763	0.771	0.851

• FM 和 BPR 的表现在所有模型中相对较差,这两种方法并没有利用故障知识图谱作为信息源,仅使用关联矩阵作为输入. FM 模型在获取到词向量嵌入特征后直接进行池化操作,这种方式虽然节约了计算资源,但是损失大量有效信息,并且每个词向量嵌入特征维度必须保持一致才能进行下一步计算,使得模型的表达能力受限,这也是 FM 模型在两个数据集上的表现较差的主要原因. BPR 模型在面对数据稀疏问题和冷启动问题时效果较差,并且机床故障数据具有长尾分布的特点,因此 BPR 模型在所有模型中表现最差,而 FM 模型对稀疏数据有更好的学习能力,可以直接通过交互项学习特征之间的关联关系,因此在面对数据量不足的工业生产关键设备故障诊断场景时效果略好于 BPR 模型.

• CFKG 和 CKE 的表现较之传统的不使用知识图谱的模型有一定的提升,说明将知识图谱与关联矩阵协同训练能够有效缓解故障现象 - 故障根因关联矩阵的数据稀疏性问题.但是这两种模型的效果都不如 MKFD,一个可能的原因是,它们在进行知识图谱与关联矩阵的信息交互时直接采用强制实体嵌入对齐的方式,会导致实体嵌入中所保存知识的丢失.常见的知识图谱与关联矩阵的协同训练有 3 种方式,分别是依次学习、联合学习和交替学习. CFKG 和 CKE 都是采用联合学习的方式进行训练的,当训练数据不足时,上述信息的丢失现象会变得更严重,从而造成模型性能的下降.

• MKFD 在所有模型中表现最好. MKFD 模型使用多任务学习的框架进行交替学习,由于故障知识图谱中的实体和关联矩阵中的相应项实际上是对同一个对象的两种不同描述,在低层使用改进十字绣单元进行信息交互共享,可以让两者都获得来自对方的额外信息,从而弥补了其自身信息稀疏性的不足.同时,在面对工业生产关键设备故障根因推断任务时, MKFD 模型在处理数据稀疏和冷启动问题上取得了更好的效果.

5 总结

本文提出了一种基于知识图谱和多任务学习的工业生产关键设备故障诊断模型 MKFD,实现了对故障根因的推断,从而辅助操作人员对工业生产关键设备进行故障诊断.通过将知识图谱和推荐算

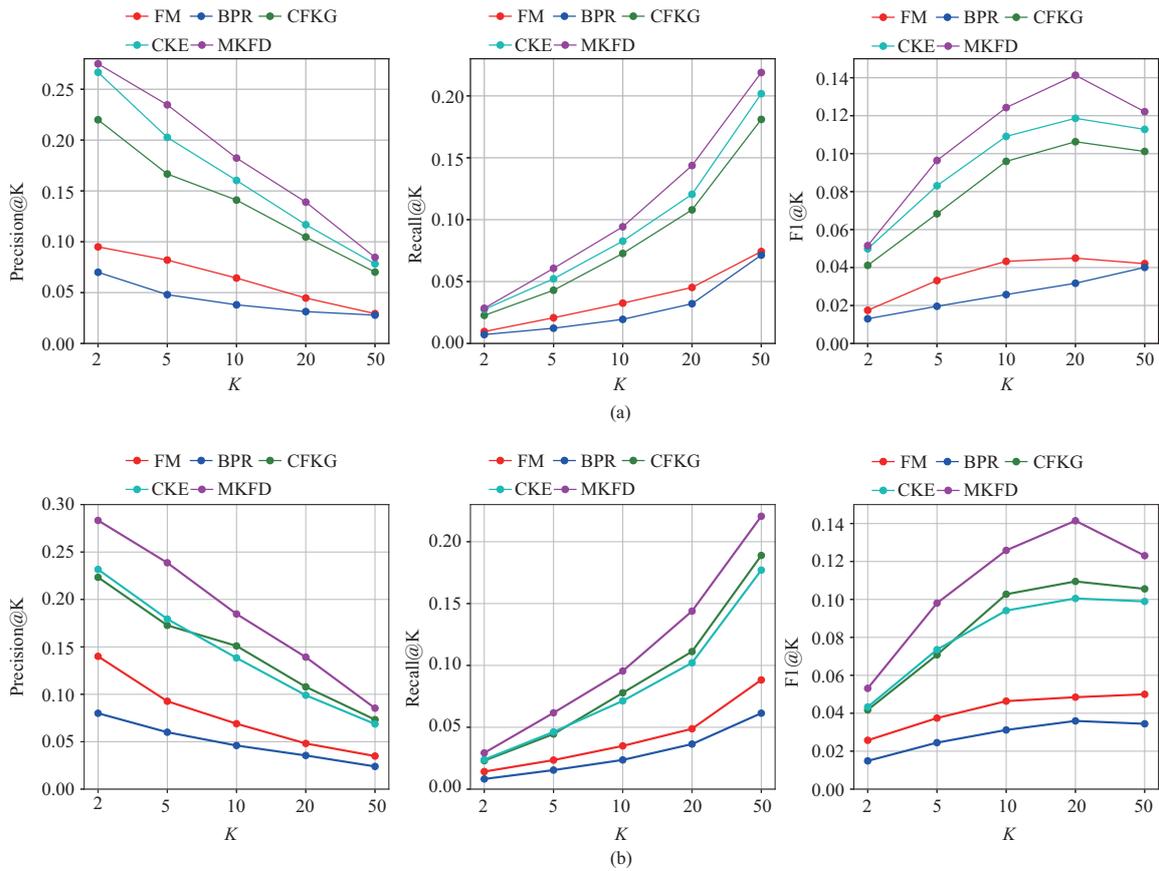


图 9 (网络版彩图) 最优推荐评价结果. (a) 故障知识图谱 1; (b) 故障知识图谱 2

Figure 9 (Color online) Optimal recommendation evaluation results based on (a) fault knowledge graph 1 and (b) fault knowledge graph 2

法相结合, 应用于工业生产关键设备故障诊断领域, 能够有效解决领域内故障数据稀疏的问题. 通过对十字绣网络的改进构建多任务学习框架, 能够提升模型的可迁移性以及泛化性, 从而有效解决工业生产关键设备故障诊断领域的知识和经验结构复杂、更新速度快的问题. 基于国内某工业企业的运维数据所构建的两个工业生产关键设备故障知识图谱对所提出的模型进行了验证, 结果表明, MKFD 相较于其他对比方法具有显著的性能提升, 表明知识图谱技术在故障诊断领域具有广阔的应用前景. 在下一步的工作中, 我们计划在所提出的模型中融合其他类型的深度学习模型, 并构建规模更大的数据集, 进一步验证模型的泛化性能.

参考文献

- 1 Wen C L, Qiu A B, Jiang B. An output delay approach to fault estimation for sampled-data systems. *Sci Sin Inform*, 2013, 43: 694–706 [文成林, 邱爱兵, 姜斌. 基于输出时滞方法的采样数据系统故障估计. *中国科学: 信息科学*, 2013, 43: 694–706]
- 2 Guo T X, Sang J X, Chen M Y, et al. A fault detection method for a braking system of high-speed trains. *Sci Sin Inform*, 2020, 50: 483–495 [郭天序, 桑建学, 陈茂银, 等. 一种高速列车制动系统故障检测方法. *中国科学: 信息科学*, 2020, 50: 483–495]
- 3 Mao Z H, Gu Y X, Jiang B, et al. Incipient fault diagnosis for high-speed train traction systems via improved LSTM.

- Sci Sin Inform, 2021, 51: 997–1012 [冒泽慧, 顾彧行, 姜斌, 等. 基于改进 LSTM 的高速列车牵引系统微小渐变故障诊断. 中国科学: 信息科学, 2021, 51: 997–1012]
- 4 Jiang B, Chen H T, Yi H, et al. Data-driven fault diagnosis for dynamic traction systems in high-speed trains. Sci Sin Inform, 2020, 50: 496–510 [姜斌, 陈宏田, 易辉, 等. 数据驱动高速列车动态牵引系统的故障诊断. 中国科学: 信息科学, 2020, 50: 496–510]
 - 5 Mao Z, Xia M, Jiang B, et al. Incipient fault diagnosis for high-speed train traction systems via stacked generalization. IEEE Trans Cybern, 2022, 52: 7624–7633
 - 6 Hu N Q, Chen H P, Cheng Z, et al. Fault diagnosis for planetary gearbox based on EMD and deep convolutional neural networks. J Mech Eng, 2019, 55: 9–18 [胡芑庆, 陈徽鹏, 程哲, 等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法. 机械工程学报, 2019, 55: 9–18]
 - 7 Zhang D H, Liu Z Y, Jia W Q, et al. A review on knowledge graph and its application prospects to intelligent manufacturing. J Mech Eng, 2021, 57: 90–113 [张栋豪, 刘振宇, 郑维强, 等. 知识图谱在智能制造领域的研究现状及其应用前景综述. 机械工程学报, 2021, 57: 90–113]
 - 8 Guo R, Yang Q, Liu S H, et al. Construction and application of power grid fault handling knowledge graph. Power Syst Technol, 2021, 45: 2092–2100 [郭榕, 杨群, 刘绍翰, 等. 电网故障处置知识图谱构建研究与应用. 电网技术, 2021, 45: 2092–2100]
 - 9 Nie T P, Zen J Y, Cheng Y J, et al. Knowledge graph construction technology and its application in aircraft power system fault diagnosis. Chin J Aeronaut, 2022, 43: 625499 [聂同攀, 曾继炎, 程玉杰, 等. 面向飞机电源系统故障诊断的知识图谱构建技术及应用. 航空学报, 2022, 43: 625499]
 - 10 Cao M, Wang P, Zuo H F, et al. Fault diagnosis and health management for civil aero-engines: present situation, challenges and opportunities — ground integrated diagnosis, life management and intelligent maintenance decisions. Chin J Aeronaut, 2022, 43: 625574 [曹明, 王鹏, 左洪福, 等. 民用航空发动机故障诊断与健康管理的现状、挑战与机遇 — 地面综合诊断、寿命管理和智能维护维修决策. 航空学报, 2022, 43: 625574]
 - 11 Qiao J, Wang X Y, Min R, et al. Framework and key technologies of knowledge-graph-based fault handling system in power grid. Proc CSEE, 2020, 40: 5837–5849 [乔骥, 王新迎, 闵睿, 等. 面向电网调度故障处理的知识图谱框架与关键技术初探. 中国电机工程学报, 2020, 40: 5837–5849]
 - 12 Qin C, Zhu H S, Zhuang F Z, et al. A survey on knowledge graph-based recommender systems. Sci Sin Inform, 2020, 50: 937–956 [秦川, 祝恒书, 庄福振, 等. 基于知识图谱的推荐系统研究综述. 中国科学: 信息科学, 2020, 50: 937–956]
 - 13 Zhao H, Yao Q, Li J, et al. Meta-graph based recommendation fusion over heterogeneous information networks. In: Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2017. 635–644
 - 14 Xian Y, Fu Z, Muthukrishnan S, et al. Reinforcement knowledge graph reasoning for explainable recommendation. In: Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval, 2019. 285–294
 - 15 Guan N, Song D, Liao L. Knowledge graph embedding with concepts. Knowl Based Syst, 2019, 164: 38–44
 - 16 Wang Q, Mao Z, Wang B, et al. Knowledge graph embedding: a survey of approaches and applications. IEEE Trans Knowl Data Eng, 2017, 29: 2724–2743
 - 17 Bordes A, Usunier N, Garcia-Duran A, et al. Translating embeddings for modeling multi-relational data. In: Proceedings of the 26th International Conference on Neural Information Processing Systems, 2013. 2787–2795
 - 18 Wang Z, Zhang J, Feng J, et al. Knowledge graph embedding by translating on hyperplanes. In: Proceedings of the 28th AAAI Conference on Artificial Intelligence, 2014. 28
 - 19 Lin Y, Liu Z, Sun M, et al. Learning entity and relation embeddings for knowledge graph completion. In: Proceedings of the 29th AAAI Conference on Artificial Intelligence, 2015. 2181–2187
 - 20 Ji G, He S, Xu L, et al. Knowledge graph embedding via dynamic mapping matrix. In: 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
 - 21 Liu H, Wu Y, Yang Y. Analogical inference for multi-relational embeddings. In: Proceedings of the 34th International Conference on Machine Learning, 2017. 2168–2178
 - 22 Nickel M, Rosasco L, Poggio T. Holographic embeddings of knowledge graphs. In: Proceedings of the 30th AAAI Conference on Artificial Intelligence, 2016

- 23 Misra I, Shrivastava A, Gupta A, et al. Cross-stitch networks for multi-task learning. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016. 3994–4003
- 24 Zhang Y, Wallace B. A sensitivity analysis of (and practitioners' guide to) convolutional neural networks for sentence classification. 2015. ArXiv:1510.03820
- 25 Wang H, Zhang F, Xie X, et al. DKN: deep knowledge-aware network for news recommendation. In: Proceedings of the 2018 World Wide Web Conference, 2018. 1835–1844
- 26 Zhang F, Yuan N J, Lian D, et al. Collaborative knowledge base embedding for recommender systems. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2016. 353–362
- 27 Fernandes D, Bernardino J. Graph databases comparison: AllegroGraph, ArangoDB, InfiniteGraph, Neo4J, and OrientDB. In: Proceedings of DATA, 2018. 373–380
- 28 Cattuto C, Quagiotto M, Panisson A, et al. Time-varying social networks in a graph database: a Neo4j use case. In: Proceedings of the 1st International Workshop on Graph Data Management Experiences and Systems, 2013. 1–6
- 29 Holzschuher F, Peinl R. Performance of graph query languages: comparison of cypher, gremlin and native access in Neo4j. In: Proceedings of the Joint EDBT/ICDT 2013 Workshops, 2013. 195–204
- 30 Rendle S. Factorization machines. In: Proceedings of the 2010 IEEE International Conference on Data Mining, 2010. 995–1000
- 31 Rendle S, Freudenthaler C, Gantner Z, et al. BPR: Bayesian personalized ranking from implicit feedback. 2012. ArXiv:1205.2618
- 32 Zhang Y, Ai Q, Chen X, et al. Learning over knowledge-base embeddings for recommendation. 2018. ArXiv:1803.06540

Fault diagnosis method of critical industrial equipment based on knowledge graphs and multi-task learning

Jianan BIAN¹, Zehui MAO^{1*}, Bin JIANG¹, Yajie MA¹ & Wenjing LIU^{2,3}

1. *College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China;*

2. *Beijing Institute of Control Engineering, Beijing 100190, China;*

3. *Science and Technology on Space Intelligent Control Laboratory, Beijing 100190, China*

* Corresponding author. E-mail: zehuimao@nuaa.edu.cn

Abstract To resolve the problem of sparse fault data in critical industrial equipment and meet the demands of fault diagnosis, we propose a critical industrial equipment fault diagnosis model, termed multi-task learning for knowledge graph-enhanced fault diagnosis (MKFD), which is based on a knowledge graph and multi-task learning. The model realizes the inference of fault root causes. First, a multi-task learning framework is designed, and an improved cross-stitch network is constructed to realize the information sharing among subtasks in the framework. Then, the interaction matrix of fault phenomena and fault root causes is constructed using operation and maintenance data, and the knowledge graph embedding model is built using a multi-layer perceptron. The embedding of the interaction matrix and knowledge graph is regarded as two subtasks in the multi-task learning framework. Through the alternative learning of subtasks, the parameters of MKFD are optimized to infer the fault root cause, thus assisting the operation and maintenance personnel in fault diagnosis. Moreover, this scheme was verified by constructing two critical industrial equipment fault knowledge graphs based on the operation and maintenance data of a domestic industrial enterprise, and the results show that the proposed method has good performance.

Keywords fault diagnosis, knowledge graph, multi-task learning, critical industrial equipment, recommender system