

4-12-2023

## Knowledge Graph-based Process Knowledge Reasoning Method for Intelligent Production System

Weikai Yang

*Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;, 1277715900@qq.com*

Yan Wang

*Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;*

Zhicheng Ji

*Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# Knowledge Graph-based Process Knowledge Reasoning Method for Intelligent Production System

## Abstract

**Abstract:** Aiming at the disadvantages of high redundancy and weakness between knowledge and data in intelligent production system, and the difficulty to perform knowledge reasoning, a process knowledge reasoning method for knowledge maps is proposed. *The input information is semantically labeled and classified, the characteristics of the information match are extracted, the extracted local feature and global feature are associated through graph convolution method, and the feature of the difference value information is integrated and mapped with the constructed knowledge graph. Different reasoning rules are used according to different reasoning types, and the association and topology information between instances are deduced, and the properties and values of input information are generated.* Compared with the recommended system algorithm and fusion knowledge map, the algorithm has higher predictive rates on Movielens-1M, Book-Crossing, Last.FM data set. The feasibility of the reasoning model is verified by the process instance knowledge.

## Keywords

knowledge graph, knowledge reasoning, process knowledge, graph convolution, graph matching

## Recommended Citation

Weikai Yang, Yan Wang, Zhicheng Ji. Knowledge Graph-based Process Knowledge Reasoning Method for Intelligent Production System[J]. Journal of System Simulation, 2023, 35(4): 773-785.

# 面向知识图谱的智能生产系统工艺知识推理方法

杨伟凯, 王艳, 纪志成

(江南大学 物联网技术应用教育部工程研究中心, 江苏 无锡 214122)

**摘要:** 针对智能生产系统中知识和数据之间存在冗余度高、关联性弱, 难以进行知识推理的缺点, 提出了面向知识图谱的工艺知识推理方法。对输入信息进行语义标注和分类, 提取得到用于信息匹配的特征; 利用图卷积方法对提取到的局部特征和全局特征进行关联, 整合成带有差异值信息的特征无向图, 与构建好的知识图谱进行图匹配操作; 根据不同的推理类型采用不同的推理规则, 推理得出实例之间的关联和拓扑信息, 生成关于输入信息的属性和值。与推荐系统算法、融合知识图谱的图卷积算法相比, 该算法在 MovieLens-1M、Book-Crossing、Last.FM 数据集上取得了较高的预测率, 通过工艺实例知识推理验证了所提推理模型的可行性。

**关键词:** 知识图谱; 知识推理; 工艺知识; 图卷积; 图匹配

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X(2023)04-0773-13

DOI: 10.16182/j.issn1004731x.joss.21-1305

**引用格式:** 杨伟凯, 王艳, 纪志成. 面向知识图谱的智能生产系统工艺知识推理方法[J]. 系统仿真学报, 2023, 35(4): 773-785.

**Reference format:** Yang Weikai, Wang Yan, Ji Zhicheng. Knowledge Graph-based Process Knowledge Reasoning Method for Intelligent Production System[J]. Journal of System Simulation, 2023, 35(4): 773-785.

## Knowledge Graph-based Process Knowledge Reasoning Method for Intelligent Production System

Yang Weikai, Wang Yan, Ji Zhicheng

(Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China)

**Abstract:** Aiming at the disadvantages of high redundancy and weakness between knowledge and data in intelligent production system, and the difficulty to perform knowledge reasoning, a process knowledge reasoning method for knowledge maps is proposed. *The input information is semantically labeled and classified, the characteristics of the information match are extracted, the extracted local feature and global feature are associated through graph convolution method, and the feature of the difference value information is integrated and mapped with the constructed knowledge graph. Different reasoning rules are used according to different reasoning types, and the association and topology information between instances are deduced, and the properties and values of input information are generated.* Compared with the recommended system algorithm and fusion knowledge map, the algorithm has higher predictive rates on Movielens-1M, Book-Crossing, Last.FM data set. The feasibility of the reasoning model is verified by the process instance knowledge.

**Keywords:** knowledge graph; knowledge reasoning; process knowledge; graph convolution; graph matching

收稿日期: 2021-12-16 修回日期: 2022-02-15

基金项目: 国家重点研发计划(2018YFB1701903)

第一作者: 杨伟凯(1999-), 男, 硕士生, 研究方向为知识图谱与知识推理。E-mail: 1277715900@qq.com

## 0 引言

在数据信息化的背景下,制造业展现出蓬勃发展的趋势,在智能生产系统的设计、生产、装配等生命周期内,出现了较为冗余且关联弱的制造知识和工艺数据,在整个智能生产环境中只强调了对数据的检索、查询、应用,却很少注重工艺知识之间的关联、理解及推理<sup>[1]</sup>。从海量的工艺知识中找到其内在的关联及实现高效的知识推理方法受到了广泛的关注。

知识图谱(knowledge graph, KG)<sup>[2]</sup>是谷歌提出的用来增强搜索引擎的一种技术,其初意是通过知识图谱加深搜索与显示之间的关联,使谷歌的搜索结果具有完整知识体系。知识图谱基于语义网络的思想,增强了实体之间的关联性<sup>[3]</sup>,将实体之间的联系可视化,具有非常强大的知识表示和推理的能力,在知识本体之间根据原有的关系进行不同节点之间的连接,形成一种规范的共享形式<sup>[4]</sup>,以机器可读的方式将知识明确、透彻地表示出来。

目前,知识图谱已经在互联网搜索引擎、智能问答场景应用中趋于成熟,并且在逐步往生活中的其他领域进行拓展,比如,金融风险预测<sup>[5]</sup>、医疗人员管理<sup>[6]</sup>、智能制造生产<sup>[7]</sup>、社会科学<sup>[8]</sup>等。

在智能制造领域,国内外学者已在工艺知识推理、知识图谱与工艺知识结合方面开展了诸多的研究。针对智能制造中的工艺知识推理,Zheng等<sup>[9]</sup>提出了一个基于知识的低碳产品设计框架,采用多目标粒子群优化解决产品低碳优化问题,将本体知识建模应用于语义功能的表示,通过实例说明其可行性,但是在解决过程中没有考虑到整个知识之间存在的内在联系;Peng等<sup>[10]</sup>提出一种基于超网络的方法模型,由产品、知识、问题网络等构成,明确捕获多方面知识中各元素之间的关系,采用贝叶斯方法进行协同推理,通过各个节点网络的属性来进行拓扑识别,捕捉多方面元素的复杂关联,但是其知识的形式化表示途径和

推理的过程有待改进;Li等<sup>[11]</sup>将专家综合决策集成到自动经验推理,提出一种特征加权的案例适应方法,通过采用提出的加权支持向量机和动态粒子群优化,实现了在案例推理中识别特征参数经验矩阵挖掘出隐藏在函数、参数之间的隐形知识,但是这种方法缺乏对产品功能和结构认识的考虑;Tai等<sup>[12]</sup>设计了一个基于知识的产品自动化设计系统,提出通用特征设计流程框架来表示产品初始设计阶段到最终自动生成计算机辅助模型中的知识,基于案例推理的方法进行案例适配,实现特征的复用,从而实现制造业中的工艺知识推理,但是这种方法依赖一定的领域专家综合决策,大大增加了研究成本和设计流程。

对于知识图谱在智能制造领域的应用,Zhou等<sup>[13]</sup>提出一个基于知识图谱的决策框架,框架中集成了加工车间的隐式知识,框架用于支持资源最优分配,允许对给定的订单插入任务进行快速的资源分配决策,利用车间资源知识图谱挖掘隐式资源信息,进行知识图谱的更新,但是在进行资源的决策分配时受制于资源加工的信息和设备的评估策略;Hka等<sup>[14]</sup>提出一种基于机器学习和知识图谱的增材制造设计规则构建的方法,利用机器学习从数据中提取可预测的知识,采用知识图谱作为知识库,将知识进行形式化的表示、提取、推理,利用机器学习及知识图谱技术设计规则,解决增材制造分析和设计方面的相关决策问题,但是在知识推理过程中没有考虑到多特征之间的内在联系及推理中的推理类型;Zheng等<sup>[15]</sup>提出了一种基于工业知识图谱的多智能体强化学习方法,实现自我认知的制造网络,多智能体强化学习方法可以实现自我配置、自我优化、自我调整和自我适应,可以执行基于图神经网络的嵌入算法,进而基于语义的自配置解决方案进行搜索和任务的分解,但是在工业知识图谱的自建立和动态补充方面具有一定的局限性。

对于智能制造中的工艺知识推理,合理的特征利用是关键。当前的解决方案大多采取专家决

策和案例推理, 而专家决策和案例推理缺乏普适性, 受制于资源加工的信息以及加工设备的评估策略, 所以具有局限性。从以上分析可知, 如何进行知识图谱的动态构建、在推理过程中考虑局部特征和全局特征的联系是知识推理的关键。基于此, 本文提出一种面向知识图谱的工艺知识构建和推理方法, 在知识表示的基础上进行实体的切割和关系的提取, 采用本文所提出的知识推理算法解决工艺知识方面的决策和推理问题。

## 1 工艺知识图谱的构建

知识图谱一般采用三元组  $\langle h, r, e \rangle$  的结构<sup>[16]</sup>表示知识信息, 其中  $h$  和  $e$  可以映射为知识图谱中的节点,  $r$  为知识图谱中的关系。知识图谱的构建包括从非结构化文本中获取知识信息, 形式化地表示为结构性知识, 再进行异源知识的融合, 生成可视化的工艺知识图谱。利用知识提取可以从特定的工艺文本数据中将工艺知识信息进行识别、表示, 将图形进行识别再进行特征构建, 通过图谱构建规则进行知识的有效存储, 生成一种丰富的结构化语义知识库<sup>[17]</sup>。工艺知识图谱是在工艺知识概念节点与实例节点映射下生成的, 由于工艺知识中同类的产品在设计过程中具有极大的相似性, 所以在海量的知识数据中的某些设计过程知识是可以直接进行复用的。工艺知识图谱以图结构<sup>[18]</sup>的形式来存储数据及知识, 在不同层次的分类中会产生不同形态的工艺知识图谱, 通过图谱之间的内在关联产生高效的数据检索能力和智能化的知识推理能力。

### 1.1 工艺知识表示

本文将工艺知识图谱分为零件知识图谱、特征知识图谱和制造要求知识图谱3类。通过不同数据层的构建, 实现实例化工艺知识的统一形式化表征。工艺知识是采用三元组进行表示的, 对工艺知识进行去重和筛选操作, 构建成三元组存储方式的知识数据。其中零件知识图谱是由三元

组  $\langle \text{Part}, \text{obtain\_feature}, \text{Feature} \rangle$  表示的,  $\text{Part}$  表示头实体, 头实体由零件  $\text{Part-ID}$  和信息  $\text{Part-Info}$  (零件描述信息) 以及零件实体的名称 (零件名称)  $\text{Part-Name}$  组成,  $\text{Feature}$  为尾实体 (零件具有的属性),  $\text{obtain\_feature}$  为连接头实体和尾实体的关系, 表示之间所属情况。例如,  $\text{Part}$  可表示为导轨加工零件及其相关的加工设备、加工尺寸信息;  $\text{Feature}$  表示导轨零件具有的零件特征端面、外圆、轴外圆等特征信息;  $\text{obtain\_feature}$  表示为零件和特征之间的所属信息。

特征知识图谱由三元组  $\langle \text{Feature}, \text{feature\_require}, \text{Require} \rangle$  表示, 其中  $\text{Feature}$  为头实体, 头实体由特征  $\text{Feature-ID}$  和特征名称  $\text{Feature-name}$  组成;  $\text{feature\_require}$  是连接头实体  $\text{Feature}$  和尾实体  $\text{Require}$  的所属关系, 表示特征具有的加工要求;  $\text{Require}$  是尾实体 (加工制造要求属性值)。加工制造特征知识图谱主要表示的是每个加工制造特征对应的加工要求。例如,  $\text{Feature}$  表示轴外圆加工特征信息;  $\text{Require}$  表示表面粗糙度、加工精度等制造要求信息;  $\text{feature\_require}$  表示特征和制造要求之间的连接关系。

制造要求知识图谱由三元组  $\langle \text{Require}, \text{require\_prosta}, \text{ProSta} \rangle$  组成, 其中  $\text{Require}$  是头实体, 头实体由特征制造要求的  $\text{Require-ID}$  和制造要求的名称  $\text{Require-Name}$  组成,  $\text{require-prosta}$  是连接头实体  $\text{Require}$  和尾实体  $\text{ProSta}$  (加工制造工序) 的关系, 表示零件特征的制造要求  $\text{Require}$  可以被  $\text{ProSta}$  来进行加工完成。例如,  $\text{Require}$  表示 6 mm 的表面粗糙度信息,  $\text{ProSta}$  表示粗铣-精铣加工工序的信息,  $\text{require-prosta}$  表示制造要求与工序之间的联系。

### 1.2 工艺知识本体与知识图谱的映射

如图1所示, 工艺知识图谱是将工艺知识本体概念层视为树结构, 将顶层概念视为根节点, 采用自顶向下<sup>[19]</sup>的方法, 逐步将子概念与顶层概念

之间的关系进行细分。将本体作为工艺知识图谱的数据模式，使整个概念树完整地映射到工艺知识图谱中，生成准确的层次关系。将工艺知识图谱中的概念层次关系作为树的叉枝，将概念节点视为每个树的节点，节点之间采用层次关系进行相连。将知识图谱中的实体关系视为图结构，实体的节点视为图结构中相连的节点，采用带有语义表示的关系将节点之间联系起来<sup>[20]</sup>。实际上，工艺知识图谱中集成了异构数据来源，从而形成了知识图的边缘基础，其具体的映射关系如图2所示。

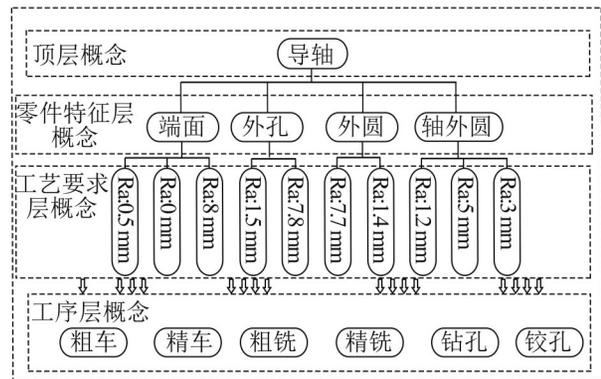


图1 工艺知识本体结构

Fig. 1 Process knowledge ontology structure

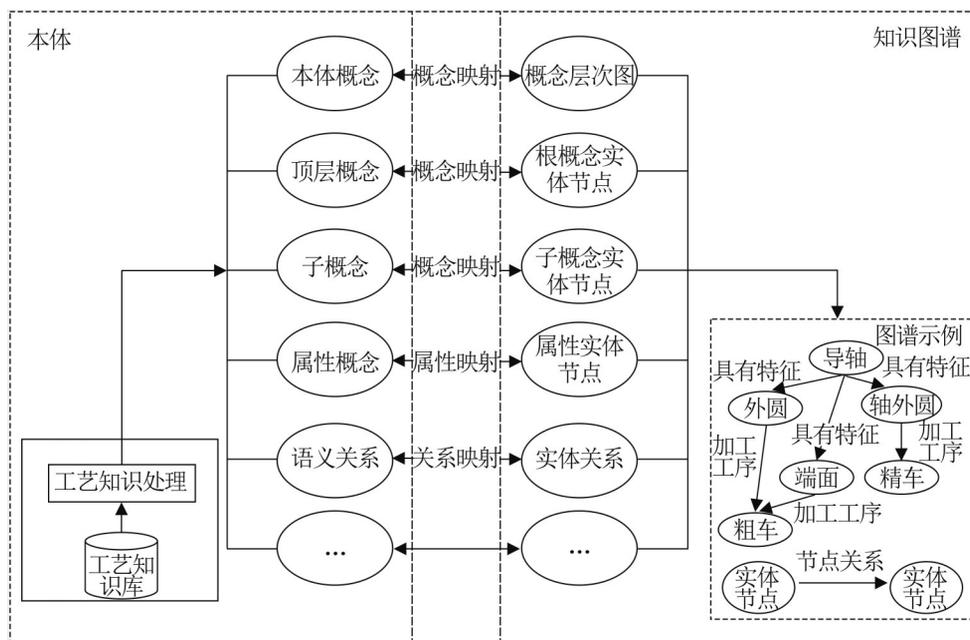


图2 工艺知识本体与知识图谱映射原理

Fig. 2 Mapping schematic of process knowledge ontology and knowledge map

图1~2中本体概念表示导轨零件所构建出来的包含特征属性、加工要求属性、加工工序属性的概念知识总体；顶层概念表示加工零件导轨；零件特征层概念表示加工零件导轨的特征，如端面、外孔、外圆等信息；工艺要求层概念表示加工零件导轨的加工要求表面粗糙度和加工精度；工序层概念表示零件在不同表面粗糙度和加工精度的情况下的加工工序等；语义关系表示的是层次节点与层次节点之间是否具有外圆、外孔等特征，以及外圆特征表面粗糙度为1.5 mm等关系。

### 1.3 工艺知识融合

由于实际的工艺设计过程不仅仅与加工的零件特征有关，还与零件所要求的加工信息以及过往的历史加工经验有关，对于这种多源数据，为了减少工艺数据的冗余并且保证工艺知识之间的准确性和一致性，将构建的知识图谱进行融合，实现工艺知识图谱信息的整合及资源的灵活调用。

工艺知识图谱中具有图结构的信息，为了解决不同知识图谱中的实体对齐问题，将同一实体在不同知识图谱中对应起来匹配到同一知识图谱

中, 平衡不同知识图谱中的损失, 生成完整的工艺知识。3 类知识图谱如图 3 所示, 将对应三元组信息中的关系映射为头节点指向尾节点的箭头线段, 其中 2 个节点以及之间的连接代表了 1 个三元组存储的数据。

本文运用图卷积网络 (graph convolutional network, GCN) 实体对齐<sup>[21]</sup>方法将构建的零件知识图谱、特征知识图谱、制造要求知识图谱进行知识融合, 在 3 层 GCN 网络模型的作用下, 对输入的图结构信息进行卷积信息操作。

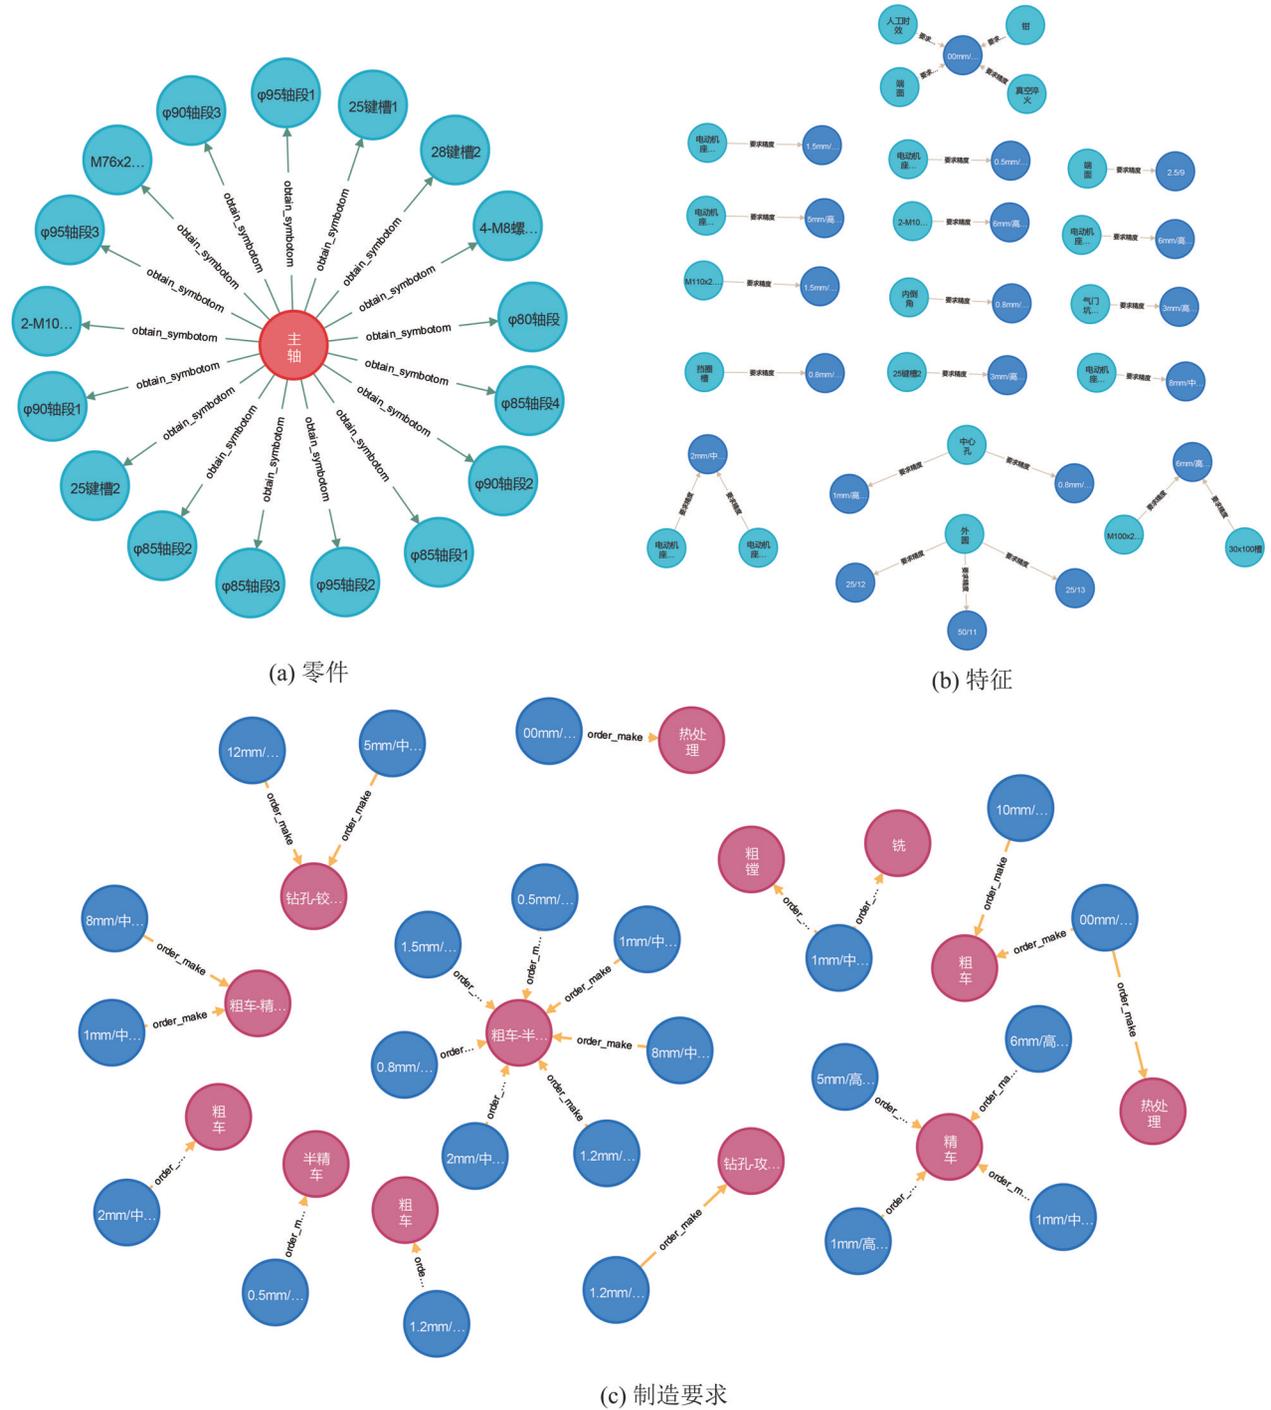


图 3 多层知识图谱显示  
Fig. 3 Multi-layer knowledge graph display

<http://www.china-simulation.com>

$$\mathbf{H}^{(t+1)} = s(\hat{\mathbf{Q}}^{-\frac{1}{2}} \hat{\mathbf{P}} \hat{\mathbf{Q}}^{-\frac{1}{2}} \mathbf{H}^{(t)} \mathbf{W}^{(t)}) \quad (1)$$

式中： $s$ 为激活函数； $\mathbf{P}$ 为一个 $n \times n$ 的邻接矩阵，代表着图的结构信息， $n$ 为特征节点数量； $\hat{\mathbf{P}} = \mathbf{P} + \mathbf{I}$ ， $\mathbf{I}$ 为一个单位矩阵； $\mathbf{H}^{(t)}$ 为网络的输入数据，为顶点特征矩阵； $\hat{\mathbf{Q}}$ 是 $\hat{\mathbf{P}}$ 的对角节点度矩阵； $\mathbf{W}^{(t)}$ 是GCN的权重矩阵。3层GCN对应融合的3层知识图谱，每个GCN处理一个知识图谱来生成实体的嵌入，每个GCN层中的每个实体分配2个特征向量，结构特征向量 $\mathbf{h}_s$ 和属性特征向量 $\mathbf{h}_a$ ，让 $\mathbf{H}_s$ 和 $\mathbf{H}_a$ 作为每一个GCN层中所有实体的结构和属性特征矩阵，重新定义卷积计算如下：

$$[\mathbf{H}_s^{(t+1)}; \mathbf{H}_a^{(t+1)}] = s\left(\hat{\mathbf{Q}}^{-\frac{1}{2}} \hat{\mathbf{P}} \hat{\mathbf{Q}}^{-\frac{1}{2}} [\mathbf{H}_s^{(t)} \mathbf{W}_s^{(t)}; \mathbf{H}_a^{(t)} \mathbf{W}_a^{(t)}]\right) \quad (2)$$

#### 1.4 工艺知识图谱构建

基于工艺知识本体的工艺知识图谱构建方法的准则：①分层融合。工艺知识图谱是本体、属性、概念模型的融合。一方面，通过本体知识模型描述工艺知识的核心，另一方面，通过概念、属性模型描述核心知识的约束条件和附加属性。②引入概念的多实例。概念的多实例是指概念与

实例之间因为属性的细微不同而在知识图谱中具有不同位置的关系。③与工艺知识内容本体的有机衔接。工艺知识内容本体主要刻画代加工零件、概念和属性，而知识图谱主要进行工艺知识实例层次方面的知识表示。工艺图谱构建流程如图4所示，根据工艺知识上层本体构建工艺知识内容本体，包含零件名称、加工特征、制造要求、加工工序、加工车床、零件材质等；根据知识本体从数据源中进行对应的抽取、去重、知识表示、知识映射和知识融合实现知识图谱的构建。知识图谱构建伪代码如下：

算法1：知识图谱构建

```

BEGIN
  初始化 data.xml,
  Info={"Product", "Require", "ProSta", "Pro_info"}
  xmlLine = 0, jsonLine = 0
  while xmlLine < MaxXmlLine
    Extraction_Attribute,
    Extraction_Relation,
    Extraction_Entity 生成JSON文件,
    xmlLine = xmlLine + 1
  while jsonLine < MaxJsonLine

```

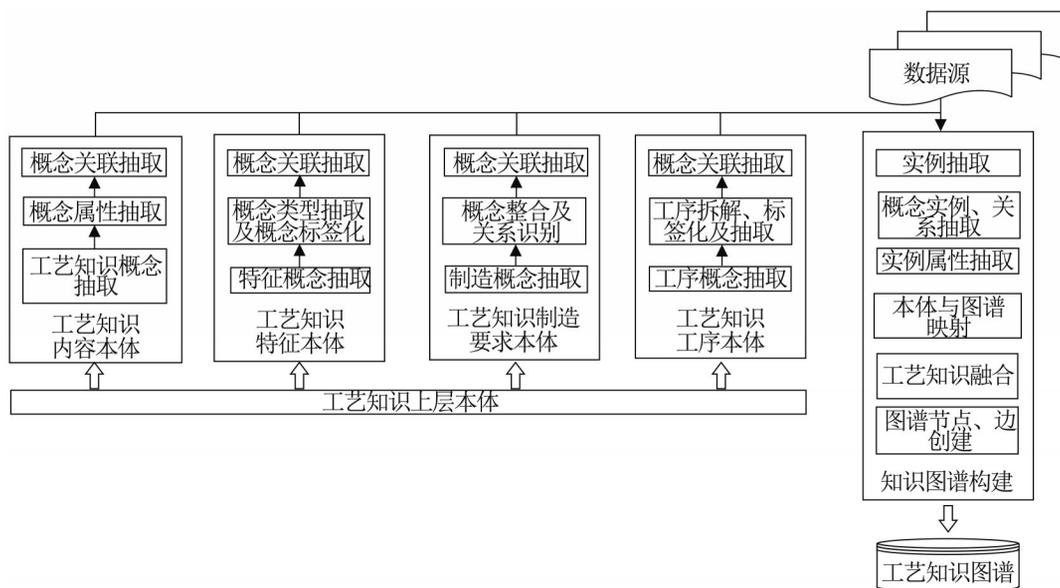


图4 基于工艺知识本体的知识图谱构建流程

Fig. 4 Knowledge mapping process based on process knowledge ontology

映射本体与图谱对应关系, 得到实体集合  $V = \{v_1, v_2, \dots, v_k\}$ ,  $jsonLine = jsonLine + 1$   
知识融合, 生成 Proect\_dict  
创建 Part\_node、Feature\_node、Require\_node、ProSta\_node  
创建 Part\_Feature, Feature\_Require, Require\_ProSta 关系边  
END

其中,  $xmlLine$  表示实例文件 data.xml 中的当前行数;  $jsonLine$  表示关系抽取文件中的当前行数; Info 表示实例抽取存放类型; Extraction\_Attribute 表示抽取属性; Extraction\_Relation 表示抽取关系; Extraction\_Entity 表示抽取实体; Proect\_dict 表示映射完成的知识词典, 根据词典可以生成图 3 中对应不同层次的知识图谱。

## 2 工艺知识推理模型

传统的知识重用系统中多采用特定关键字进行知识的搜索, 例如, 搜索“导轴”零件在单个数据库中进行查询(只是键入“导轴”关键字), 搜索知识比较杂乱且没有关联性。知识图谱的引入允许了多约束文本的语义解析过程, 例如, 查询带有“导轴”的特征(导轴零件所具有的制造特征包括?)增加了查询知识之间的模糊关联, 允许查询的语义解析, 可以返回可视化的搜索显示结果, 有助于更好地理解知识内容。本文提出

一种知识推理模型, 通过高效的知识获取, 将其目标知识和查询知识进行关联, 实现工艺知识信息的高效查询和推理, 其包括了工艺知识局部特征提取(E)、工艺知识特征整合(I)、工艺知识特征匹配(M) 3 个阶段, 通过 EIM 工艺知识推理模型实现匹配查询语句中包含的特征和知识图谱之间的联系, 提出的工艺知识推理方法如图 5 所示。

### 2.1 工艺知识推理总体流程

针对知识推理中局部特征的利用不充分问题, 本文设计的集成工艺知识图谱与知识推理模型的推理方法总体流程如图 6 所示。主要包括 4 个部分, 分别是工艺知识图谱可视化构建、文本数据模型解析、知识推理 EIM 模型、数控工艺知识方案生成。工艺知识图谱的可视化构建是数控工艺知识方案生成的核心; 知识推理 EIM 模型包括基于语义信息的特征提取、基于图卷积的特征融合、基于图匹配的特征知识信息匹配; 通过知识图谱的构建和知识推理模型生成的工艺知识方案再进行知识图谱和知识库的更新存储。基于知识图谱中的强语义和强关联性质, 在面向知识图谱的工艺知识推理方法中可以充分提升知识推理准确性和高效性。不仅可以缓解知识图谱中可能存在的工艺知识案例和实体规则之间分离不足的缺点, 还可以兼容知识图谱中存在的直观的信息关系。推理流程的推理算法如下。其中 GM 表示知识图谱匹配过程, KG 表示生成的知识图谱。

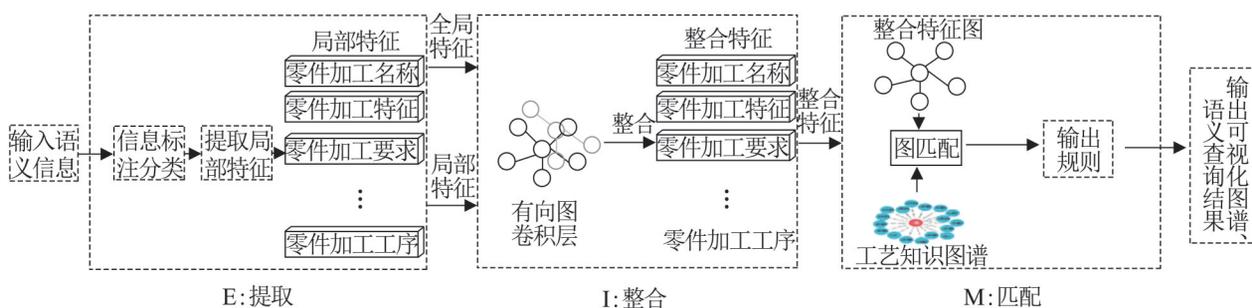


图 5 知识推理模型 EIM  
Fig. 5 Knowledge reasoning model EIM

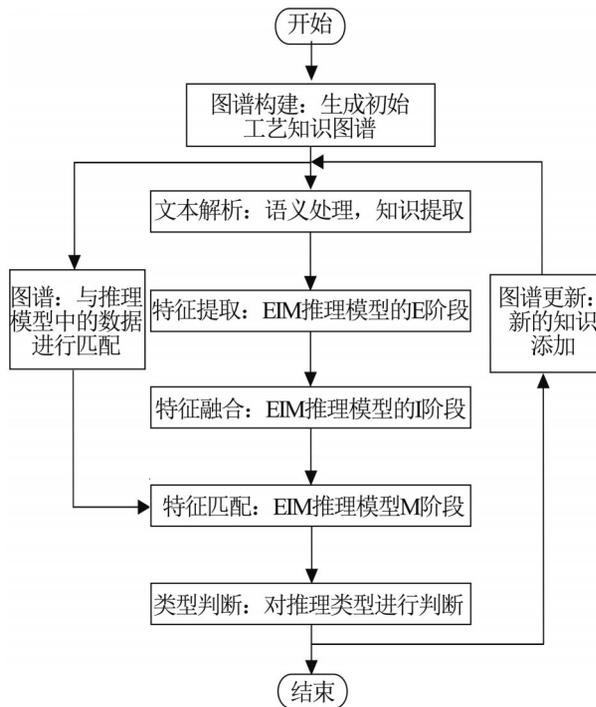


图6 基于工艺知识图谱的知识推理流程

Fig. 6 Process knowledge reasoning process based on knowledge map

## 算法2: 知识推理算法

BEGIN

获取输入查询语义信息 Question

 $t_{ex} \leftarrow \text{Classify}(\text{Question})$ , 生成  $t_{ex}$  语义特征生成局部特征  $V_1 = g(t_{ex})$ 生成全局特征  $V_g = f(t_{ex})$ 计算差异权重矩阵  $A_{tr}$ 、连接矩阵  $A$ , 初始化全连接层  $f_1$ 、 $f_2$  $V_o \leftarrow [f_1(V_1) + f_2((A_{tr} + A) \otimes V_1), V_g]$ 匹配结果  $V_o \leftarrow GM(V_o, KG)$ , 判断推理类型

返回推理文本结果

END

## 2.2 工艺知识特征提取

知识推理模型中工艺知识特征提取阶段的目标是提取输入文本信息的一阶语义特征。对于输入的文本信息进行标注分类<sup>[22]</sup>, 根据算法设置匹配得到工艺零件的信息内容, 因为输入的信息可能不完善, 所以本文在E阶段对其输入文本信息

进行局部特征的提取, 提取出残缺的零件特征信息和完整的零件特征信息, 获得一组关键的语义局部特征  $V_1$  和全局特征  $V_g$ 。这个过程可以表示为

$$\begin{aligned} V_1 &= \{v_k\}_{k=1}^K = g(t_{ex}) \\ V_g &= v_g = f(t_{ex}) \end{aligned} \quad (3)$$

式中:  $t_{ex}$  为经过信息标注分类提取到的语义特征, 如“导轴”“制造要求”“加工工序”等;  $V_1$  为根据语义特征生成的局部特征集合, 由  $\{v_1, v_2, \dots, v_k\}$  个局部特征组成;  $g(\cdot)$  为一个全局平均函数;  $V_g$  为根据语义特征生成的全局特征;  $f(\cdot)$  为一个全局特征函数。

## 2.3 工艺知识特征融合

在工艺知识推理重用的过程中, 输入的语义信息(“导轴的加工路线”)中仅有加工零件、加工工序的特征信息, 没有加工特征和加工要求等特征信息, 所以传入I阶段的数据特征信息是残缺的。由于局部特征的不完整性, 通过GCN卷积网络将不同的高阶语义特征区域视为不同的节点信息, 在对其进行建模的基础上实现节点之间的信息传递, 找到全局特征和局部特征之间的关联程度。由图5可知, 在本文提出的EIM知识推理模型中, I阶段的输入为E阶段的输出, 在工艺知识整合阶段所做的工作就是将E阶段提取出来的局部特征和全局特征进行关联程度上的整合, 找寻出残缺信息下的局部特征与全局特征之间的关联。赋予不同特征之间不同的权重信息, 将带有权重信息的节点特征传递给知识推理M阶段。整个过程可以表示为

$$V_o = [f_1(V_1) + f_2((A_{tr} + A) \otimes V_1), V_g] \quad (4)$$

式中:  $A_{tr}$  为局部特征  $V_1$  和全局特征  $V_g$  之间的差异权重;  $A$  为连接矩阵, 代表特征之间的关系, 在特征与特征之间有关系时表示为1, 没有关系时为0;  $V_o$  为带有关联信息的特征数据;  $f_1$ 、 $f_2$  为2个全连接层, 将特征向量变换为另一个特征空间, 来进行特征加权和。

$$f_1 = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1k} \\ w_{21} & w_{22} & \dots & w_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ w_{k1} & w_{k2} & \dots & w_{kk} \end{bmatrix} \quad (5)$$

将文本局部特征和全局特征作为输入, 通过比较局部特征和全局特征之间的差异, 然后与转置的全局特征进行矩阵相乘的运算, 其结果与标准化的邻接矩阵  $A$  进行元素间相乘得到带有特征联系信息的邻接矩阵, 通过与原先的局部特征进行矩阵相乘, 得到带有关联信息的局部特征, 再与局部特征进行融合输出新的特征信息。

具体原理如图 7 所示,  $\ominus$  表示对应位置的元素相减,  $\otimes$  表示矩阵之间的乘法,  $\boxtimes$  表示对应位置的元素相乘,  $\oplus$  表示对应位置的元素相加,  $K$  表示特征的维度。

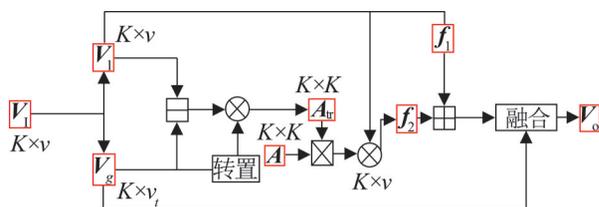


图 7 工艺知识特征融合

Fig. 7 Process knowledge feature fusion

### 2.4 工艺知识特征匹配

一种简单的匹配策略是匹配同样相同关键点之间的特征, 但是这种匹配策略往往无法应对一些复杂的情况, 例如, 离散值、特征缺失等情况。图匹配方法可以充分利用输入的零件特征信息, 还可以避免出现一对一的匹配干扰。本文采用图匹配方法对 I 阶段提取出特征数据, 可以有效减少特征缺失的影响, 聚集于未缺失特征信息的匹配。具体匹配原理如图 8 所示, 对于 I 阶段提取到的特征信息  $V_1$  和构建好的  $KG$ , 通过全连接层  $f_c$ 、 $f_{kg}$  的作用后进行图匹配  $GM$  操作, 得到知识图谱和特征信息之间的关系矩阵  $N$ ,  $N$  代表这两个图结构中的特征间的对应关系。将  $N$  与输入特征进行乘法操作, 再与图谱  $KG$  的信息进行合并, 得到最终的匹配特征信息。

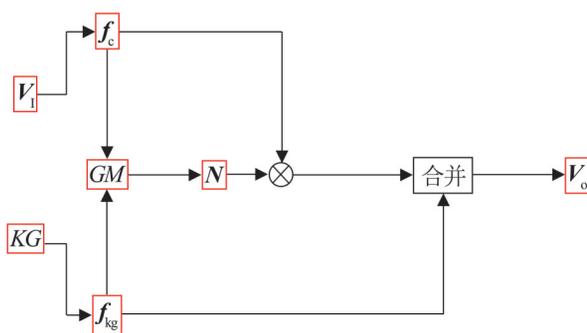


图 8 工艺知识特征匹配

Fig. 8 Process knowledge feature matching

## 3 工艺知识推理实例分析

本节通过一个案例验证所提方法的可行性, 同时展示该方法如何进行图谱的构建和推理。基于知识图谱的知识推理方法充分利用了知识图谱的语义性以及强关联性, 增加了查询知识和知识图谱之间的关联显示, 不仅可以进行特定的查询, 还可以允许提供模糊的查询对象, 以可视化的方式获得关联知识。案例研究包括构建具有本体知识的工艺知识图谱、利用提出的 EIM 知识推理模型推理文本输入的语义查询信息。

### 3.1 对比模型

本文实验运行的环境为 2.8GHz Inter(R)Core (TM)i5 处理器和 16 GB 内存的计算机, 操作系统为 Windows 7, 运行的编程语言为 Python 3.8。本节给出 EIM 模型在 MovieLens-1M、Book-Crossing、Last.FM 3 个数据集<sup>[23]</sup>上 CTR(click through rate)预测的正确率(ACC)与另外 2 个代表模型进行推理性能的对比。

(1) KGCN<sup>[23]</sup>: 利用图神经网络实现知识图谱中高阶信息的捕获、挖掘。

(2) RippleNet<sup>[24]</sup>: 利用历史信息, 结合知识图谱和推荐系统发现潜在的关联信息。

(3) EIM: 本文提出的知识推理模型。

如表 1 所示, EIM 推理模型在 3 个数据集上的 ACC 指标都有所提高, 在 Book-Crossing 数据集上提高明显, 有效利用了知识图谱中局部特征之间

的关系,提取了特征之间的交互信息,建立了特征之间的相关性,提高了模型的推理性能。

表1 CTR预测中的ACC结果  
Table 1 Results of Acc in CTR prediction

模型	MovieLens-1M	Book-Crossing	Last.FM
RippleNet	0.843 6	0.646 9	0.722 3
KGCN	0.832 7	0.635 5	0.723 8
EIM	0.849 7	0.697 3	0.746 5

### 3.2 工艺知识分析

利用EIM推理模型进行工艺实例的验证。本文所构建的工艺知识图谱使用的工艺知识和数据来自于制造企业的知识库数据、开展项目中的工艺数据、课题组成员积累的工艺数据、制造行业的加工工艺手册、网络爬虫爬取网站整理得到的工艺知识。其示例如表2所示。

表2 工艺知识实例  
Table 2 Process knowledge examples

属性	描述
ID	5bb578b6831b973a137e3ec6
零件名称	导轴
特征	外圆、边槽、孔
表面粗糙度/mm	2.5、10、1.5
制造精度	IT9、IT10、IT7
加工工序	粗车-半精车-精车-精磨-钻孔-铣孔
加工车床	AD-35型多功能数控车床
是否淬火	否
有色金属	不存在

对获取到的工艺知识数据进行简单的处理,删减了基本重复的工艺知识数据,并且用XML文

件格式将其进行存储,在存储前进行工艺知识的简单关系提取和标注,形成JSON文件表示的智能制造工艺知识数据集。部分工艺实例数据如表3所示。数据集中包含的节点概念数据为228;包含的工艺概念知识连接边为419。

### 3.3 工艺知识图谱构建

本文根据本体概念构建工艺知识本体,抽取对应实例的顶层概念、特征概念、工序概念、加工要求概念,根据其关联程度抽离出规范的工艺知识。在工艺知识本体与知识图谱映射的关系下,对工艺实例进行遍历,得到本体和特征概念的对象,对工艺实例数据中的228个节点概念进行预处理,构建出228个工艺实例本体节点、子概念节点,包含零件、特征、制造要求、加工工序等节点;再遍历JSON文件中的各个对象的属性,构建出在三元组 $\langle h, r, e \rangle$ 形式下的本体和特征之间关系的字典,通过去重操作,筛检不必要的信息,构建出本体和子概念之间的419个工艺知识关联边,包含了零件-特征、特征-要求、要求-工序等关联边。通过知识融合过程将其转化为结构化工艺知识图谱,对零件、制造特征、制造要求不同分层的知识图谱进行工艺知识融合操作,生成完整的图形化的工艺知识图谱,如图9表示。由图9可以看出该工艺知识图谱中包含228个工艺知识节点和419个工艺知识关联边,工艺知识图谱中不同零件特征之间具有重合度非常高的加工工序,呈现出非常大的关联度,在节点与节点、节点与边的关系上可以进行深一步的知识推理和表征。

表3 工艺实例数据  
Table 3 Process instance data

ID	零件名称	特征	表面粗糙度/mm	精度	加工工序
133	导轴	外圆	2.5	IT9	粗车-半精车-精车
133	导轴	边槽	10	IT10	精磨
133	导轴	孔	1.5	IT7	钻孔-铣孔
134	主轴	外螺纹	2	IT10	粗车-半精车-车螺纹
134	主轴	轴段	8	IT9	粗车-半精车-精车-精磨
134	主轴	键槽	1.5	IT9	粗车-半精车
134	主轴	螺纹孔	0.5	IT8	粗车-车螺纹

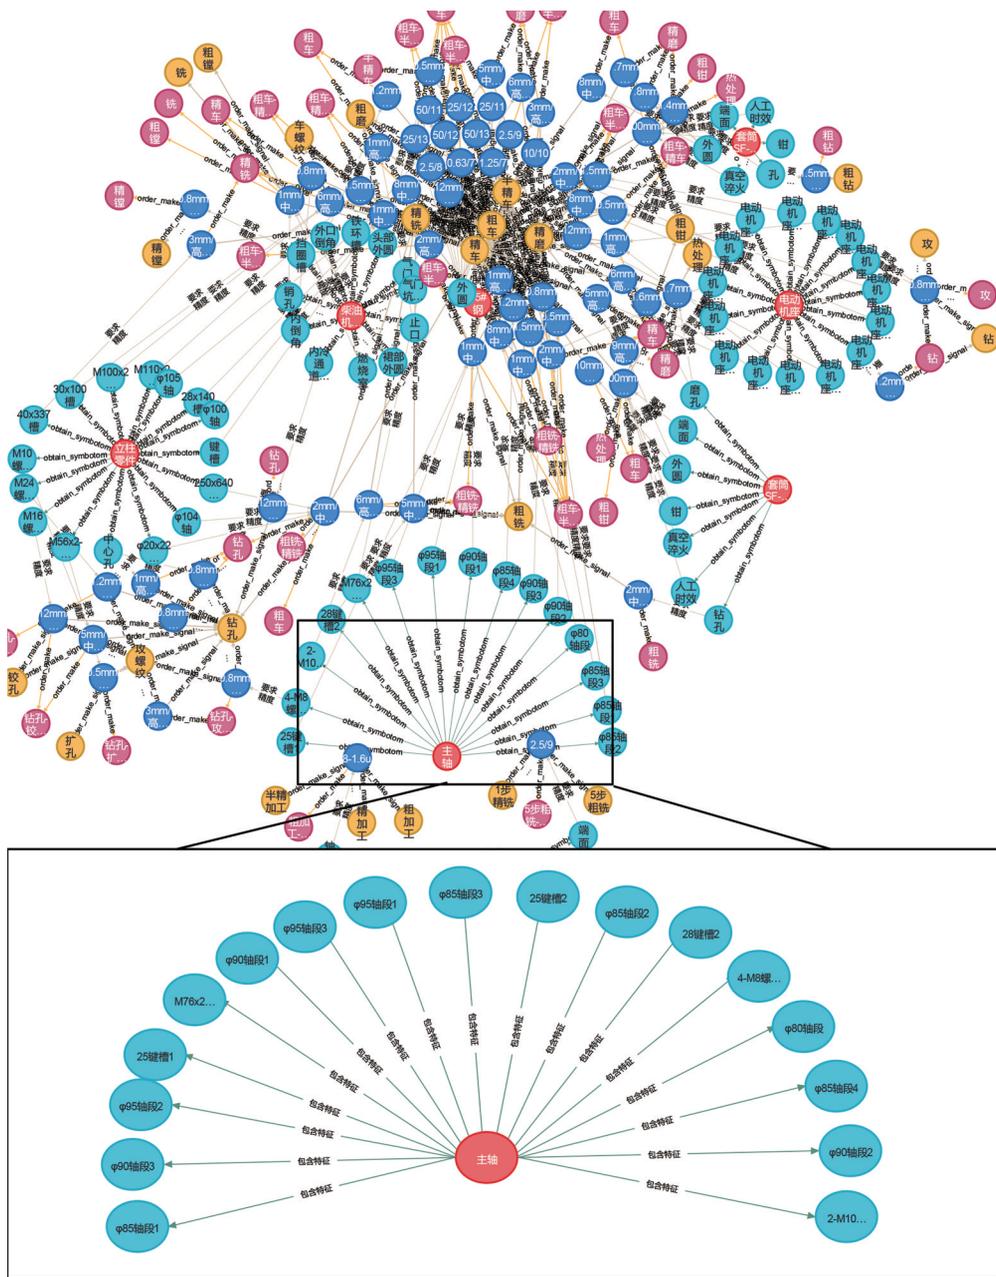


图9 工艺实例数据的工艺知识图谱表示

Fig. 9 Process knowledge graph representation of process instance data

### 3.4 工艺知识推理

基于构建好的知识图谱, 可以支持进一步的知识推理任务, 结合工业制造场景中的零件输入诉求(立柱零件包含的中心孔的制造要求), 通过语义分析, 提取出零件的名称(立柱零件)、加工特征(中心孔)、加工要求(制造要求)、局部特征和全局加工特征; 对特征融合操作, 生成带有特征差异

信息的数据传递给图匹配阶段, 进行工艺知识的推理和查询, 利用本文的EIM知识推理模型, 生成正确的工艺知识推理结果。

一种基于知识图谱的知识推理结果如图10所示, 该推理方法可以实现实时查询推理问题, 并返回知识图谱中具有连接关系的文本信息, 进行可视化显示, 提供直观的查询体验。

请输入零件信息: 立柱零件的加工特征  
 客服机器人: 立柱零件所包含的特征包括: M10螺纹孔; M56x2-6G螺纹孔; φ105轴; 30x100槽; 键槽; M16螺纹孔; φ21x510孔;  
 请输入零件信息: 立柱零件包含的中心孔的制造要求  
 客服机器人: 零件立柱零件中特征中心孔的加工要求为0.8mm/中低精度和1mm/高精度  
 请输入零件信息: 零件立柱零件中中心孔特征在0.8mm/中低精度下的加工流程是什么  
 客服机器人: 零件立柱零件中中心孔特征在0.8mm/中低精度的加工要求情况下的加工工序包含: 钻孔  
 请输入零件信息: 主轴的4-108螺纹孔的制造要求  
 客服机器人: 零件主轴中特征4-108螺纹孔的加工要求为0.8mm/中低精度  
 请输入零件信息:

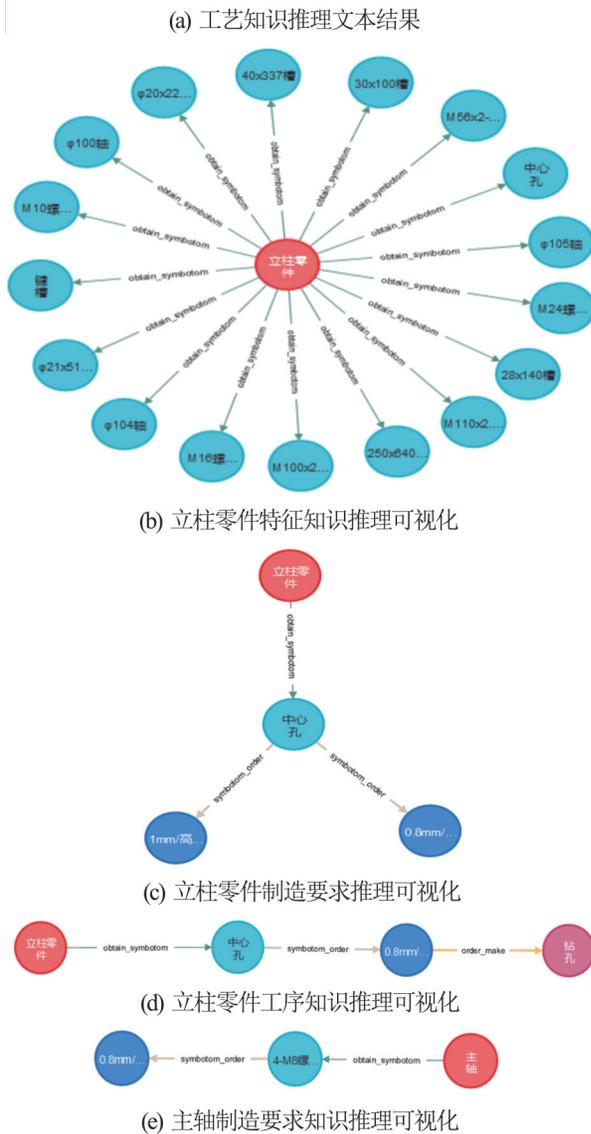


图 10 工艺知识推理结果  
Fig. 10 Reasoning results of process knowledge

## 4 结论

本文针对工艺知识表示中存在的繁杂及难以统一表示问题, 以及工艺知识共享和推理重用问题, 提出一种基于工艺知识本体的知识推理方法, 通过知识图谱的构建, 在知识图谱的基础上利用本文提出的知识推理模型, 对输入的多约束文本查询语句进行特征解析、提取, 与构建好

的知识图谱进行相应的图匹配操作, 从而进行工艺知识的推理重用。在 3 个数据集上进行了预测推理能力的对比, 相比其他 2 种算法, 本文的知识推理模型取得了较好的预测效果, 在某车间工艺知识推理实验结果下, 相较于普通的决策推理, 本文提出的知识推理方法可以实现工艺知识的高效推理和利用, 获得满意的推理结果。

## 参考文献:

- [1] He L L, Jiang P Y. Manufacturing Knowledge Graph: A Connectivism to Answer Production Problems Query With Knowledge Reuse[J]. IEEE Access(S2169-3536), 2019, 7: 101231-101244.
- [2] Steiner T, Verborgh R, Troncy R, et al. Adding Realtime Coverage to the Google Knowledge Graph[C]// International Semantic Web Conference. 11th ISWC 2012. Boston, USA: Central Europe, 2012: 11-15.
- [3] 王保魁, 吴琳, 胡晓峰, 等. 基于知识图谱的联合作战态势知识表示方法[J]. 系统仿真学报, 2019, 31(11): 2228-2237.  
Wang Baokui, Wu Lin, Hu Xiaofeng, et al. Knowledge Representation Method of Joint Operation Situation Based on Knowledge Graph[J]. Journal of System Simulation, 2019, 31(11): 2228-2237.
- [4] 饶子昀, 张毅, 刘俊涛, 等. 应用知识图谱的推荐方法与系统[J]. 自动化学报, 2021, 47(9): 2061-2077.  
Rao Ziyun, Zhang Yi, Liu Juntao, et al. Recommendation Method and System for Applying Knowledge Graph[J]. Acta Automatica Sinica, 2021, 47(9): 2061-2077.
- [5] Cheng D W, Yang F Z, Wang X Y, et al. Knowledge Graph-Based Event Embedding Framework for Financial Quantitative Investments[C]// 43th International ACM SIGIR Conference on Research and Development in Information Retrieval(SIGIR). Xian, China, 2020: 2221-2230.
- [6] Khalid M M, Madan K, Mazen A, et al. Automated Domain-Specific Healthcare Knowledge Graph Curation Framework: Subarachnoid Hemorrhage as Phenotype[J]. Expert Systems With Applications(S0957-4174), 2020, 145(C): 113120.
- [7] Yan H H, Yang J, Wan J F. KnowIME: A System to Construct a Knowledge Graph for Intelligent Manufacturing Equipment[J]. IEEE Access(S2169-3536), 2020, 8: 41805-41813.
- [8] Abu-Salih B, Alsawalqah H, Elshqeirat B, et al. Toward a Knowledge-Based Personalised Recommender System

- for Mobile App Development[J]. CoRR(S0916-8508), 2019, 9: 12322-12330.
- [9] Zheng H, Yang S, Lou S H, et al. Knowledge-Based Integrated Product Design Framework Towards Sustainable Low-carbon Manufacturing[J]. Advanced Engineering Informatics(S1474-0346), 2021, 48: 101258-101269.
- [10] Peng G Z, Wang H W, Zhang H M, et al. A Hypernetwork-Based Approach to Collaborative Retrieval and Reasoning of Engineering Design Knowledge[J]. Advanced Engineering Informatics (S1474-0346), 2019, 42: 100956-100967.
- [11] Li H T, Ren W, Du Y F, et al. A Parameter-Extended Case-Based Reasoning Method Based on a Functional Basis for Automated Experiential Reasoning in Mechanical Product DesignsP[J]. Advanced Engineering Informatics(S1474-0346), 2021, 50: 101409-101421.
- [12] Tai J J, Li H T, Du Y F, et al. A Knowledge-Based Automated Design System for Mechanical Products Based on a General Knowledge Framework[J]. Expert Systems with Applications(S0957-4174), 2021: 178: 114960-114971.
- [13] Zhou B, Bao J S, Li J, et al. A Novel Knowledge Graph-Based Optimization Approach for Resource Allocation in Discrete Manufacturing Workshops[J]. Robotics and Computer-Integrated Manufacturing(S0736-5845), 2021, 71(3): 102160-102179.
- [14] Hka B, Pw A, Yan L A, et al. Machine Learning and Knowledge Graph Based Design Rule Construction for Additive Manufacturing[J]. Additive Manufacturing (S2214-8604), 2020, 37: 101620-101633.
- [15] Zheng P, Xia L Q, Li C X, et al. Towards Self-X Cognitive Manufacturing Network: An Industrial Knowledge Graph-Based Multi-agent Reinforcement Learning Approach[J]. Journal of Manufacturing Systems (S0278-6125), 2021, 61: 16-26.
- [16] Li Q, Wang D L, Feng S, et al. Global Graph Attention Embedding Network for Relation Prediction in Knowledge Graphs[J]. IEEE Transactions on Neural Networks and Learning Systems(S2162-237X), 2021, 31: 34-48.
- [17] Shi M, Tsai S B. Knowledge Graph Question and Answer System for Mechanical Intelligent Manufacturing Based on Deep Learning[J]. Mathematical Problems in Engineering(S1024-123X), 2021(2): 1-8.
- [18] Ma T, Lü S, Huang L, et al. HiAM: A Hierarchical Attention Based Model for Knowledge Graph Multi-hop Reasoning[J]. Neural Networks(S0893-6080), 2021, 143: 261-270.
- [19] Zhu M Y J, Pao B K, Xu C S. Research Progress on Development and Construction of Knowledge Graph[J]. Journal of Nanjing University of Information Science and Technology(S1674-7070), 2017, 9(6): 575-588.
- [20] Wang Z K, Li L J, Zeng D. SRGCN: Graph-Based Multi-hop Reasoning on Knowledge Graphs[J]. Neurocomputing (S0925-2312), 2021, 454: 280-290.
- [21] Chen Z W, Xu J M, Peng T, et al. Graph Convolutional Network-Based Method for Fault Diagnosis Using a Hybrid of Measurement and Prior Knowledge[J]. IEEE Transactions on Cybernetics(S2168-2267), 2021, 99: 1-13.
- [22] Sha X, Sun Z, Zhang J. Hierarchical Attentive Knowledge Graph Embedding for Personalized Recommendation[J]. Electronic Commerce Research and Applications(S1567-4223), 2021, 48(3): 101071-101084.
- [23] Wang H W, Zhang F Z, Wang J L, et al. RippleNet: Propagating User Preferences on the Knowledge Graph for Recommender Systems[C]//27th ACM International Conference on Information and Knowledge Management, Torino, Oct 22-26, 2018. New York: ACM, 2018: 417-426.
- [24] Wang H W, Zhao M, Xie X, et al. Knowledge Graph Convolutional Networks for Recommender Systems[C]//2019 World Wide Web Conference. San Francisco, May 13-17, 2019. New York: ACM, 2019: 3307-3313.