

知识图谱推理研究综述: 从单一任务到复杂任务^{*}

牛广林, 栗思悦, 李 波

(北京航空航天大学 人工智能学院, 北京 100191)

通信作者: 李波, E-mail: boli@buaa.edu.cn



摘 要: 知识图谱可以有效组织和利用现实世界中的各类知识, 弥补数据驱动的方法或者大模型技术存在的不可解释和幻觉等不足, 是实现具有理解和推理能力的认知智能系统的核心技术之一. 知识图谱推理是从已有的知识推理出新的知识, 广泛应用于工农业生产、国防安全、日常生活等领域. 早期知识图谱推理领域主要关注单一推理任务, 近 3 年逐渐开始关注更加复杂的推理任务, 包括时序多步知识图谱推理、小样本多步知识图谱推理、小样本时序知识图谱推理、小样本多模态知识图谱推理、多模态归纳式知识图谱推理和时序归纳式知识图谱推理. 为此, 首先分别描述面向单一任务和复杂任务的知识图谱推理的特点, 进而, 介绍几类面向单一任务的知识图谱推理技术. 然后系统总结面向复杂任务的已有代表性知识图谱推理方法, 并对这些方法进行对比分析. 最后, 总结和探讨当前知识图谱推理仍存在的主要问题, 并对该领域有价值的未来发展方向进行展望.

关键词: 知识图谱推理; 单一任务和复杂任务; 知识表示学习; 多模态学习; 大模型

中图法分类号: TP18

中文引用格式: 牛广林, 栗思悦, 李波. 知识图谱推理研究综述: 从单一任务到复杂任务. 软件学报. <http://www.jos.org.cn/1000-9825/7627.htm>

英文引用格式: Niu GL, Su SY, Li B. Review of Knowledge Graph Reasoning Research: From Single Tasks to Complex Tasks. Ruan Jian Xue Bao/Journal of Software (in Chinese). <http://www.jos.org.cn/1000-9825/7627.htm>

Review of Knowledge Graph Reasoning Research: From Single Tasks to Complex Tasks

NIU Guang-Lin, SU Si-Yue, LI Bo

(School of Artificial Intelligence, Beihang University, Beijing 100191, China)

Abstract: Knowledge graphs effectively organize and exploit diverse real-world knowledge, alleviating limitations of purely data-driven methods and large language models, such as limited interpretability and hallucination, and serve as one of the core technologies for cognitive intelligent systems with understanding and reasoning capabilities. Knowledge graph reasoning aims to infer new knowledge from existing knowledge and is widely applied in various fields, including industrial and agricultural production, national defense and security, and daily life. Early studies on knowledge graph reasoning primarily focus on single tasks, while recent research increasingly shifts attention to more complex tasks. These complex tasks include temporal multi-step knowledge graph reasoning, few-shot multi-step knowledge graph reasoning, few-shot temporal knowledge graph reasoning, few-shot multi-modal knowledge graph reasoning, multi-modal inductive knowledge graph reasoning, and temporal inductive knowledge graph reasoning. Accordingly, this study first describes the characteristics of knowledge graph reasoning for single tasks and complex tasks. Subsequently, several representative knowledge graph reasoning techniques for single tasks are introduced. Then, existing representative knowledge graph reasoning methods for complex tasks and conduct a comparative analysis of these methods are systematically summarized and comparatively analyzed. Finally, the major remaining challenges in knowledge graph reasoning are discussed, and promising future research directions are outlined.

Key words: knowledge graph reasoning; single task and complex task; knowledge representation learning; multi-modal learning; large language model (LLM)

^{*} 基金项目: 国家自然科学基金 (62376016, U25A20531)

收稿时间: 2025-01-27; 修改时间: 2025-10-29; 采用时间: 2025-12-29; jos 在线出版时间: 2026-06-24

人工智能中的深度学习技术通过强大的算力和大量的标注数据,在感知智能领域发挥出显著的效果,但是存在显著的不可解释性,且由于其缺乏有效的语义知识导致难以直接用于对数据间关联挖掘和推理决策等任务.虽然大模型 (large language model, LLM) 技术当前成为研究热点之一,但是其缺乏显式的知识导致存在明显的幻觉问题.为了充分建模和利用准确且显式的知识,知识图谱技术采用有向图结构来描述知识和建模世界万物之间的关联^[1,2].知识图谱中节点表示实体,边表示实体之间具体的关联关系,每个关系及其连接的两个实体共同构成一个事实三元组 (头实体, 关系, 尾实体).学术界和工业界都发现了知识图谱的实用价值并构建了各种各样的知识图谱,国外的典型知识图谱如 Freebase^[3]、YAGO^[4]、WordNet^[5]、NELL^[6]和 DBpedia^[7]等,国内的代表性知识图谱例如百度百科知识图谱、美团餐饮娱乐知识图谱、阿里巴巴电商知识图谱等.这些知识图谱已经在关系抽取^[8]、语义搜索^[9]、对话系统^[10]、问答系统^[11]和推荐系统^[12]等多种任务中发挥了重要作用.

然而,大多数知识图谱都不可避免地存在不完备的问题^[13],例如知识图谱 Freebase 中有 75% 的人没有国籍信息^[14],DBpedia 中 60% 的人没有出生地信息^[15].让计算机像人类一样根据知识图谱中已有的知识,从中寻找到这些知识蕴含的语义关联并推理出未知的知识以补全知识图谱是这一研究领域的核心目标,因此知识图谱推理技术也被称为知识图谱补全^[16].当前,知识图谱推理技术已经广泛应用于公安线索发现^[17,18]、新冠病毒药物发现^[19]、债券市场风险监管^[20]、商品推荐^[21]、语音助手^[22]、智能司法^[23]等实际场景.

虽然当前已有大量关于知识图谱推理的研究和一些综述工作,但是其中大部分综述研究都仅基于某一类技术作为分类标准,例如马昂等人^[24]从强化学习的角度,吴越等人^[25]和孙水发等人^[26]从图神经网络的角度,刘洪波等人^[27]从规则学习的角度分别总结了知识图谱推理方法.此外,现有综述研究只考虑了从知识图谱类型出发的单一推理任务^[28-34],例如王春雷等人^[35]专门针对多模态知识图谱,沈英汉等人^[36]和肖蕾等人^[37]面向时序知识图谱,梁新雨等人^[38]面向存在未见实体和关系的知识图谱,分别介绍对应的知识图谱推理任务的特点和现有方法.特别的,Liang 等人^[39]较为全面地从静态、动态和多模态这 3 类知识图谱的角度总结了现有的知识图谱推理方法.可以看到,已有的知识图谱推理相关综述文献主要从单一推理任务的角度介绍知识图谱推理相关工作,而实际中针对知识图谱的推理任务普遍存在不同单一推理任务间耦合的情况,例如针对公共安全领域的时序知识图谱,进行线索挖掘和多步推理的过程中需要结合事件发生的时效性和事件间的时序性,面向单一任务的方法难以解决这一问题,因此采用时序多步知识图谱推理技术非常关键.可见,面向复杂任务的知识图谱推理具有重要的研究价值和实际意义,然而,当前研究缺少对面向复杂任务的知识图谱推理完整分类体系的探讨,且没有对这一视角的相关方法进行系统性的总结和分析.因此,在现有面向单一任务的知识图谱推理方法的基础上,值得进一步对更具实际意义的面向复杂任务的知识图谱推理现有研究开展系统全面的梳理和总结.

不同于以往按照知识图谱类型的知识图谱推理方法分类原则,本文从面向不同推理任务的视角,致力于充分调研和全面梳理知识图谱推理方向相关的工作,总结并提出面向 6 类单一任务和 6 类复杂任务的知识图谱推理研究分类体系.本文第 1 节总结针对知识图谱推理的任务分类体系,根据知识图谱的类型并结合已有综述论文简要介绍 6 类单一任务,同时梳理单一任务和本文综述研究重点关注的复杂任务间的关联,并分析针对知识图谱推理领域单一任务和复杂任务的特点.第 2 节具体介绍已有的 6 类面向单一任务的知识图谱推理技术.第 3 节对 6 类面向复杂任务的知识图谱推理现有方法进行梳理和总结,包括时序多步知识图谱推理、小样本多步知识图谱推理、小样本时序知识图谱推理、小样本多模态知识图谱推理、多模态归纳式知识图谱推理和时序归纳式知识图谱推理,并探讨这些方法的特点.此外,第 4 节对知识图谱推理领域有待进一步深入探索的未来研究方向进行展望,讨论该领域仍存在的主要挑战和有价值的研究思路.

1 针对知识图谱推理的任务分类

由于当前研究缺乏对知识图谱推理任务的系统性总结,本文首先针对知识图谱推理领域讨论单一任务和复杂任务的分类体系,并介绍每类具体任务的特点及单一任务和复杂任务间的关联.由于单一任务与知识图谱的类型密切相关,因此,本节首先介绍 3 类典型的知识图谱类型.

(1) 静态知识图谱^[2]: 通常一个传统的静态知识图谱仅由事实三元组构成, 而每个事实三元组 (h, r, t) 包括头实体 h 和尾实体 t 及其之间的关系 r . 这里, 静态知识图谱可以被视为由实体代表的节点和关系代表的边构成的有向图, 并且边具有不同关系表示的类别标签. 在有向图数据结构中, 节点间的路径和节点的邻居子图是重要的拓扑信息, 分别代表节点间的多步间接语义关联和节点的上下文语义. 由于现有的大多数公开知识图谱均属于静态知识图谱, 所以已有的知识图谱推理研究工作大部分面向静态知识图谱.

(2) 动态知识图谱^[40]: 现实中面向金融、新闻、学术等领域, 产生的数据存在明显的动态特性, 基于这些领域数据构建的知识图谱属于动态知识图谱. 特别的, 动态知识图谱的“动态”特性体现在两个方面. 一方面, “动态”体现在知识会发生更新, 包括事实三元组的增、删、改等变化, 同时新增一些未见的实体和关系. 另一方面, “动态”体现在对事实三元组增加时间维度后, 知识带有时间属性, 这类知识图谱通常被称为由事件四元组构成的时序知识图谱 (或称为时态知识图谱). 考虑到人们对事件的普遍描述方式和已有动态知识图谱相关研究中对事件的常用表达, 一个事件四元组可以表示为 (主语, 谓词, 宾语, 时间), 其通常符号化为 $(s, p, o, time)$, 值得说明的是, 为了将本综述中各类知识图谱推理任务中的符号进行统一, 本文将事件四元组表示为 $(h, r, t, time)$, 其中 h 、 r 、 t 、 $time$ 分别对应主语、谓词、宾语和时间, 这里时间具体可以是时间戳或时间区间.

(3) 多模态知识图谱^[41,42]: 一般而言, 构建知识图谱的数据源本身包括文本、图像、语音等多模态数据, 然而由这些数据抽取得到的符号化实体和关系缺少了多模态数据的丰富特征. 因此, 近几年多模态知识图谱逐渐受到研究者的关注, 在构建知识图谱的过程中为实体和关系添加图像、文本等多模态数据, 以此来丰富对实体和关系的描述.

1.1 面向单一任务的知识图谱推理分类

知识图谱推理的核心目标是在给定已有知识的基础上, 预测出一个事实三元组或事件四元组中缺失的一个实体或关系, 也就是实体预测或关系预测. 针对不同类型的知识图谱及推理过程的条件, 本文将知识图谱推理分为面向单一任务和面向复杂任务的两大类方法进行介绍, 其中, 面向单一任务的知识图谱推理可以视为面向复杂任务的知识图谱推理的基础, 其分为单步知识图谱推理、多步知识图谱推理、时序知识图谱推理、多模态知识图谱推理、小样本知识图谱推理和归纳式知识图谱推理, 这 6 类知识图谱推理的示例如图 1 所示.




图 1 6 类面向单一任务的知识图谱推理示意图

具体的, 每类面向单一任务的知识图谱推理描述如下.

(1) 单步知识图谱推理^[29]: 单步知识图谱推理是最简单和基础的任务, 需要从已知静态知识图谱的事实三元组中挖掘实体间的语义关联, 并将这些语义关联迁移到未知的事实三元组中, 从而用于预测实体间潜在的关系. 在推理过程中, 需要根据一个事实三元组中的两个元素推理出另一个元素, 例如图 1 中给定头实体“Tim Cook”和单步关系“国籍”来推理尾实体. 由于单步知识图谱推理可以视为其他各类知识图谱推理任务的基础, 为了便于理解各类任务之间的关系, 首先给出单步知识图谱推理任务的形式化定义, 其可以形式化为给定一个查询问题如 $(h, r, ?)$, 其中 h 和 r 分别是头实体和关系, 推理出尾实体 t 以补全新的事实三元组 (h, r, t) . 当前完成这一任务的主要方法是基于知识表示学习的方法和基于符号规则的方法.

(2) 多步知识图谱推理^[43]: 与单步知识图谱推理不同之处在于, 多步知识图谱推理要求针对未知事实三元组推理的过程中给出实体间的多步路径, 这类多步路径信息代表了实体间的间接关联, 也就是根据知识图谱中实体间

的多步路径进行知识图谱推理,例如通过搜索知识图谱中头实体“Tim Cook”和尾实体之间表示“国籍”关系的多步路径来推理正确的尾实体,这些路径能够为推理结果提供一定的可解释性,该任务可以形式化为给定一个查询问题如 $(h, r, ?)$, 在推理事实三元组 (h, r, t) 的过程中不仅考虑实体间直接的关系,重点需要依赖于头实体 h 和尾实体 t 之间的路径 $path$.

(3) 时序知识图谱推理^[44]: 时序知识图谱推理适用于带有时间维度信息的动态知识图谱,这里特指时序知识图谱,例如 (Tim Cook, 居住, 德州, 1997 年) 仅在 1997 年这一时间约束下成立,其体现为事件的时效性,进而推理在 1998 年主语“Tim Cook”和谓词“居住”对应的宾语,除了考虑事件的时效性,还需要捕捉发生在不同时间的事件四元组之间的时序特性. 时序知识图谱推理任务可以形式化为给定查询问题 $(h, r, ?, time)$, 在考虑主语、谓词、宾语之间语义关联的基础上,结合时间维度信息推理出新的事件 $(h, r, t, time)$.

(4) 多模态知识图谱推理^[42]: 多模态知识图谱推理需要利用文本、图像和视频等信息对实体和关系进行表示,如图 1 中展示了“加州”对应的图像数据及“苹果”对应的文本数据,其可以作为对实体的补充信息以此来增强实体和关系的表示能力. 这类方法的核心目标是有效融合多模态数据特征和实体与关系自身的拓扑结构特征,通常需要借助知识表示学习的框架. 该任务需要给定查询问题如 $(h, r, ?)$, 同时充分利用实体和关系的多模态数据,推理出新的事实三元组 (h, r, t) .

(5) 小样本知识图谱推理^[45]: 考虑到实际的知识图谱中存在长尾分布的实体和关系,同时动态知识图谱中新增的实体和关系所关联的知识非常稀疏. 对于查询集中的查询问题例如 $(h, r, ?)$, 支持集中关于实体 h 或关系 r 的已知事实三元组或事件四元组样本数量非常有限,例如图 1 中关系“上市于”仅关联少量三元组样本,因此属于典型的小样本知识图谱推理,其可以形式化为提供支持集中有限的 K 个样本 $\{(h_1, r, t_1), (h_2, r, t_2), \dots, (h_K, r, t_K)\}$, 推理出新的事实三元组 (h, r, t) . 小样本知识图谱推理任务的核心目标是从有限的已有知识中学习样本间的关联,将其迁移到长尾实体和关系中以支持推理.

(6) 归纳式知识图谱推理^[38]: 前面介绍的几类知识图谱推理任务主要依赖于已知的实体和关系,然而实际中尤其对于动态知识图谱,很多实体和关系在训练过程中从未见过,例如图 1 中的“实体 1”和“实体 2”等,其可以形式化为给定查询问题例如 $(h, r, ?)$, 且头实体 h 和未知的尾实体均是训练阶段未见的实体,需要推理出新的事实三元组 (h, r, t) . 因此该任务的核心目标是挖掘已知知识和未见实体或关系之间的语义关联,从已知实体和关系相关的事实三元组中归纳出未见实体和关系的表示,并推理新的事实三元组.

本文梳理和总结了 6 类面向单一任务的知识图谱推理的特点,包括知识图谱类型、查询问题和条件、推理结果的形式和针对每类知识图谱推理方法的核心目标,如表 1 所示.

表 1 6 类面向单一任务的知识图谱推理特点总结

类别	知识图谱类型	查询问题和条件	推理结果	方法核心目标
单步知识图谱推理	静态知识图谱	$(h, r, ?)$	(h, r, t)	挖掘实体间的直接语义关联
多步知识图谱推理	静态知识图谱	$(?, r, t)$ $(h, ?, t)$	(h, r, t) $(h, path, t)$	挖掘实体间的间接语义关联
时序知识图谱推理	动态知识图谱	$(h, r, ?, time)$ $(?, r, t, time)$ $(h, r, t, ?)$	$(h, r, t, time)$	挖掘实体间随时间变化的语义关联
多模态知识图谱推理	多模态知识图谱	$(h, r, ?)$ $(?, r, t)$ $(h, ?, t)$	(h, r, t)	融合多模态数据增强知识表示能力
小样本知识图谱推理	静态/动态知识图谱	支持集: $\{(h_1, r, t_1), (h_2, r, t_2), \dots, (h_K, r, t_K)\}$ 查询集: $\{(h, r, ?) / (?, r, t) / (h, ?, t)\}$	(h, r, t)	挖掘有限的已有知识间的语义关联
归纳式知识图谱推理	静态/动态知识图谱	$(h, r, ?)$ $(?, r, t)$ $(h, ?, t)$	h, t 是训练过程中未见的实体 (h, r, t)	挖掘已有知识与未见实体间的关联

1.2 面向复杂任务的知识图谱推理分类

为了便于理解本文内容,给出面向复杂任务与单一任务的知识图谱推理间的关联,如图 2 所示,复杂任务可以

视为两个单一任务间的耦合模式, 且每类单一任务至少与其他两类单一任务间存在联系构成复杂推理. 其中, 编号①—⑤分别表示任务之间的关联, 表示单一任务之间的逻辑关联或单一任务与复杂任务之间的扩展关系, 而根据两个复杂任务之间公共邻居表示的单一任务, 可以看出这两个面向复杂任务的知识图谱推理间具有的共有特性.




图2 面向单一任务与复杂任务的知识图谱推理间关联的示意图

可见当前研究重点关注 6 类复杂任务, 分别为时序多步知识图谱推理、小样本多步知识图谱推理、小样本时序知识图谱推理、小样本多模态知识图谱推理、多模态归纳式知识图谱推理和时序归纳式知识图谱推理.

具体的, 6 类面向复杂任务的知识图谱推理描述如下.

(1) 时序多步知识图谱推理^[46]: 时序多步知识图谱推理可以视为综合了时序知识图谱推理和多步知识图谱推理这两类单一任务的复杂推理任务, 其要求在时序知识图谱中针对给定的主语和谓词及时间, 通过搜索一条多步路径到达正确的宾语, 其中在每一步的动作选择时均需要考虑时序信息.

(2) 小样本多步知识图谱推理^[47]: 小样本多步知识图谱推理属于将小样本知识图谱推理和多步知识图谱推理这两类单一任务耦合的复杂任务, 需要针对普遍存在的长尾关系, 在样本稀缺的情况下保证模型具有多步路径搜索和推理的能力.

(3) 小样本时序知识图谱推理^[48]: 小样本时序知识图谱推理属于结合小样本知识图谱推理和时序知识图谱推理的复杂任务, 需要针对时序知识图谱中存在长尾关系 (谓词) 情况下进行推理, 也可以视为在小样本知识图谱推理任务基础上考虑时序信息的推理任务.

(4) 小样本多模态知识图谱推理^[49]: 针对长尾关系相关样本稀缺的限制, 小样本多模态知识图谱推理结合小样本知识图谱推理和时序知识图谱推理的特点, 利用一些多模态信息对表示长尾关系进行补充, 可以为实体和关系提供丰富的语义信息, 以弥补低资源场景下数据稀疏的限制.

(5) 多模态归纳式知识图谱推理^[50]: 多模态归纳式知识图谱推理可以视为在归纳式知识图谱推理的基础上, 结合多模态知识图谱推理任务中所用的实体和关系文本描述、图像等信息来表示未见实体和关系的复杂任务.

(6) 时序归纳式知识图谱推理^[51]: 时序归纳式知识图谱推理是在时序知识图谱推理基础上考虑归纳式知识图谱推理任务中存在未见实体的情况, 要求能够结合时序信息进行归纳式推理.

本文梳理了 6 类面向复杂任务的知识图谱推理的特点, 如后文表 2 所示.

1.3 已有综述论文总结

此外, 表 3 和表 4 梳理了 2022–2024 年知识图谱推理 (knowledge graph reasoning, KGR) 领域中最有代表性的中、英文综述论文, 并总结了这些综述论文的特点, 便于相关研究人员进行参考. 从表 3 和表 4 中可以看到, 2022–2024 年知识图谱推理领域的中文和英文综述工作中大多数仅针对某一类任务的知识图谱推理技术进行总结. 虽然这些综述论文对本文所讨论的 6 类面向单一任务的知识图谱推理均有涉及, 但是当前仍缺乏对不同任务类型的知识图谱推理方法的总结, 同时没有考虑面向复杂任务的知识图谱推理方法. 因此, 系统性总结和对比面向各类单一和复杂任务的知识图谱推理主要解决的问题、涉及的代表性方法及优缺点, 对于研究者了解该研究方向

并思考有价值的研究思路非常有意义.

表 2 6类面向复杂推理任务的知识图谱推理特点总结

类别	知识图谱类型	查询问题和条件			推理结果	与单一场景间关联
时序多步知识图谱推理	动态知识图谱	$(h,r,?,time)$			$(h,r,t,time)$ $(h,path,t)$	时序知识图谱推理上的多步推理
小样本多步知识图谱推理	静态/动态知识图谱	支持集: $\{(h_1,r,t_1),(h_2,r,t_2),\dots,(h_K,r,t_K)\}$ 查询集: $(h,r,?)$			(h,r,t) $(h,path,t)$	小样本知识图谱推理上的多步推理
小样本时序知识图谱推理	动态知识图谱	支持集: $\{(h_1,r,t_1,time_1),(h_2,r,t_2,time_2),\dots,(h_K,r,t_K,time_K)\}$ 查询集: $\{(h,r,?,time)/(?r,t,time)\}$			$(h,r,t,time)$	时序知识图谱推理上的小样本推理
小样本多模态知识图谱推理	多模态知识图谱	支持集: $\{(h_1,r,t_1),(h_2,r,t_2),\dots,(h_K,r,t_K)\}$ 查询集: $\{(h,r,?)/(?r,t)\}$			实体和关系的 多模态数据 (h,r,t)	多模态知识图谱推理上的小样本推理
多模态归纳式知识图谱推理	多模态知识图谱	$(h,r,?)$ $(?,r,t)$	实体和关系的 多模态数据	h,t 是训练图谱中 未见的实体	(h,r,t)	多模态知识图谱推理上的归纳式推理
时序归纳式知识图谱推理	动态知识图谱	$(h,r,?,time)$ $(?,r,t,time)$	h,t 是训练过程中 未见的实体		$(h,r,t,time)$	时序知识图谱推理上的归纳式推理

表 3 2022–2024 年知识图谱推理领域相关中文综述论文总结

论文题目	综述论文特点	推理任务	出版源	发表时间
基于强化学习的知识图谱推理研究综述 ^[52]	对采用强化学习技术的KGR方法进行了总结	多步知识图谱推理	计算机应用研究	2024年
时序知识图谱补全方法研究综述 ^[37]	从采用不同技术的角度将当前时序KGR方法总结为6类方法并进行了介绍	时序知识图谱推理	计算机工程与应用	
时序知识图谱表示与推理的研究进展 ^[44]	将时序KGR按照底层嵌入模块、时间信息处理模块、推理模块和特殊场景构成统一的框架		软件学报	
面向链接预测的知识图谱表示学习方法综述 ^[29]	分别介绍了二元关系、多元关系和超关系这三类特定场景下的KGR研究现状	单步知识图谱推理	软件学报	
知识图谱嵌入技术研究综述 ^[32]	对传统知识表示学习和时序知识表示学习技术进行了总结和讨论	单步/时序知识图谱推理		
基于表示学习的知识图谱推理研究综述 ^[53]	总结了结合文本、图像、路径、时序信息、逻辑规则、属性类别等多源信息的知识表示学习模型	单步知识图谱推理	计算机科学	
知识图谱嵌入模型中的损失函数研究综述 ^[32]	对知识表示学习中常用的6类损失函数的原型公式、物理含义和应用进行了深入总结和讨论			
时态知识图谱的推理研究综述 ^[36]	针对补全和预测两类任务总结了时序KGR方法	动态知识图谱推理	计算机学报	2023年
面向知识图谱补全的归纳学习研究综述 ^[38]	按照半归纳和全归纳两类场景,总结了归纳式KGR方法	归纳式知识图谱推理	计算机科学与探索	
图神经网络应用于知识图谱推理的研究综述 ^[26]	按照递归图神经网络、卷积图神经网络、图自编码网络和时空图神经网络的分类原则介绍了时序KGR方法	动态知识图谱推理		2022年
少样本知识图谱补全技术研究 ^[45]	按照基于度量学习、元学习、其他模型这三类技术的分类原则,小样本知识总结了小样本KGR的已有方法	知识图谱推理		
多模态知识图谱表示学习综述 ^[27]	总结了当前融合文本、图片、视频、音频等多模态信息的知识表示学习模型和相关数据集	多模态知识图谱推理	计算机应用	
知识图谱可解释推理研究综述 ^[43]	归纳了事前可解释和事后可解释KGR模型	单步/多步知识图谱推理	软件学报	2022年
知识图谱推理研究综述 ^[34]	按照多样本推理、少样本推理和零与单样本推理的分类原则,总结了当前的KGR方法	小样本知识图谱推理	计算机科学	
基于强化学习的知识图谱推理研究综述 ^[24]	包含基于强化学习的多步KGR方法的总结	多步知识图谱推理	计算机研究与发展	

表 4 2022–2024 年知识图谱推理领域相关英文综述论文总结

论文题目	综述论文特点	推理任务	出版源	发表时间
Knowledge graph embedding: A survey from the perspective of representation spaces ^[54]	按照代数、几何结构、分析结构的分类原则, 针对采用的不同表示空间全面总结知识表示学习现有模型	单步知识图谱推理	ACM Computing Surveys	2024年
A survey of knowledge graph reasoning on graph types: Static, dynamic, and multi-modal ^[39]	按照知识图谱的类型, 从静态、动态、多模态知识图谱的分类原则总结了KGR方法	静态/时序/多模态知识图谱推理	IEEE TPAMI	
Overview of knowledge reasoning for knowledge graph ^[55]	从单步推理、因果推理、时序推理和常识推理几个角度分别论述KGR模型	单步/时序知识图谱推理	Neurocomputing	
Survey of temporal knowledge graph completion methods ^[37]	分别从符号规则、知识表示学习、深度强化学习和语言模型的角度总结了当前时序KGR模型	时序知识图谱推理	Journal of Computer Engineering and Applications	
Temporal knowledge graph completion: A survey ^[40]	从如何融入时序信息的角度, 梳理了当前时序KGR领域已有研究	归纳式知识图谱推理	IJCAI	2023年
Generalizing to unseen elements: A survey on knowledge extrapolation for knowledge graphs ^[56]	针对未见实体和未见关系的两类情况, 总结了归纳式KGR已有方法			
Beyond transduction: A survey on inductive, few shot, and zero shot link prediction in knowledge graphs ^[57]	全面总结了归纳式知识图谱推理和小样本知识图谱最新研究	归纳式/小样本知识图谱推理	arXiv	
A survey on knowledge graph embedding ^[58]	简要介绍了基于翻译、张量分解和神经网络的3类知识图谱表示学习模型	单步知识图谱推理	IEEE DSC	2022年
A comprehensive overview of knowledge graph completion ^[59]	分别从仅考虑三元组、结合外部信息、时序、常识和超关系知识图谱的角度介绍了知识图谱推理研究情况	单步/时序知识图谱推理	Knowledge-based Systems	

1.4 知识图谱推理性能评价指标

知识图谱推理的核心目标是在一个未见事实三元组或事件四元组中缺少某个元素的情况下, 推理出正确的事实三元组或事件四元组. 为了评价每个方法的推理性能, 当前普遍采用基于信息检索的评价机制判断正确推理结果在所有候选中的排名, 其排名越高说明推理准确性越高. 以头实体预测 $(?, r, t)$ 的查询问题为例, 将知识图谱中每一个实体填充头实体位置构造候选三元组 (h, r, t) , 并根据每类方法定义的评价机制对候选三元组按照成立的可能性进行排名, 因而可以得到每个正确预测结果的排名, 尾实体预测和关系预测的评价方式与之类似^[60]. 本文采用知识图谱推理中的 3 个常用指标^[61].

(1) MR : 所有正确三元组排名的平均值, 计算公式为: $MR = (1/N) \cdot \sum_{i=1}^N rank_i$, 其中, $rank_i$ 表示第 i 个测试样本对应的正确三元组排名, N 为测试样本总数.

(2) MRR : 所有正确三元组排名倒数的平均值, 计算公式为: $MRR = (1/N) \cdot \sum_{i=1}^N (1/rank_i)$.

(3) $Hits@n$: 正确三元组排在前 n 的比例, 计算公式为: $Hits@n = (1/N) \cdot \sum_{i=1}^N \mathbb{I}(rank_i \leq n)$, 这里, $\mathbb{I}(rank_i \leq n)$ 表示如果 $rank_i \leq n$ 为真则函数值为 1, 通常 n 取值为 1、3 或 10.

特别的, MR 越低, MRR 越高, $Hits@n$ 越高表明方法的性能越好. 此外, MR 值对离群值非常敏感, 导致对整体推理结果的评价不够鲁棒, 而 MRR 恰好解决了这一问题, 因此 MRR 和 $Hits@n$ 是知识图谱推理各类任务更为通用的评价指标. 由于在正确预测结果排名之前的候选三元组可能同样是正确结果, 这种情况会影响推理结果的可靠性, 因此, 现有方法通过消除已经在知识图谱中存在的候选三元组来过滤推理结果, 保证评价结果的有效性.

下文将具体介绍面向每类单一任务和复杂任务的已有知识图谱推理方法, 并针对其他几类特殊的推理任务探讨知识图谱推理领域值得进一步深入研究的发展方向.

2 面向单一任务的知识图谱推理方法

为了便于理解后续面向复杂任务的方法, 本节简要介绍 6 类面向单一任务的知识图谱推理方法.

2.1 单步知识图谱推理

单步知识图谱推理任务需要从已知的事实三元组中学习实体间直接语义关联的能力, 进而在给定一个事实三元组中的两个元素时, 通过评估候选三元组成立的可能性推理出正确结果. 如图 3 所示, 在已见的知识图谱中, 实体“Tim Cook”和“美国”之间原本不存在任何关系, 需要推理其间的关系“国籍”. 现有的单步知识图谱推理技术主要分为基于知识表示学习和基于符号规则的两类方法, 基于知识表示学习的方法通过学习有向图结构的拓扑特征作为实体和关系的嵌入表示, 进而找出与实体“Tim Cook”和关系“国籍”的嵌入表示最能满足预设约束的尾实体作为推理结果. 而基于符号规则的方法首先根据知识图谱中三元组出现的频繁模式自动挖掘出符号规则, 再利用与规则匹配的查询问题和事实三元组将规则进行实例化, 例如知识图谱中已知的两个事实三元组 (Tim Cook, 出生于, 亚拉巴马) 和 (亚拉巴马, 位于国家, 美国) 与符号规则“国籍(x, y) $\Leftarrow$ 出生于(x, z) $\wedge$ 位于国家(z, y)”匹配, 进而将该规则实例化为“国籍(Tim Cook, 亚拉巴马) $\Leftarrow$ 出生于(Tim Cook, 亚拉巴马) $\wedge$ 位于国家(亚拉巴马, 美国)”, 进而得到推理结果 (Tim Cook, 国籍, 亚拉巴马). 基于知识表示学习和基于符号规则的方法分别代表连接主义和符号主义的人工智能两大流派.




图3 单步知识图谱推理方法示意图

(1) 基于知识表示学习的方法: TransE^[62]是知识表示学习领域的一个经典模型, 其灵感源自 Word2Vec^[63]的词嵌入方法. 它通过向量空间中的平移操作来建模实体间的关系, 对于一个事实三元组 (h, r, t), TransE 旨在使 $h + r \approx t$ 成立, 其中 h 、 r 、 t 分别为头实体、关系和尾实体的向量表示. 尽管 TransE 在许多场景中表现出色, 但在处理复杂关系时存在明显不足. 例如 TransE 难以区分同一头实体和关系对应的不同尾实体, 且其基于平移的操作无法有效建模对称关系. 为此, 研究者提出了多种扩展模型, TransH 模型^[64]为每种关系引入特定的超平面, 将实体投影到这些超平面上, 以取得关系特定的嵌入表示. TransR 模型^[65]使用独立的投影矩阵分别对实体和关系进行投影, 增强模型的表达能力. 进一步, TransD 模型^[66]针对每个关系的头实体和尾实体使用不同的投影矩阵, 提高模型的灵活性. RotatE 模型^[67]利用复数向量空间中的 Hadamard 积将关系建模为旋转操作, 能够有效捕捉对称关系. QuatE 模型^[68]进一步扩展旋转操作到四元数空间, 提供更丰富的关系表示. PairRE 模型^[69]为每个关系学习成对的嵌入表示, 并分别对头实体和尾实体进行投影. TransA 模型^[70]将关系建模为对称非负矩阵, 并在打分函数中采用自适应马氏距离. 此外, DistMult 模型^[71]基于张量分解的思想建模对称关系, HolE 模型^[72]通过霍普金斯乘积学习实体之间的全局语义信息. ComplEx 模型^[73]首次将张量分解扩展到复数空间以建模反对称关系. ConvE^[74]使用卷积神经网络建立实体和关系的特征交互以统一建模实体和关系. R-GCN 模型^[75]在图卷积神经网络 (graph convolutional network, GCN) 的基础上针对知识图谱中多关系的特性进行了扩展, 能够综合建模关系和学习拓扑结构特征的能力. SimKGC^[76]定义正、负样本对和相似性优化目标, 进而采用对比学习策略来提高知识图谱推理的能力. KG-BERT 模型^[77]基于预训练语言模型 BERT 直接在三元组文本上进行分类, 利用丰富的语义信息进行知识图谱推理.

(2) 基于规则学习的方法: 为了保留符号化知识图谱原本的可解释性, 同时考虑到人类的推理过程主要依赖于经验规则, 单步知识图谱推理的另一个主要研究方向是采用符号主义流派的规则学习. 面向知识图谱的规则学习

方法按照搜索或构建规则的方式, 可以分为基于归纳逻辑编程的方法和基于神经网络的两类方法. 基于归纳逻辑编程的方法包括 AMIE+[78]、ScaLeKB[79]、RDF2Rules[80]、SWARM[81]、RuDiK[82]和 RuLES[83]等. AMIE+使用优化的查询编写技术和改进的规则质量评估算法来实现更高效的规则挖掘, 而 ScaLeKB 通过部署自动清理策略和数据分区技术进一步提高了规则学习的效率和可扩展性. 当前的规则学习方法大多数诉诸于对候选规则的穷举搜索, 并借助一些启发式的规则剪枝策略, 然而规则学习的效率和得到的规则质量仍然有限, 为此, Evoda[84]采用了一种新的遗传逻辑编程算法, 将常见的 Horn 规则扩展到更一般化的 Datalog 规则[85], 并定义基于关系表示学习的打分机制提高效率. 基于神经网络的方法 NeuralLP[86]和 DRUM[87]都用独热编码的实体表示和用矩阵编码的关系表示, 采用端到端的方式学习可能的规则模式并评估每个规则的置信度. RLvLR[88]结合知识表示学习得到的实体和关系嵌入表示与一类新的打分函数, 对规则进行剪枝以提高规则学习的效率. RNNLogic[89]设计了一个基于循环神经网络 (recurrent neural network, RNN) 的规则生成器来生成规则, 并在此基础上通过一个推理预测器推理答案. 基于 Transformer 的规则学习模型 Ruleformer[90]将规则挖掘视为序列到序列的生成过程, 用改进的注意力机制从头实体的子图中编码上下文信息, 进而利用子图信息解码生成规则序列中每个关系的概率分布, 得到规则的同时计算推理结果的打分.

基于知识表示学习的单步知识图谱推理方法具有良好的计算效率和泛化性, 而基于符号规则的方法具有显著的可解释性, 更好地融合这两类方法的特性实现优势互补, 达到兼顾准确性、推理效率、泛化性和可解释性的知识图谱推理效果是该领域值得进一步深入探索的重要研究方向.

2.2 多步知识图谱推理

当前多步知识图谱推理主要采用基于随机游走、基于强化学习和基于大模型的 3 类方法, 如图 4 所示.




图 4 多步知识图谱推理方法示意图

(1) 基于随机游走的方法: 随机游走技术广泛应用于图数据, 其是从起始节点出发, 每次随机采样下一个到达的节点, 以此形成一条路径. Lao 等人[91]提出的路径排序算法 PRA 是最早通过随机游走技术的多步知识图谱推理方法, 该方法旨在找到两个实体间的路径, 将路径中所有关系组成的序列视为实体间的特征, 将其输入分类器预测路径连接的两个实体间的关系. 面向多步知识图谱推理任务, 改进路径生成的方法主要针对 PRA 算法的路径搜索过程进行优化, 通过挖掘更有效的路径信息来表示实体间的语义关联. Lao 等人[92]对自己提出的 PRA 进行改进并提出了一种加权随机游走的关系推理算法, 能够调整随机游走生成的不同路径的权重, 以利用最有效的路径推理目标关系. Gardner 等人[93]利用从大型语料库中挖掘出的句法特征对实体间添加隐式句法标签, 达到特征增强的效果, 辅助 PRA 算法生成更丰富的关系序列作为路径, 以提高多步推理任务的性能. CPRA[94]使用聚类方法自动发现高度相关的关系, 然后采用多任务学习策略利用路径间的交互作用来提升关系预测的效果. C-PR 算法[95]引入一种选择性路径探索策略通过双向随机游走枚举上下文相关的路径. A*Net 模型[96]将启发式搜索 A* 算法引入路径搜索过程中, 能够每次选择最重要的实体和关系扩展路径. PathCon 模型[97]结合实体对相关的邻接关系构成关系上下文知识, 共同预测实体间的关系. 由于随机游走中每一步的选择仅依赖当前状态而与之之前的状态无关, 导致搜索空间过大, 造成路径搜索并提取其特征的效率较低, 且无法得到和查询问题语义最接近的路径.

(2) 基于强化学习的方法: 由于路径搜索过程可以形式化为马尔可夫决策过程 (Markov decision process, MDP), 因此可以利用深度强化学习来训练一个智能体使其具有路径搜索的能力, 在路径搜索的过程中智能体从头实体出发并根据当前到达的状态采用策略网络得到动作空间的概率分布, 以判断下一步动作并通过设计奖励函数更新策略网络, 以更加智能的方式找到正确的尾实体[52]. DeepPath[98]首先将强化学习技术应用在多步知识图谱推

理任务, 其将知识图谱中的关系作为动作空间, 并根据是否到达正确尾实体来设计主要的奖励函数用于指导路径搜索的过程, 然而 DeepPath 的状态中包含了尾实体, 因此只能用于给定头尾实体和关系的三元组分类任务. 为此, MINERVA^[99]设计了适用于给定头实体和关系作为查询问题的强化学习策略来进行路径搜索, 实现了实体推理的功能, 其中采用长短期记忆 (long short-term memory, LSTM) 网络对历史状态和动作序列进行编码, 并输入由全连接网络构建的策略网络中得到动作空间的概率分布. MultiHopKG 模型^[100]通过预训练的知识表示学习模型例如 ComplEx 和 ConvE 等对中间状态进行打分提供软奖励来有效减轻稀疏奖励的影响, 同时设计动作随机丢弃 (action dropout) 机制一定程度上避免陷入局部最优. 基于强化学习的多步推理可以有效避免 PRA 路径搜索空间过大的问题, 但是如果给定的查询实体和正确的答案实体之间不存在有限长度的路径, 基于强化学习的多步推理方法将无法得到推理结果, 导致鲁棒性受限.

(3) 基于大模型的方法: 为了解决基于强化学习的多步推理方法存在冷启动和鲁棒性不足的问题, 近年来, 随着大模型 (LLM) 技术的兴起, 一些研究充分利用大模型的多步推理能力, 将 LLM 视为智能体在知识图谱上进行路径搜索, 提升多步推理的性能, 同时借助 LLM 自身蕴含的隐式知识解决冷启动和知识图谱不存在答案的问题^[101]. StructGPT^[102]提出“迭代式调用-线性化-生成求解”的框架, 首先调用 LLM 接口从知识图谱中提取和查询问题相关的路径作为证据, 然后将其线性化为文本提示输入 LLM, 进而选择有用的路径在下一步迭代或者直接得出推理结果. KSL^[103]设计了一个简单而有效的提示, 使得 LLM 能够在零样本的情况下具备搜索知识的能力, 同时提供完整的检索路径, 以增强推理过程的可解释性. KD-CoT^[104]将基于大模型的多步推理过程形式化为一个结构化多轮问答模式, 通过检索得到精确答案以生成可靠的推理路径. ToG 模型^[105]通过在知识图谱上采用 LLM 执行集束搜索以发现最有价值的路径, 并返回最可能的推理结果. Nguyen 等人^[106]提出了一种新颖的判别式和生成式思维链 (chain of thought, CoT) 评估范式, 不仅判断推理结果, 还评估由提示生成的中间推理步骤, 有效提高推理结果的可信度. 由于 LLM 和特定的知识图谱间语义不对齐, 直接使用 LLM 进行路径搜索的性能不足, 因此另一类基于大模型的多步推理方法需要结合指令集对 LLM 进行微调, KG-agent^[107]采用迭代机制自主选择工具以进行知识图谱推理, 并采用一个指令数据集微调基础大模型. AgentTuning^[108]构建了一个轻量级的指令微调数据集, 并将其与来自一般领域的开源指令相结合进行混合指令微调, 提升大模型多步推理的性能. 基于大模型的多步知识图谱推理方法能够充分利用大模型自身的隐式知识, 搜索与查询问题语义最相关的路径, 然而这种方法当前成本较高.

基于强化学习的多步知识图谱推理方法可以通过反馈机制让智能体在知识图谱的环境中自主决策每一步的动作, 但是鲁棒性不足; 基于大模型的方法可以充分利用大模型自身的逻辑推理能力和隐含的大量知识进行动作选择, 但是通常和知识图谱间语义难以对齐. 因此, 结合强化学习方法在知识图谱环境中交互的策略和大模型的推理能力是多步知识图谱推理领域值得探索的研究方向.

2.3 时序知识图谱推理

由于时序知识图谱相比静态知识图谱的特别之处在于增加了具体的时间维度信息, 因此, 时序知识图谱推理的核心目标是有效建模时间信息, 以表达事件的时效性和事件间的时序特性. 现有方法对时间有两种建模方式: 对已知时间的事件预测采用基于时间嵌入表示的方法, 对未来时间的事件预测采用基于事件演化的方法.

(1) 基于时间嵌入表示的方法: 基于时间嵌入表示的时序知识图谱推理方法通过学习向量、张量或超平面等形式的时间嵌入表示, 并联合实体和谓词表示计算事件四元组的打分, 预测事件发生的可能性. TA-TransE^[109]将时间视为属性值, 将带有时间属性的谓词序列利用 LSTM 进行编码, 并根据 TransE 中的打分函数评估一个四元组的分值. 然而, 这种方法无法对时间学习单独的嵌入表示, 难以保证时间表示的准确性. TTransE 模型^[110]将事件四元组 $(h, r, t, time)$ 之间的交互视为从主语 h 经过谓词 r 和时间 $time$ 共同翻译到达宾语 t , 基于这个思想设计针对四元组的打分函数为 $\|h + r + time - t\|$. 然而, TTransE 无法建模同一个事件主体 (h, r, t) 在不同时间发生的两个事件, 限制了对事件的表示能力. 为了解决这一问题, 受 TransH 中提出的关系超平面解决复杂关系的推理的启发, HyTE^[111]将实体和谓词投影到特定于时间的超平面中, 保证同一事件主体在不同的时间具有不同的表示, 提高了对时间的表示能力. TeRo^[112]进一步将 HyTE 中关于时间超平面的投影操作改为 RotatE 中的旋转操作, 以建立在

特定时间中实体和谓词之间的关联. 此外, TComplex^[113]是对基于三阶张量分解的 ComplEx 改进为引入时间尺度信息的四阶张量分解. 笔者团队提出的 LCGE 模型^[114]利用时序规则学习算法从时序知识图谱中自动挖掘时序规则, 并以此建立时序规则引导的谓词嵌入正则化机制, 能够同时建模事件的时效性和事件间的时序特性. 同时, LCGE 通过学习时序知识图谱中隐含的静态常识知识, 从动态事件和静态常识两个角度联合进行事件推理, 如图 5 所示.




图 5 时序知识图谱推理 LCGE 模型示意图

(2) 基于事件演化的方法: 另一种对时间的建模方式是将不同时间的子图按照时间顺序组成序列, 用图神经网络 (graph neural network, GNN) 编码每个子图, 并利用 RNN 等对事件序列进行编码, 学习事件间隐式的时序性并预测未来发生的事件. Know-evolve^[115]最早提出了一类深度演化知识网络, 其可以从历史事件的演化过程中建立事件间的时序性, 以此预测未来发生的事件. 然而, Know-evolve 对每个时间同时发生的事件缺乏有效建模. RE-NET^[116]将与查询主语相关的历史事件按照相同时间聚合为一个子图的方式构建子图序列, 并使用基于图卷积神经网络 (GCN) 的子图聚合器对每个子图分别进行编码, 再利用门控循环单元 (gate recurrent unit, GRU) 编码历史子图序列, 进一步基于分类器预测未来时间发生的事件. 考虑到相邻时间发生的事件可能完全不同, 导致无法形成子图序列的问题, EvolveGCN 模型^[117]认为每个时间对应的 GCN 参数不同, 且每个时间 GCN 的权重与上一个时间 GCN 权重有关, 因此可以用 GCN 权重序列代替实体相关的子图序列来解决无法构建子图序列的问题. 为了建模随时间重复发生的一些事件, 依照自然语言生成任务中的复制策略, CyGNet^[118]提出了时间感知的复制机制, 能够识别具有重复性的事件, 并据此参考过去已知的事件来预测未来的事件. 然而, 并不是所有的历史信息都对当前时间的推理有效, 以上几种基于演化的时序推理方法忽略了对历史证据的选择, 导致引入了一定的噪声历史数据, 因此, CluSTeR^[119]提出了一个基于证据搜索和时序推理的两阶段时序推理方法, 将证据搜索形式化为一个马尔可夫决策过程以选择对当前时间的推理最有帮助的路径信息. 可以看到, 上述基于演化的时序推理方法都仅利用了事件之间的时序性而没有对具体时间进行表示, 当查询问题只能关联较少已发生的事件时, 这类方法难以利用事件间的时序关联, 导致推理性能较弱.

(3) 基于大模型的方法: 由于大模型技术的快速发展和应用, 最近两年, 涌现了一批基于大模型的时序知识图谱推理方法. 基于大模型的方法均是将事件四元组及其相关信息作为大模型的输入, 将知识图谱推理任务转换为掩码预测任务或上下文学习任务, 使得大模型具有对事件的推理能力. PPT 模型^[120]首次将时序知识图谱推理任务转换为面向语言模型的掩码预测任务, 将一系列和查询问题中主语相关的事件四元组转换为大模型的输入, 特别的是, PPT 模型将时间戳之间的间隔转换为不同的提示, 例如时间窗口内最早的时间信息用“开始”表达, 并将之后的时间戳间的间隔用“第 2 天”“3 周后”“1 个月后”等语言形式进行表示, 进而由大模型给出被掩码部分的实体作为推理结果, 该模型提高了大模型理解和预测时序知识的能力. ECOLA 模型^[121]与 PPT 模型类似, 但是不同之处

在于, ECOLA 同时将事件四元组及其相关的描述文本作为大模型的输入序列, 并从词语、实体和谓词这 3 个方面设计了掩码预测子任务, 能够更好地编码事件并进行推理. SToKE 模型^[122]利用大模型来学习联合知识图谱拓扑结构和时序上下文的知识嵌入表示, 该模型是在针对静态知识图谱的 K-BERT 模型^[123]基础上的改进, SToKE 的特别之处在于为每个查询问题构建了一个事件演化树, 其记录了与查询问题相关的结构化事件序列, 事件序列按照时序特性组织了每个时间与查询问题中主语相关的子图, 因此蕴含了每个时间戳上的拓扑结构信息和时序上下文信息, 并以掩码预测任务对大模型进行微调. Lee 等人^[124]提出以上下文学习的微调方式使大模型具有时序知识图谱推理能力, 主要根据查询问题从时序知识图谱中检索最近一段时间内的相关事件作为上下文, 并将这些上下文转换为表示事件预测任务的词汇提示, 进而将大模型的输出解码为候选实体的概率分布, 得到推理结果. 3 类时序知识图谱推理方法对比总结如表 5 所示.

表 5 时序知识图谱推理方法对比总结

方法类型	特点	优点	缺点
时间嵌入表示	学习时间的嵌入表示, 用其约束四元组打分, 预测已知时间的事件	能够显式表示时间, 有利于表示事件的时效性	无法处理未知时间发生的事件
基于事件演化	编码不同时间发生的事件间的关联, 从而预测未来发生的事件	能够预测未知时间的事件, 建模事件间时序性能力强	难以表示事件的时效性
基于大模型	转换为适用于大模型的掩码预测任务或上下文学习任务, 直接由大模型得到推理结果	充分利用大模型的逻辑推理能力和上下文语义信息	时序建模能力有限, 且成本较高

当前基于时间嵌入表示的时序知识图谱推理方法主要能够表示事件的时效性, 而基于事件演化和基于大模型的方法均主要建模事件间的时序性, 且这些方法均缺乏一定的可解释性. 因此, 研究能够同时表示事件的时效性和事件之间的时序性并改善推理结果的可解释性的时序知识图谱推理方法非常意义.

2.4 多模态知识图谱推理

大多数知识图谱推理任务仅考虑了知识图谱中的三元组事实, 而忽略了很多和实体有关的辅助信息. 为了进一步提高知识图谱推理的性能, 一些方法结合了多模态知识图谱中实体和关系的文本描述、实体的图像等多模态数据作为辅助信息来表达实体和关系. 在 2022 年全国知识图谱与语义计算大会中, 专门提出了“多模态商品知识图谱链接预测”评测任务, 需要结合电商知识图谱中的文本和图像等多模态信息进行知识图谱推理. 当前, 多模态知识图谱推理主要采用两类方法: 基于嵌入表示的方法和基于预训练模型的方法. 下面对这两类方法具体开展介绍.

(1) 基于嵌入表示的方法: 大多数多模态知识图谱推理模型不使用预训练的 Transformer 框架生成和融合特征, 而是通过扩展传统的知识表示学习技术, 设计不同的机制来编码额外的模态信息. 最常见的模态融合的方法关注于多模态信息和结构信息的有效融合, 早期的模型如 IKRL^[125]将实体对应的图像编码到实体表示空间, 按照 TransE 模型建立实体和关系间的关联并学习实体表示和关系表示. MKBE 模型^[126]将多模态信息视为额外的三元组, 设计组合编码组件来联合学习实体及其多模态嵌入表示. 针对实体对应的多个图像中存在不相关噪声图像的问题, RSME^[127]设计了一个特殊的遗忘门机制, 有效地选择了有价值的图像信息. OTKGE 模型^[128]使用最优传输思想来融合多模态知识, 而 HRGAT 模型^[129]通过构建超节点关系图学习多模态实体表示. 特别的, 少量模型如 MoSE^[130]为结构、文本、视觉数据单独训练了 3 个推理模型, 并利用模态集成的策略进行联合预测. 此外, 部分模型采用了对比学习或者对抗学习的策略. MMRNS^[131]模型设计了一种关系增强的负采样策略, 可以自适应选择负样本. 考虑到多模态信息的不均衡分布问题导致多模态融合的效果受限, AdaMF-MAT 模型^[132]使用视觉和文本编码器分别学习不同模态的特征, 并设计一个自适应多模态融合模块得到融合视觉嵌入、文本嵌入和知识图谱嵌入的联合嵌入表示. 此外, 采用对抗训练策略, 通过视觉和文本生成器得到生成的多模态嵌入以构造对抗样本, 进而通过判别器进行知识图谱推理和对抗训练的优化, 提高知识图谱推理模型的训练效果, 如图 6 所示.

(2) 基于预训练模型的方法: 得益于 Transformer 易扩展到多模态场景的优势, 许多方法将多模态知识图谱三元组转化为令牌序列, 送到 BERT 和 VisualBERT 等预训练的 Transformer 模型中. VBKGC^[133]利用预训练的 Transformer 对多模态特征进行编码, 并设计多模态打分函数进行优化. 更进一步, MKGformer^[134]改进了 Transformer

内部结构以实现混合粒度的多模态融合, 并将不同下游任务的学习范式统一在掩码语言模型 (masked language model, MLM) 框架中. 近年来随着大模型的流行, 不少研究专注于将多模态信息和知识图谱结构信息整合到大模型中. GLTW^[135]模型引入图 Transformer 编码具有局部和全局结构信息的子图, 并与 LLM 集成以增强推理性能. SSQR 模型^[136]通过图重建任务构建类似于自然语言词汇表的离散码本序列, 以实现与 LLM 的无缝集成. 然而, 基于预训练模型的多模态知识图谱推理研究仍处于早期阶段. 两类多模态知识图谱推理方法对比总结如表 6 所示.




图 6 多模态知识图谱推理 AdaMF-MAT 模型示意图

表 6 多模态知识图谱推理方法对比总结

方法类型	特点	优点	缺点
基于嵌入表	大多数是单步知识图谱推理任务的扩展, 侧重于通过嵌入空间中的特征融合来学习多模态信息	学习过程简单, 方法更为多样	对多模态信息的表示能力有限
基于预训练模型的方法	利用预训练模型实现对多模态信息的理解, 倾向于研究统一的学习框架或者易集成的结构	更有效挖掘多模态信息对表示实体和关系的能力	训练过程较繁琐, 且成本较高, 难以处理和学习复杂的知识图谱结构信息

总体而言, 融合多模态特征的方法相比仅基于知识图谱结构特征的方法具有更好的性能. 但是, 对于某一种模态数据存在噪声或编码性能不足的情况会显著影响这类方法的整体性能, 导致鲁棒性不足. 因此, 更丰富的多模态数据探索和去噪方法, 是多模态知识图谱推理领域值得探索的方向.

2.5 小样本知识图谱推理

实际的知识图谱通常存在长尾分布的实体或关系, 如图 7(a) 所示为最早提出小样本知识图谱推理任务的文献^[137]中给出的, Wikidata 数据集中关系的长尾分布情况统计图, 可以看到大约有 10% 的关系只有不超过 10 个三元组事实. 特别的, 现有小样本知识图谱推理研究一般针对关系具有少量三元组样本的情况, 对于未见实体的情况主要在后续归纳式知识图谱推理中介绍. 小样本知识图谱推理遵循在传统图像分类和文本分类等领域中对小样本学习 N -way K -shot 的设定, N -way 代表推理过程中的关系数量为 N , K -shot 表示推理过程中每个关系的支持集包含三元组数量为 K . 在此基础上需要针对查询集中的查询三元组进行推理, 这里一般设置 $K = \{1, 3, 5\}$; 同时, 训练过程也采用与推理过程相同的设定, 但是训练集、验证集和测试集不存在交集. 这一设定表示对于每个长尾关系 r , 在给定少量支持集中的参考三元组 $S_r = \{(h_i, r, t_i) | (h_i, r, t_i) \in T_r\}_{i=1}^K$ 的前提下, 需要针对关系 r 的所有查询集中的查询三元组 $Q_r = \{(h_i, r, t_i) | (h_i, r, t_i) \in T_r\}_{i=1}^{T_r-K}$ 进行推理, 表达了小样本知识图谱推理的含义, 图 7(b) 给出 3-shot 设置下的示例. 当前, 小样本知识图谱推理主要采用两类方法: 基于度量学习的方法和基于元学习的方法. 下面对这两类方法具体开展介绍.

(1) 基于度量学习的方法: Xiong 等人^[137]最早定义了小样本知识图谱推理任务, 并提出了基于度量学习的 GMatching 模型, 该模型主要考虑小样本知识图谱推理任务中极端的 1-shot 模式, 由于仅通过支持集中的一个三元组难以有效表示长尾关系, 为此, 使用实体的邻居子图来编码长尾关系的每个候选头、尾实体对, 并训练一个匹配器将支持集中参考三元组的实体对编码表示与查询集中的实体对编码表示计算相似度, 以预测这两个实体对是否由相同的连接. FSRL^[138]在 GMatching 的基础上, 在编码实体对时采用关系感知的邻居编码器以关注实体

邻居的不同影响, 并使用一个循环自编码器聚合支持集中的多个参考实体对. 进一步, FAAN^[139]在 FSRL 的基础上, 使用 Transformer 编码实体对, 并考虑到支持集中不同参考三元组对于表达同一个关系的语义具有不同的权重, 引入自适应匹配模块以有选择性地将一个查询集中的实体对与多个支持集中的实体对匹配. TransAM 模型^[140]通过序列化支持集中的实体对和查询集中的实体对, 应用具有局部-全局注意力的 Transformer 来捕捉三元组内部和三元组之间的实体交互, 并进行支持集和查询集的匹配过程. FRL-KGC^[141]结合 LSTM 和 Transformer 对支持集和查询集中的三元组分别进行编码, 以增强其学习实体和关系的上下文语义的能力. 大部分基于度量学习的该领域研究都只使用实体进行匹配, 缺少了针对关系语义的匹配, 为此, HMNet 模型^[142]提出了一种混合匹配网络, 通过实体感知匹配网络和关系感知匹配网络联合评估支持集和查询集中实体层面和关系层面的匹配得分. MetaP 模型^[143]设计了基于卷积神经网络 (convolutional neural network, CNN) 的模式学习器, 能够从有限的参考三元组中学习关系特定模式的表示, 并计算参考三元组正样本和负样本与查询三元组间关系模式表示的相似度, 预测查询三元组成立的可能性. 基于度量学习的小样本知识图谱推理方法均不直接编码关系, 而是编码长尾关系的头、尾实体对, 主要关注对于实体对邻居子图的编码表示, 进而对于支持集和查询集的实体对表示进行匹配, 评估是否具有相同关系, 如图 8(a) 所示. 然而, 这类方法仅利用实体对表示间的匹配, 无法根据当前长尾关系对应的三元组事实学习关系的表示, 限制了面向长尾关系的小样本知识图谱推理性能.




图 7 小样本知识图谱推理任务特性介绍




图 8 小样本知识图谱推理经典模型 GMatching 和 MetaR 示意图

(2) 基于元学习的方法: 为了从少量三元组样本中有效学习长尾关系的嵌入表示, 一些研究借助模型无关的元学习 (model-agnostic meta-learning, MAML) 机制^[144], 将长尾关系相关的已有知识迁移到关系元表示中. 浙江大学

Chen 等人^[145]最早提出了基于元学习的模型 MetaR, 从支持集中编码实体对并得到关系元表示, 进而利用知识表示学习模型如 TransE 和梯度下降策略快速优化关系元表示, 在此基础上使用关系元表示对查询集进行优化, 进而在推理过程中可以通过计算查询集中候选三元组的打分以评估其成立的可能性, 如图 8(b) 所示. MetaR 模型在被提出时显示出出众的性能, 然而, 该模型在编码实体对得到关系元表示和考虑支持集中不同三元组对优化关系元表示的重要性等方面仍存在改进空间. 为了充分利用实体的邻居信息表示长尾关系, 同时抑制噪声邻居信息对表示关系的影响, GANA 模型^[146]设计了一个门控注意力邻居聚合器编码实体的邻居信息同时减少噪声邻居的权重, 以此得到关系元表示, 同时利用带有注意力的双向长短期记忆网络 (bidirectional long short-term memory network, BiLSTM) 融合支持集中的不同三元组以表示关系元, 特别的, 该方法将 MAML 机制引入 TransH 模型构造了 MTransH 模块以计算三元组的打分, 提升了考虑复杂关系的小样本知识图谱推理性能. Meta-iKG 模型^[147]将小样本知识图谱推理任务转换为子图建模问题, 针对长尾关系的子图采用 GNN 进行编码, 其中 GNN 的参数采用 MAML 机制从不同长尾关系的三元组中学习初始最优参数值, 进而针对当前长尾关系对应的支持集中三元组对初始最优参数值进行快速更新, 以适应学习当前关系的嵌入表示. SMetaR 模型^[148]对 GANA 模型进行了简化, 仅针对支持集中的头、尾实体对采用线性映射学习关系元表示, 能够提高模型推理效率. HiRe 模型^[149]从 3 个粒度的层次来学习关系元表示, 借助对比学习策略得到关系上下文级别的表示, 同时利用 Transformer 编码支持集得到三元组级别的表示, 以更全面地表示长尾关系. MTRN 模型^[150]设计自注意力编码器来建模长尾关系的每个头实体和尾实体的交互, 以区分不同实体对的编码表示对学习关系元表示的重要性. 基于元学习的小样本知识图谱推理方法主要基于 MAML 机制从少量样本中学习长尾关系的表示, 但是这类方法需要经历参数更新过程影响推理效率, 仅利用和长尾关系直接相关的少量事实三元组, 对表示长尾关系和执行推理的性能仍然有限.

两类小样本知识图谱推理方法对比总结如表 7 所示.

表 7 小样本知识图谱推理方法对比总结

方法类型	特点	优点	缺点
基于度量学习	学习三元组中实体对的表示, 通过实体对表示的匹配机制判断查询集与支持集是否具有相同关系	实体对表示易于学习	无法根据当前长尾关系对应的三元组事实学习关系的表示
基于元学习	借助 MAML 机制将长尾关系相关的已有知识迁移到关系元表示中	能够得到长尾关系的表示	需要经历参数更新过程, 影响推理效率

当前小样本知识图谱推理方法主要依靠度量学习和元学习的思想, 然而已有的方法在多个小样本知识图谱推理数据集上的实验结果表明这些方法的性能仍非常有限, 例如在 5-shot 的设置下, HiRe 模型在 NELL-One 和 Wiki-One 数据集上针对 Hits@1 评价指标的结果分别为 0.207 和 0.319. 因此, 该领域仍有较大探索空间, 例如结合知识图谱的本体层中对于长尾关系的高层语义知识, 或者结合大模型和上下文学习机制提高小样本知识图谱推理的性能是值得深入研究的方向.

2.6 归纳式知识图谱推理

当前, 一类非常有挑战性的推理任务为归纳式知识图谱推理, 其主要考验模型针对未见实体和关系的推理能力^[151]. 为了促进该方向的研究, 2023 年全国知识图谱与语义计算大会中专门提出了“归纳式知识图谱关系推理”的评测任务. 小样本知识图谱推理主要关注在训练过程中模型如何利用有限的训练样本, 归纳式知识图谱推理关注的是模型在测试过程中归纳推理的泛化能力. 如图 9 所示, 归纳式知识图谱推理的核心思想是归纳出从源知识图谱到目标知识图谱之间可迁移的结构模式, 例如挖掘源知识图谱与目标知识图谱中具有相似邻居结构的实体, 由此将源知识图谱中的结构模式迁移到目标知识图谱中, 进而推理出未见实体间的潜在关系.

(1) 基于 GNN 的方法: 基于 GNN 的知识表示学习模型可以编码实体的邻居信息来表示该实体, 基于该思想同样可以编码未见实体的邻居以得到该实体的嵌入表示, 赋予模型归纳能力的方式, 进而实现归纳式知识图谱推理, 例如早期的 MEAN 模型^[152]使用 GNN 编码实体的邻居信息, 并基于 TransE 模型进行解码得到推理结果. 然而, MEAN 仅通过简单的池化函数聚合邻居, 缺少对邻居信息的充分挖掘和利用. 为此, 大量研究针对提取和利用

邻居上下文信息展开. NBFNet 模型^[153]是利用子图和路径信息赋予模型归纳学习能力的代表性方法, 其结合了基于路径和基于 GNN 的知识表示学习模型, 并定义了 3 个运算符来增强 GNN 的整体表达能力和归纳能力. GraIL 模型^[154]可以根据两个实体周围的子图结构来预测这两个实体之间的关系, 学习与实体无关的关系语义. 特别的, 后续很多方法对 NBFNet 和 GraIL 模型进行了扩展. PathCon 模型^[97]、SNRI 模型^[155]、REPORT 模型^[156]、LogCo 模型^[157]和 RPC-IR 模型^[158]对 NBFNet 模型进行了改进, 均提取未见实体对的关系上下文子图和关系路径, 进而聚合上下文子图和路径的表示实现关系推理, 这 5 个模型各自的特点在于采用不同的方法来学习子图和路径的表示, 其中, PathCon 采用特定于关系的消息传递机制聚合未见实体的邻域信息, SNRI 使用 GNN 和门控循环单元 (GRU) 分别编码上下文子图与关系路径, REPORT 对实体对间的上下文子图和关系路径都借助 Transformer 进行编码, LogCo 和 RPC-IR 针对监督信号不足的问题构建正、负关系路径表示得到更充分的自监督信息, 进而引入对比学习机制进行模型训练. TACT 模型^[159]、NRTG 模型^[160]和 CoMPILE^[161]均在 GraIL 的基础上进行了改进, TACT 对关系之间的语义关联按照定义的 7 种拓扑模式进行建模, NRTG 将关系之间的关联结构划分为 6 种拓扑模式, 可以有效地以实体无关的方式利用关系之间的拓扑相关性进行归纳式推理, CoMPILE 引入新的节点边缘通信消息传递机制来建模有向子图, 有助于考虑不同关系的相对重要性, 可以有效处理对称和反对称关系. 由于基于 GNN 方法的归纳学习能力主要来自子图信息, 因此, 抽取最有效的子图对于归纳式推理非常重要. 为此, LCILP^[162]和 ReCoLe^[163]都采用了一种局部聚类方法来提取与当前关系语义相关的子图, 再对子图通过 GNN 进行编码, DEKG-ILP^[164]设计了基于 GNN 的子图建模机制来挖掘每个关系周围的局部子图信息. 此外, 为了增强对子图信息的利用, 一些方法针对关注子图中不同信息的重要性进行了设计. LAN^[165]结合逻辑规则和注意力机制在编码邻居子图的过程中为实体的邻居赋予不同的权重. ARP 模型^[166]通过注意力网络抽取和当前查询三元组最相关的子图得到实体上下文特征. 此外, TransNS^[167]利用实体之间的语义亲和力来得到相关的高质量负样本来增强模型的归纳学习能力.




图9 归纳式知识图谱推理示意图

(2) 基于规则学习的方法: 规则作为高层语义知识的抽象形式, 通常仅依赖于变量而不针对具体实体, 因此, 规则能够直接应用于对未见实体的推理. 特别地, 如第 2.1 节所述的基于规则学习的单步知识图谱推理模型同样适用于归纳式知识图谱推理任务, 此外, 本节主要介绍专门面向归纳式知识图谱推理任务的代表性方法. 与第 2.1 节中介绍的 AMIE+算法在全图范围内计算规则置信度的模式不同, RuleNet 模型^[168]提出了一种双重图遍历机制, 通

过引入关系参数信息对候选规则空间进行系统性搜索. CBGNN 模型^[169]利用循环空间的线性结构高效求取循环基, 以捕捉更具代表性的潜在规则模式, 在此基础上基于 GNN 的消息传递机制实现规则的端到端学习. 此外, RED-GNN 方法^[170]从关系路径重叠结构出发, 构建关系导向图并在该图上生成可组合的规则模式, 从而实现复杂逻辑规则的表达与学习. 为进一步减轻知识图谱中邻域信息稀疏的问题, VN 模型^[171]提出了基于规则的虚拟邻居预测框架, 首先挖掘路径规则, 并在此基础上引入软标签与知识图谱嵌入表示的协同优化机制, 能够有效补充未见实体的上下文邻域信息, 从而在归纳式知识图谱推理任务中实现更丰富且语义一致的实体表示. 这类基于规则的归纳式知识图谱推理模型在提升推理结果可解释性方面展现出显著优势.

两类归纳式知识图谱推理方法对比总结如表 8 所示.

表 8 归纳式知识图谱推理方法对比总结

方法类型	特点	优点	缺点
基于 GNN 的方法	大多是基于 GNN 的模型, 能够较好地利用关系事实和图结构	通过归纳嵌入具有对未见实体较好的表示能力	缺乏可解释性
基于规则学习的方法	从已有三元组中挖掘规则, 天然具备较好的归纳式推理能力	能够捕捉实体之间的关系模式, 可解释性较好	泛化能力有限, 且时间和空间复杂度较高

虽然大量的归纳式知识图谱推理方法已经被提出, 但是由于未见实体的邻居子图存在稀疏性, 当前该类方法的性能仍存在较大提升空间, 笔者认为一方面可以结合大模型蕴含的丰富隐式知识开发更有效的规则学习算法, 通过更丰富的规则进行不依赖于具体实体的归纳式知识图谱推理. 此外, 可以结合未见实体的邻居信息和大模型生成未见实体的文本描述以改善对该实体的表示, 这些思路值得进一步深入探索.

3 面向复杂任务的知识图谱推理方法

基于上述介绍的面向单一推理任务的知识图谱推理方法, 本节进一步探讨几类面向复杂任务的知识图谱推理方法.

3.1 时序多步知识图谱推理

时序多步知识图谱推理可以视为综合了时序知识图谱推理和多步知识图谱推理这两类单一任务的复杂推理任务. 按照建模知识图谱中多步信息的方式, 当前主要有基于 GNN 的方法和基于强化学习的方法.

(1) 基于 GNN 的方法: Han 等人^[46]在国际会议 ICLR 2021 上首次提出关于时序多步知识图谱推理的模型 xERTE, 针对一个时序知识图谱推理查询问题 (主语, 谓词, ?, 时间), 借鉴图学习中的消息传递思想, 从查询主语出发, 迭代地采样当前实体的子图中相关边 (谓词) 并沿着采样的边传播注意力, 这里为了引导子图向查询感兴趣的方向扩展, 采用了一种新颖的时间感知关系图注意力机制, 在传递消息时施加时间约束, 以保持时序知识图谱中事件之间的因果关联, 经过多轮扩展和剪枝, 通过可解释的子图路径, 可以推理出查询问题中缺少的宾语. 与其类似的是, 如图 10 所示, T-GAP 模型^[172]针对给定的查询问题, 通过基于 GNN 的预先邻居编码得到蕴含上下文知识的实体嵌入, 并迭代地在每一步 t 中进行子图采样和子图邻居编码与查询上下文融合, 得到第 t 步的实体嵌入, 进而传播每个实体的注意力值到其可达的邻居实体, 以此按照时间顺序有选择性地一步步探索知识图谱, 并根据最后一步 T 时得到的实体注意力分值高低来判断最有可能正确的答案实体, 实现具有可解释性的时序多步推理. xERTE 和 T-GAP 均是通过图注意力传播的思想来提供多步推理能力, 然而这种方式无法给出显式的推理路径, 可解释性不足.

(2) 基于强化学习的方法: 借鉴基于强化学习机制的多步知识图谱推理方法, TPath 模型^[173]通过强化学习框架在时序知识图谱中建模路径推理过程, 其中, 与面向静态知识图谱的方法不同之处在于, 这里智能体在搜索路径的过程中, 状态、动作空间、策略网络、奖励函数等部分的设计均增加了时间信息, 使得智能体动态调整路径搜索策略以适应时间变化, 从而实现在时序知识图谱上的路径搜索和多步推理. CluSTeR 模型^[119]借鉴了人类在面对推理任务时先查找有用的历史信息, 再进行合理推理的过程, 该方法通过两阶段的推理策略结合了历史线索的搜索和时序推理, 具体的, 该方法利用强化学习技术从整个时序知识图谱中搜索和查询主语相关的所有多步路径作为

历史线索,进而采用 R-GCN 模型编码每个时间戳的事实,同时基于 GRU 建模时间窗口内的所有事实及其之间的时序关联,进一步采用多层感知机 (multi-layer perceptron, MLP) 计算所有候选实体为正确结果的概率分布得到推理结果. 以上时序多步知识图谱推理方法仅考虑了事件间的顺序而忽略了事件间具体的间隔时间信息, RTTI 模型^[174]提出了一个时间间隔表示方法,通过两个时间戳的中值和时间戳嵌入表示的变化来表达时间间隔信息,并结合强化学习技术实现时序知识图谱多步推理. TITer (TimeTraveler) 模型^[170]为了解决关于未知时间戳的多步推理问题,在基于强化学习的路径搜索的框架中引入相对时间编码增强模型,如图 11 所示, TITer 从查询节点开始,在每个步骤中,根据策略网络采样一个出边并遍历到新节点. 在搜索过程中,利用动态嵌入、路径编码和动作评分机制来选择动作. 当搜索完成后,根据基于狄利克雷分布设计的时间塑形奖励函数,并通过优化策略网络来最大化预期奖励. 在处理未见实体时,使用归纳平均表示方法更新其表示,以提高模型对新增实体的处理能力,实现在进行动作选择时对未知时间信息的捕捉能力,同时,能够结合时间信息得到路径搜索的奖励以引导模型更有效的训练.




图 10 基于图注意力传播的 T-GAP 模型示意图




图 11 基于强化学习的 TITer 模型示意图

表 9 总结了这几类时序多步知识图谱推理方法的核心创新点并对比了它们之间的优缺点,这些方法的共同特点是不同程度上利用了图注意力传播或强化学习技术,旨在从历史数据中提取信息,推导出未来事件. 此外,可解释性也是几项研究相比于面向单一任务的时序知识图谱推理方法的优势之一,这显示出当前研究开始关注可信的知识图谱推理. 同时,第 2.2 节中介绍的结合 LLM 的多步知识图谱推理方法同样可以扩展到时序多步知识图谱任务中,进而第 2.3 节中结合大模型的时序知识图谱推理策略赋予 LLM 时序多步知识图谱推理能力是一个值得探索的方向.

表 9 时序多步知识图谱推理方法对比总结

模型	创新点	优点	缺点
基于GNN的方法	时间感知关系图注意力机制	可解释性和因果建模能力强	存在路径扩展问题,忽略时间间隔信息
基于强化学习的方法	强化学习框架融入时间信息	能够有效建模时间间隔,并充分学习历史信息对未来事件准确推理	在大规模知识图谱上效率较低,因果性建模较弱,且依赖特定数据

3.2 小样本多步知识图谱推理

为了在小样本的场景中实现多步知识图谱推理,也可以视为小样本知识图谱推理和多步知识图谱推理的综合

复杂任务, Lv 等人^[47]最早提出了 Meta-KGR 模型, 将 MAML 机制引入基于强化学习的多步知识图谱推理框架中, 该方法使用高频关系的样本训练强化学习模型的多步推理能力, 进而将学习到的强化学习模型参数视为元参数, 针对长尾关系采用 MAML 机制将元参数进行快速更新, 以适应长尾关系的多步推理. FIRE 模型^[175]是在 Meta-KGR 基础上的扩展, 如图 12 所示, FIRE 设计了异质结构编码方法, 利用实体的异质邻居信息增强实体嵌入表示, 使模型能够更好地捕捉知识图谱中的结构信息, 同时采用知识感知的搜索空间剪枝策略, 借助知识图谱嵌入表示对路径搜索空间执行剪枝操作, 减少冗余动作选择, 提高了路径搜索和推理的效率. ADK-KG 模型^[176]对 FIRE 模型进行了改进, 设计了一个基于预训练 BERT 模型的文本增强图神经网络来提高对实体编码的效果, 并利用基于类型的邻居聚合和异构信息融合等策略有效捕捉知识图谱中的丰富语义和结构信息, 进一步, 采用自注意力机制计算针对不同关系下小样本学习任务的权重, 以此增强基于 MAML 的元学习训练效果. 由于基于强化学习的模型在困难关系也就是训练损失高的关系上推理性能受限, THML 模型^[177]在处理小样本多步知识图谱推理时, 采用与 Meta-KGR 和 FIRE 类似的 MAML 机制设计强化学习模块, 不同之处在于 THML 通过在每个训练批次中识别困难关系并生成样本, 设计了两级难度感知采样策略, 从关系级别和关系簇级别有效生成新的批次样本, 通过对困难关系的重复采样和训练, 交替进行不同级别的采样, 使模型能够逐渐更新到最优参数, 有效提高了模型的泛化能力. 最新的研究开始关注综合时序多步知识图谱推理和小样本多步知识图谱推理的更加复杂的推理任务, FTMI 模型^[178]通过多跳邻居编码器聚合小样本关系的多跳邻居生成时间感知的实体嵌入来增强实体的表示, 并采用 Transformer 编码实体对嵌入, 并通过平均池化层聚合得到长尾关系的表示. 进而, 引入强化学习框架, 构建策略网络和新的奖励函数平衡路径新颖性和路径长度, 帮助智能体找到最优路径, 同时在训练过程中应用基于 MAML 的元学习机制, 使得模型快速适应新的长尾关系.




图 12 小样本多步知识图谱推理 FIRE 模型示意图

以上 5 个模型展示了在面对低资源场景下增强多步知识图谱推理能力的各种策略, 核心思路都是基于元学习机制对用于多步推理的强化学习模型参数进行快速更新, 以适应新的长尾关系, 这 5 个模型的特点及优缺点对比如表 10 所示. 此外, 结合大模型的多步推理能力和基于上下文学习的小样本学习能力是小样本多步知识图谱推理方向值得研究的一个思路.

表 10 小样本多步知识图谱推理方法对比总结

模型	创新点	优点	缺点
Meta-KGR	首次在建模多步推理过程的强化学习框架中采用元学习, 从高频关系中学习模型的元参数并快速适应长尾关系	相比于之前的多步知识图谱推理方法, 能够适应新的长尾关系	未充分考虑实体和关系的语义信息
FIRE	结合异质结构编码、知识感知的搜索空间剪枝与元学习机制	改善了路径搜索和推理的效率	实体编码能力不足
ADK-KG	用文本增强异质图神经网络优化实体嵌入, 采用元学习结合知识蒸馏的方式优化模型	有效捕捉知识图谱中的丰富语义和结构信息	引入较多模块技术, 增加模型复杂性, 训练与理解难度增大
THML	通过两级难度感知采样, 交替进行不同级别采样生成批次样本并基于元学习更新参数	模型能够逐渐更新到最优参数, 有效提高了模型的泛化能力	两级难度感知采样增加了模型的复杂度
FTMI	通过邻居编码器聚合小样本关系的多跳邻居信息生成时间感知的实体嵌入, 引入强化学习中新的奖励函数	实现了时序和低资源场景下的多步知识图谱推理	对时序信息的表示能力有待提升

3.3 小样本时序知识图谱推理

小样本时序知识图谱推理属于小样本知识图谱推理和时序知识图谱推理的耦合复杂任务. 例如面向时序知识图谱推理, 基于度量学习的方法在查询三元组和参考三元组的匹配过程中, 需要考虑具有时间信息的实体对表示进行匹配. 整体而言, 当前小样本时序知识图谱推理方法均可以视为在已有小样本知识图谱推理方法上的改进, 因此, 可以按照小样本知识图谱推理方法的分类原则, 分为基于度量学习的方法和基于元学习的方法.

(1) 基于度量学习的方法: FTMO 模型^[48]对 FSRL 模型从建模时序信息的角度进行了一定的改进, 采用时间关系感知的邻居编码器, 在编码实体时结合了时间信息, 并借助循环自聚合网络融合支持集中所有参考三元组的语义信息, 进而衡量参考三元组和查询三元组之间的相似度. TFSC 模型^[179]基于 FAAN 进行了优化, 与 FAAN 不同之处在于, TFSC 采用 TTransE 模型对融合时间信息的实体进行编码表示, 进而利用注意力机制对实体的邻居进行编码, 通过 Transformer 编码器学习具有时间感知的实体对表示, 以增强时序知识图谱背景下的实体表示能力, 同时提高时序和小样本场景下的实体对匹配效果. TR-Match 模型^[180]设计了多尺度时间关系注意力编码器, 如图 13 所示, 其能够自适应捕捉局部和全局信息, 并融合时间信息和关系得到不同尺度的实体对嵌入表示, 提高了对时序特性的处理能力. FTMF 模型^[181]使用自注意力机制来编码实体, 使用循环递归聚合网络来聚合参考集邻居, 并使用了特殊的容错机制来处理知识图谱中的错误信息, 进而使用匹配网络来计算相似性分数.




图 13 基于度量学习的小样本时序知识图谱推理 TR-Match 模型示意图

以上 4 个方法介绍了针对低资源场景下增强时序知识图谱推理的几种思路, 其核心都是在基于度量学习机制的小样本知识图谱推理方法基础上融合对时间信息的编码, 以达到小样本时序知识图谱推理效果.

(2) 基于元学习的方法: MetaRT 模型^[182]对 MetaR 模型针对时序知识图谱的特点进行了改进, 如图 14 所示, 在基于 MAML 的 MetaR 模型优化过程中, 替换了仅适用于静态知识图谱的 TransE 模型打分函数, 改为面向时序知识图谱的 TTransE 模型打分函数, 使得 MetaRT 模型能够处理时序知识图谱推理任务. MetaTKGR 模型^[183]将时间作为监督信号动态地从最近事件中采样和聚合邻居信息, 以在低资源场景下增强对当前时间实体的表示和推理, 进而采用嵌套双循环的元学习优化机制, 内循环编码最近的事件, 外循环进行知识迁移以快速适应未来事件的推理. zrLLM 模型^[184]使用 GPT-3.5 生成丰富的关系文本描述并输入 T5-11B 编码器, 生成关系的文本嵌入表示, 并使用全连接网络将大模型得到的文本嵌入表示对齐到知识表示学习模型的嵌入表示空间中, 进而结合关系文本嵌入表示和事件四元组输入时序知识表示学习模型中, 得到事件四元组的打分, 同时设计了关系历史学习器, 通过捕捉关系的历史模式, 进一步促进文本与时序知识图谱嵌入空间的对齐, 使模型能够更好地利用 LLM 提供的语义信息进行零样本关系预测, 实现了低资源场景下借助大模型的时序知识图谱推理.

以上 3 个方法介绍了从元学习的角度解决小样本时序知识图谱推理问题的方法, MetaRT 和 MetaTKGR 均是

在 MetaR 模型基础上的改进, MetaRT 结合关系元信息和特定的时间嵌入表示学习机制融合对时间的编码; MetaTKGR 侧重于元学习框架下的动态采样和聚合策略, 以及时间编码和嵌套双循环的设计; zrLLM 利用大模型生成关系文本描述并进一步增强文本与知识图谱嵌入空间的对齐。

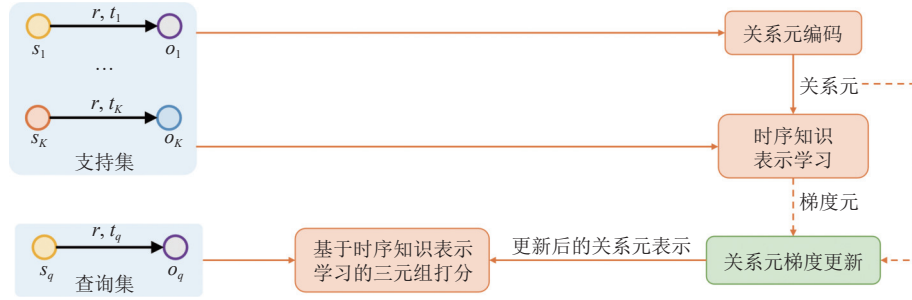


图 14 基于元学习的小样本时序知识图谱推理 MetaRT 模型示意图

两类小样本时序知识图谱推理方法的对比如表 11 所示。

表 11 小样本时序知识图谱推理方法对比总结

模型	创新点	优点	缺点
基于度量学习的方法	通过时间关系感知的邻居编码器, 自适应捕捉带时间的实体对嵌入表示用于匹配	联合考虑关系和时间信息, 在不同关系上稳定性强	对数据集有要求, 容易受到知识图谱稀疏性的影响
基于元学习的方法	结合关系元信息和特定的时间嵌入表示学习机制融合对时间的编码	在不同时间步长下性能稳定且性能提升显著	模型复杂度较高

当前小样本时序知识图谱推理方法均主要是在基于度量学习和基于元学习的小样本知识图谱推理方法上结合时间信息的改进, 此外, 在基于大模型的时序知识图谱推理方法中引入元学习或者上下文学习机制是一个解决小样本时序知识图谱推理问题的思路。

3.4 小样本多模态知识图谱推理

为了突破小样本场景下与长尾关系直接相关的三元组事实的局限性, 一类复杂任务是利用一些多模态信息表示对长尾关系进行补充, 这些多模态信息主要包括文本描述、本体信息和路径信息, 可以从不同角度为实体和关系提供丰富的语义信息, 以弥补低资源场景下数据稀疏的限制。

(1) 结合文本描述的方法: TCVAE 模型^[49]设计了文本编码器来学习和利用实体特征, 从包含多个关系的实体描述文本中提取关系特定信息, 并采用卷积神经网络和自注意力机制有效提取关键信息, 增强了模型对实体描述的理解能力, 进而, 构建基于条件变分自编码器的三元组生成器, 在训练阶段学习潜在模式, 并在测试阶段通过生成额外三元组进行数据增强, 以减轻小样本数据的稀疏问题。ZSGAN^[185]针对更加困难的零样本知识图谱推理问题, 使得模型能够在一些关系没有直接对应的训练数据的情况下, 采用生成对抗框架从关系的文本描述中生成有效的关系嵌入表示, 利用条件生成对抗网络建立文本与知识图谱之间的知识迁移过程, 使生成的关系嵌入表示能够反映知识图谱中的语义信息, 实现了零样本学习到传统监督分类任务的转换, 进而通过计算关系嵌入表示和实体对嵌入表示间的余弦相似度来评估三元组成立的可能性, 如图 15(a) 所示。HAPZSL^[186]通过引入包含关系注意力和实体注意力的混合注意力机制, 并对实体和关系的文本描述进行编码, 让模型更好地捕捉关系和实体之间的相似性和依赖性, 从而提高模型的泛化能力, 同时利用原型网络学习关系的典型表示也就是关系原型, 使得实体对表示逼近对应的关系原型。特别的, 针对零样本学习中关系原型距离易受文本描述相似性影响的问题, 通过引入负样本查询集, 计算原型与正、负样本实体对的距离来优化模型, 提高了模型的判别能力。

(2) 结合本体信息的方法: 考虑到知识图谱尤其是垂直领域知识图谱通常需要具有本体层, 其中包含了概念及其之间的关系。为了充分利用本体中丰富的高层语义信息, OntoZSL 模型^[187]利用本体中定义的概念层次结构和关

系, 构建先验概念图谱, 利用 GNN 对概念图谱进行编码, 从而可以利用本体嵌入表示增强知识图谱中长尾关系的表示, 进而采用与 ZSGAN 类似的方式, 采用 GAN 作为生成模型, 通过将学习到的本体嵌入作为条件, 使生成器能够产生具有判别性的样本特征, 将零样本学习任务转化为监督学习任务, 有效解决了数据不平衡问题. DOZSL^[188]提出了一种本体属性引导的解耦本体嵌入方法, 将本体中的概念节点嵌入解耦为多个分量, 每个分量编码概念在某一方面的语义, 进一步通过属性感知的注意力机制聚合邻居信息, 并利用属性引导的三元组评分机制来细化每个分量的语义, 使模型能够提取本体中已见和未见关系之间更细粒度的类间关系, 进而可以使用基于 GAN 的生成模型和基于 GNN 的传播模型来融合解耦嵌入, 以生成未见关系的嵌入表示. DMoG 模型^[189]发现关系可由事实图谱、本体图谱和文本图谱表达, 因此针对一个知识图谱相关的本体图谱和文本图谱, 分别通过 GCN 学习未见关系的文本和本体特征, 再设计混合专家机制, 通过融合空间映射模块将文本和本体特征映射到相同表示空间内以融合不同图谱的语义信息, 增强对未见关系的嵌入表示, 如图 15(b) 所示. (3) 结合路径信息的方法: 以上介绍的小样本多模态知识图谱推理方法均仅利用了实体间的直接关联进行匹配和编码, 忽略了实体间的多步路径信息所蕴含的实体间的间接语义关联. P-INT 模型^[190]基于度量学习的思想, 与第 2.5 节中介绍的方法不同之处在于, P-INT 利用从头实体到尾实体的路径来表示实体对, 通过 GRU 学习每个实体对间所有路径的嵌入表示, 并设计引入路径注意力的路径交互机制以计算支持集实体对和查询集实体对的路径相似度, 实现参考三元组和查询三元组的匹配过程, 同时路径注意力机制能够区分不同路径对匹配结果的影响, 有利于抑制噪声路径, 得到更好的小样本知识图谱推理结果, 如图 15(c) 所示. 与 P-INT 模型类似, EPIRL 模型^[191]采用强化学习技术从知识图谱中构建推理子图, 利用双向广度优先搜索算法预搜索可行路径作为监督策略, 训练强化学习智能体来识别和选择有前景的推理路径, 使路径搜索更精确高效, 形成参考三元组和查询三元组之间的推理路径, 进一步设计与 P-INT 模型类似的基于路径的匹配机制, 捕捉这些推理路径之间的内在关联, 构建路径交互矩阵和应用核池化方法计算相似度, 并采用关系注意力机制提高关键路径的重要性.




图 15 3 类小样本多模态知识图谱推理模型示意图

3 类小样本多模态知识图谱推理方法的特点及优缺点对比如表 12 所示.

表 12 小样本多模态知识图谱推理方法对比总结

模型	创新点	优点	缺点
结合文本描述的方法	建立文本与知识图谱之间的知识迁移过程, 利用文本表示反映知识图谱中的语义信息	对实体描述的理解能力强, 能够有效处理未见关系	依赖文本描述准确性, 模型复杂度高
结合本体信息的方法	将学习的本体嵌入用于增强未见关系的嵌入表示	充分挖掘本体中丰富的语义信息, 精准捕捉类间复杂关系	依赖本体图谱的质量, 模型复杂度高, 可扩展性受限
结合路径信息的方法	通过路径交互机制来计算支持集实体对和查询集实体对的路径相似度	能够抑制噪声路径并通过路径嵌入提高匹配的准确性	路径长度过长或数量过多导致路径搜索空间过大

当前的小样本多模态知识图谱推理方法主要是利用某类多模态信息来补偿低资源场景下的数据稀缺问题, 然而, 利用并融合多种类型的多模态信息能够更加全面地为长尾关系引入丰富的上下文信息.

3.5 多模态归纳式知识图谱推理

针对归纳式知识图谱推理, 为了不依赖于知识图谱内部的子图结构而直接得到未见实体的嵌入表示, 结合多模态信息的方法能够充分利用与实体和关系有关的文本、图像等信息来直接学习其嵌入表示. 本文第 2.4 节中已经介绍了一系列多模态知识图谱推理方法, 且这些基于多模态信息学习实体表示的技术同样适用于本节方法. 因此, 本节主要介绍专门面向归纳式知识图谱推理任务而提出的结合多模态信息的方法.

(1) 结合概念信息的方法: 基于图神经网络的方法通过编码邻居信息来表示未见实体, 这类方法可扩展性强, 在大规模知识图谱上表现良好, 但是只能对与原始知识图谱有关联的未见实体或关系进行处理, 无法应用于当前知识图谱与原始训练阶段知识图谱不存在相同实体的全归纳式推理的情况. 此外, 基于图神经网络的方法依赖于充分的邻居子图信息, 而未见实体的邻居通常较为稀疏, 导致这类方法的性能受限. 为此, CatE^[192]首次利用本体概念信息解决新增未见实体的表示问题, 采用 Transformer 对本体层中的概念上下文信息进行编码得到概念嵌入表示, 将概念嵌入作为目标实体的初始表示, 并通过关系特定的注意力机制整合相关概念, 根据查询关系衡量不同概念的重要性, 进而利用门控机制在邻居信息中集成未见实体的概念信息来增强这类实体的嵌入表示. 然而, 这一方向的已有研究较少, 且相对实体层中的知识而言, 本体层中的概念信息较为有限, 所以仅考虑知识图谱内部的结构化知识难以提供充分的实体和关系的表示.

(2) 结合文本描述的方法: 延续 DKRL 模型^[126]的思想, OWE^[50]不仅学习知识图谱嵌入表示, 还使用实体的名称和文本描述来学习未见实体的文本嵌入表示, 然后将实体的文本嵌入映射到知识图谱嵌入表示空间中, 增强对未见实体的推理能力, 如图 16 所示. 一些方法在 OWE 的基础上对文本嵌入技术和嵌入表示空间映射机制进行了改进, WOVE^[193]和 Caps-OWKG^[194]在学习实体的文本嵌入时分别采用注意力网络和关系感知的相关度指标计算实体文本描述中每个单词的权重, OWE-MRC^[195]借鉴机器阅读理解技术从长文本描述中提取出有意义的短文本描述, 以提高文本嵌入的精度, OWE-RST^[196]在 OWE 的基础上为每个关系学习特定的文本到知识图谱嵌入表示空间的映射, 通过不同的转移函数改进映射效果. EmReCo^[197]使用关系感知的注意力聚合器和门控机制筛选和学习未见实体在特定关系下的文本嵌入, 保证结合该文本嵌入的实体嵌入表示更能满足关系上下文语义. ConMask^[198]进一步使用关系掩码、全卷积神经网络和语义平均池化机制从实体和关系的文本描述中提取未见实体的关系感知嵌入表示. MIA^[199]对 ConMask 进行了改进, 提出建模头实体描述、头实体名称、关系名称和候选尾实体描述之间的交互, 对未见实体形成丰富的表示. 此外, SDT 模型^[200]利用图神经网络和文本编码器将实体的结构信息、文本描述和分层类型信息合并到统一的框架中, 以学习未见实体的嵌入表示, 并通过对比学习和自监督学习训练增强归纳式推理能力.




图 16 多模态归纳式知识图谱推理 OWE 模型示意图

(3) 基于预训练语言模型的方法: 特别的, 近两年兴起的语言模型天然适用于对文本信息的处理, 因此, Bi-link^[201]利用预训练语言模型 BERT 从实体和关系的文本描述中学习文本嵌入, 其中借助基于概率规则的提示表达式来丰富关系的文本信息. RAILD^[202]通过微调预训练语言模型 (pre-trained language model, PLM) 来编码实体和关系的文本描述, 学习未见实体和关系的嵌入表示. BERTRL^[203]将实体的邻居子图线性化为序列化路径, 进而可以

将其输入 BERT 模型中进行微调以编码邻居信息. InductiveE^[204]使用 PLM 和词嵌入来学习实体的文本嵌入, 同时基于图密集化机制为未见实体提供更多的结构信息, 进而利用 GNN 对邻居子图进行编码, 以结合文本嵌入和子图特征增强未见实体的表示. 此外, 同时引入文本和视觉信息的多模态知识图谱推理方法同样适用于归纳式知识图谱推理任务, 这类方法已在第 2.4 节中进行了梳理, 因此本节不再重复论述.

以上 3 种多模态归纳式知识图谱推理类方法的特点及优缺点对比如表 13 所示. 此外, 利用多模态大模型技术以结合隐式知识和大模型的多模态对齐和理解能力可以进一步提升多模态归纳式知识图谱推理的性能, 值得在未来研究中深入探索.

表 13 多模态归纳式知识图谱推理方法对比总结

模型	创新点	优点	缺点
结合概念信息的方法	集成未见实体的概念信息来增强这类实体的嵌入表示	利用知识图谱中已有的本体概念, 不依赖于外部信息	模型性能易受到本体概念质量的影响
结合文本描述的方法	学习关系感知的文本嵌入并将其映射到知识图谱表示空间中	自适应学习与当前关系语义最相关的文本嵌入表示	对文本嵌入学习的能力有限
基于PLM的方法	通过微调预训练语言模型来编码实体和关系的文本描述	充分发挥预训练语言模型对文本的表示能力	预训练语言模型和知识图谱存在语义鸿沟

3.6 时序归纳式知识图谱推理

相比于其他类型的知识图谱, 时序知识图谱的动态特性尤为明显, 因此普遍存在新增未见实体的情况. 因此, 时序归纳式知识图谱推理要求学习未见实体表示的同时考虑时序信息. 针对时序多步推理任务的 TITer 模型^[51]同样考虑了新增未见实体的情况, 其在基于强化学习的多步知识图谱推理框架中设计了相对时间编码函数和时间奖励策略, 更重要的是提出了归纳平均表示机制来处理新出现的未见实体, 利用查询信息和学习的实体嵌入表示, 提高了模型的归纳推理能力, 且不增加计算成本, 实现了时序知识图谱上针对未见实体的多步推理. FITCARL 模型^[205]在基于元学习的框架中引入了强化学习策略, 如图 17 所示, 通过在 Transformer 中采用时间感知的位置编码机制以更好地编码具有时间信息的实体元表示, 并设计了一个置信度增强的策略网络, 使得在计算每个候选动作的概率分布时不仅能够考虑搜索历史和当前状态, 还利用置信度学习器计算每个动作的置信度, 以减轻由于数据稀缺导致的动作空间不完整和搜索历史存在噪声等问题, 使策略网络能够做出更可靠的动作选择, 同时利用知识图谱中的概念信息提供先验约束建立正则机制, 在时序归纳式知识图谱推理任务中效果显著. FILT 模型^[206]同样基于元学习框架将已见实体向未见实体进行知识迁移, 具体地, FILT 从时序知识图谱中学习概念信息并将其注入未见实体的嵌入表示中, 同时采用基于时间差的图神经网络来计算未见实体的上下文表示, 根据查询时间戳与支持集中四元组时间戳的时间差, 确定邻居节点的重要性并进行聚合, 使模型能更好地捕捉时间信息.




图 17 基于元学习的时序归纳式知识图谱推理 FITCARL 模型示意图

这 3 个时序归纳式知识图谱推理方法的特点及优缺点对比如表 14 所示. 相对其他几类面向复杂任务的知识图谱推理方法而言, 时序归纳式知识图谱推理方法的研究非常有限, 针对这一方向从时序知识图谱中充分挖掘有效的时序规则, 将有助于改善时序归纳式知识图谱推理的性能, 值得进一步深入研究.

表 14 时序归纳式知识图谱推理方法对比总结

模型	创新点	优点	缺点
TITer	设计相对时间编码函数和时间奖励策略及归纳平均表示机制, 来表示时序信息和未见实体	通过基于时序路径的强化学习框架和归纳平均表示机制有效地进行归纳推理, 且具有较高的效率	数据分布不均匀可能影响模型对时序信息和对未见实体的处理能力
FITCARL	结合引入置信度学习器的强化学习与元学习, 并利用时间感知Transformer学习新实体表示	能够快速适应新出现的实体, 并减轻数据稀疏问题	训练过程涉及多个模块的协同优化, 训练难度和调参成本较高, 且不准确的概念标注会影响模型对概念信息的有效利用
FILT	通过元学习框架和概念信息增强对未见实体的表示	概念学习和基于时间差的GNN同时增强了未见实体和时序信息的表示, 且具有一定可解释性	模型性能依赖于概念信息的质量, 且模型复杂度相对较高

4 性能对比和下游应用

为了说明当前知识图谱推理方法的应用情况, 本节首先梳理和对比不同知识图谱推理任务中代表性方法在对应基准数据集上的实验效果, 进而介绍各类知识图谱推理任务对应的典型下游应用现状, 以说明知识图谱推理技术的实际应用价值.

4.1 代表性方法的性能对比

本文针对每类知识图谱推理任务, 分别选取 2 个或 3 个常用的基准数据集, 梳理并给出每个数据集上代表性方法的性能对比, 为了保证性能对比的公平性和真实性, 所有模型的性能结果均来源于已有文献公布的性能数值, 以便于了解已有方法的性能现状和提升空间. 本节性能对比分析表格中将指标 $Hits@n$ 简写为 $H@n$.

FB15K-237 和 WN18RR 是面向单步知识图谱推理的相关方法最常用的两个基准数据集, 因此在这两个数据集上的测试结果对于评价所提出模型的性能较有说服力. 表 15 展示了两类单步知识图谱推理方法中的代表性模型在这两个数据集上的评测结果, 从中可以发现基于知识表示的方法在大多数指标上优于基于规则学习的方法, 说明前者通过数值计算的推理方式在准确性和鲁棒性上表现出色, 但是, 后者基于符号计算的推理方式针对无法直接从性能指标上体现出的可解释性更有优势. 当前, 结合知识表示学习的泛化能力和规则学习的可解释性是知识图谱推理未来值得深入探索的方向.

表 15 代表性单步知识图谱推理方法性能对比

类型	模型	FB15K-237					WN18RR				
		MR	MRR	H@1	H@3	H@10	MR	MRR	H@1	H@3	H@10
基于知识表示的方法	TransE	357	0.294	—	—	0.465	3 386	0.226	—	—	0.501
	DistMult	254	0.241	0.155	0.263	0.419	5 110	0.430	0.390	0.440	0.490
	ComplEx	339	0.247	0.158	0.275	0.428	5 261	0.440	0.410	0.460	0.510
	ConvE	244	0.325	0.237	0.356	0.501	4 187	0.430	0.400	0.440	0.520
	RotatE	177	0.338	0.241	0.375	0.533	3 340	0.476	0.428	0.492	0.571
	PairE	—	0.351	0.256	0.387	0.544	—	—	—	—	—
基于规则学习的方法	NeuralLP	—	0.237	0.173	0.259	0.361	—	0.381	0.368	0.386	0.408
	DRUM	—	0.238	0.174	0.261	0.364	—	0.382	0.369	0.388	0.410
	RNNLogic	232	0.344	0.252	0.380	0.530	4 615	0.483	0.446	0.497	0.558
	Ruleformer	—	0.342	0.255	0.374	0.513	—	0.452	0.417	0.465	0.530

面向多步知识图谱推理任务, FB15K-237 和 WN18RR 同样是常用的两个数据集, 然而需要说明的是很多多步知识图谱推理方法所选用的数据集不同, 而且基于大模型的多步知识图谱推理方法主要在知识图谱问答应用上进行了测试, 因此, 本文仅比较在 FB15K-237 和 WN18RR 这两个公开数据集上提供了测试结果的方法. 从表 16 中可以看到基于随机游走的方法优于可以编码预先抽取的路径, 在准确率指标上优于基于强化学习的方法, 而基于

强化学习的方法可以在推理过程中在线搜索路径,因此在可解释性方面更具优势.

表 16 代表性多步知识图谱推理方法性能对比

类型	模型	FB15K-237				WN18RR			
		<i>MRR</i>	<i>H@1</i>	<i>H@3</i>	<i>H@10</i>	<i>MRR</i>	<i>H@1</i>	<i>H@3</i>	<i>H@10</i>
基于随机游走的方法	A*Net	0.505	0.410	0.556	0.687	0.557	0.504	0.580	0.666
基于强化学习的方法	MINERVA	0.293	0.217	0.329	0.456	0.448	0.413	0.456	0.513
	MultiHopKG	0.393	0.329	—	0.544	0.472	0.437	—	0.542

ICEWS (integrated crisis early warning system) 是一个面向全球政治事件的时序数据库,记录了国际关系主体如国家、组织、领导人之间带有明确时间戳的交互事件,是一个常用的大规模时序知识图谱,以支持时序推理、事件预测和关系动态建模研究.面向时序知识图谱推理研究,ICEWS14 和 ICEWS05-15 是两个最常见的基准数据集,且均是 ICEWS 的子集,分别由 2014 年内和 2005–2015 年之间的政治事件构建而成.从表 17 中 3 类时序知识图谱推理的性能对比可以看出,在 ICEWS14 数据集上基于时间嵌入表示的方法性能略好于基于大模型的方法,而在 ICEWS05-15 数据集上基于大模型的方法在大部分指标上均取得了最优的结果,由此可以发现大模型在时序知识图谱推理这类需要更强逻辑推理能力的任务上展现出了优势,值得在未来开展更深入的研究,将时序知识图谱中对于事件的表达转换为大模型更容易理解的形式以充分发挥大模型的时序推理能力.

表 17 代表性时序知识图谱推理方法性能对比

类型	模型	ICEWS14				ICEWS05-15			
		<i>MRR</i>	<i>H@1</i>	<i>H@3</i>	<i>H@10</i>	<i>MRR</i>	<i>H@1</i>	<i>H@3</i>	<i>H@10</i>
基于时间嵌入表示的方法	TA-TransE	0.275	0.095	—	0.625	0.299	0.096	—	0.668
	TTransE	0.255	0.074	—	0.601	0.271	0.084	—	0.616
	HyTE	0.297	0.108	0.416	0.655	0.316	0.116	0.445	0.681
	TeRo	0.562	0.468	0.621	0.732	0.586	0.469	0.668	0.795
	TComplEx	0.619	0.542	0.661	0.767	0.664	0.583	0.716	0.811
	LCGE	0.667	0.588	0.714	0.815	0.730	0.599	0.728	0.866
基于事件演化的方法	RE-NET	0.399	0.301	0.440	0.582	0.437	0.336	0.480	0.6272
	CyGNet	0.377	0.274	0.426	0.579	0.404	0.294	0.461	0.616
	CluSTeR	0.460	0.338	—	0.712	0.446	0.349	—	0.630
基于大模型的方法	PPT	0.384	0.289	0.425	0.570	0.389	0.286	0.434	0.586
	SToKE	0.659	0.574	0.693	0.803	0.712	0.605	0.790	0.885
	GPT-NeoX	—	0.287	0.413	0.435	—	—	—	—

FB15K-237-IMG 和 WN18-IMG 分别由 FB15K-237 和 WN18RR 数据集扩展得到,是常用于评测多模态知识图谱推理方法的两个数据集,且这两个数据集中的每个实体均有 10 张对应的图片.从表 18 中给出的性能对比结果分析可知,基于预训练模型的方法在数据集 FB15K-237-IMG 上的结果显著优于基于嵌入表示的方法,在 WN18-IMG 上两类方法的性能相当,这是由于预训练模型在处理多模态数据上的能力比传统方法更强,因此基于预训练模型的方法在面向多模态知识图谱推理任务上未来将成为主流方法.

NELL-One 和 Wiki-One 是小样本知识图谱推理任务最经典的两个基准数据集,其中, NELL-One 是基于 NELL 知识库构建,筛选包含 50–500 个三元组的关系作为小样本关系,其训练、验证和测试集分别包含 51、5、11 个任务关系, Wiki-One 是以 Wikidata 为基础,并采用与 NELL-One 相同的构建与任务划分策略,但规模更大,常用于验证模型在大规模知识图谱场景下的小样本推理性能与可扩展性;其训练、验证和测试关系划分为 133、16、34 个.从表 19 所示的代表性小样本知识图谱推理方法针对 5-Shot 设置下的性能对比发现,基于度量学习的方法和基于元学习的方法在不同数据集不同指标上各有千秋,说明针对通用小样本学习的度量学习和元学习机制在小样本知识图谱推理任务上均有一定效果,同时,当前小样本知识图谱推理的性能仍有较大提升空间.

表 18 代表性多模态知识图谱推理方法性能对比

类型	模型	FB15K-237-IMG			WN18-IMG		
		MR	H@1	H@10	MR	H@1	H@10
基于嵌入表示的方法	IKRL	298	0.194	0.458	596	0.127	0.928
	RSME	417	0.242	0.467	223	0.943	0.957
	HRGAT	156	0.271	0.542	—	—	—
	MoSE	117	0.281	0.565	7	0.948	0.974
基于预训练模型的方法	VisualBERT	592	0.217	0.439	122	0.179	0.654
	VBKGC	—	0.213	0.478	—	—	—
	MKGformer	221	0.256	0.504	28	0.944	0.972
	GLTW	—	0.351	0.599	—	—	—
	SSQR	—	0.393	0.597	—	—	—

表 19 代表性小样本知识图谱推理方法性能对比

类型	模型	NELL-One				Wiki-One			
		MRR	H@1	H@5	H@10	MRR	H@1	H@5	H@10
基于度量学习的方法	GMatching	0.201	0.143	0.264	0.311	—	—	—	—
	FSRL	0.279	0.2	0.364	0.428	0.341	0.281	0.395	0.463
	FAAN	0.337	0.253	0.454	0.521	0.357	0.296	0.431	0.494
	TransAM	0.209	0.129	0.296	0.364	0.294	0.23	0.353	0.423
	FRL-KGC	0.261	0.168	0.35	0.437	0.221	0.178	0.264	0.302
	HMNet	0.209	0.141	0.28	0.355	0.323	0.27	0.385	0.418
	MetaP	0.344	0.246	0.412	0.437	0.351	0.299	0.407	0.446
基于元学习的方法	MetaR	0.328	0.22	0.447	0.515	0.23	0.184	0.282	0.322
	GANa	0.231	0.156	0.307	0.355	0.37	0.323	0.429	0.473
	SMetaR-I	0.306	0.207	0.439	0.52	0.371	0.319	0.419	0.469
	SMetaR-R	0.243	0.16	0.313	0.398	0.355	0.288	0.413	0.485
	HiRe	0.201	0.143	0.264	0.311	—	—	—	—
	MTRN	0.279	0.2	0.364	0.428	0.341	0.281	0.395	0.463

归纳式知识图谱推理数据集由 FB15K-237、WN18RR 和 NELL-995 派生而来, 并分别构建为 4 个版本. 在这些数据集中, 为实现完全归纳式设定, 训练集和测试集的实体集合完全不重叠, 但测试集中所涉及的关系均包含在训练集中, 这 3 个数据集用于评估模型在面对新增未见实体时的知识图谱推理与泛化能力. 表 20 中展示了典型归纳式知识图谱推理模型在 3 个数据集上关于 $H@10$ 指标的性能对比, 可以看出基于 GNN 的方法显著优于基于规则学习的方法, 说明 GNN 在学习归纳嵌入方面具有较好的能力, 然而, 符号规则在解决归纳式推理问题上具有天然的优势, 因此, 结合规则学习和 GNN 将是归纳式知识图谱推理有前景的一个研究思路.

表 20 代表性归纳式知识图谱推理方法性能对比

类型	模型	WN18RR				FB15K-237				NELL-995			
		V1	V2	V3	V4	V1	V2	V3	V4	V1	V2	V3	V4
基于规则学习的方法	Neural-LP	0.744	0.689	0.462	0.671	0.529	0.589	0.529	0.559	0.408	0.787	0.827	0.806
	DRUM	0.744	0.689	0.462	0.671	0.529	0.587	0.529	0.559	0.194	0.786	0.827	0.806
	RuleNet	0.809	0.782	0.534	0.716	0.498	0.778	0.877	0.856	0.535	0.818	0.773	0.614
基于GNN的方法	NBFNet	0.948	0.905	0.893	0.890	0.834	0.949	0.951	0.960	—	—	—	—
	GraIL	0.825	0.787	0.584	0.734	0.642	0.818	0.828	0.893	0.595	0.933	0.914	0.732
	SNRI	0.872	0.831	0.673	0.833	0.718	0.865	0.896	0.894	—	—	—	—
	REPORT	0.880	0.858	0.723	0.815	0.717	0.889	0.916	0.923	—	—	—	—
	LogCo	0.902	0.847	0.687	0.791	0.739	0.819	0.806	0.842	0.618	0.935	0.942	0.808
	RPC-IR	0.851	0.816	0.624	0.764	0.676	0.825	0.844	0.892	0.598	0.933	0.940	0.718

表 20 代表性归纳式知识图谱推理方法性能对比 (续)

类型	模型	WN18RR				FB15K-237				NELL-995			
		V1	V2	V3	V4	V1	V2	V3	V4	V1	V2	V3	V4
基于GNN的方法	TACT	0.840	0.816	0.586	0.763	0.644	0.821	0.840	0.906	0.575	0.930	0.933	0.741
	NRTG	0.907	0.864	0.747	0.841	0.820	0.932	0.945	0.951	0.590	0.918	0.898	0.813
	CoMPILE	0.836	0.798	0.607	0.755	0.676	0.830	0.847	0.874	0.584	0.939	0.928	0.752
	LCILP	0.883	0.841	0.727	0.795	0.710	0.819	0.843	0.898	0.524	0.936	0.922	0.829
	ReCoLe	—	—	—	—	0.713	0.766	0.761	0.755	0.648	0.836	0.791	0.799

面向时序多步知识图谱推理任务,除了单一任务中时序知识图谱推理常用的 ICEWS14 和 ICEWS05-15 外,由 ICEWS 数据集中集中在 2018 年内带时间戳政治事件构建的时序知识图谱 ICEWS18 是另一个常用的时序多步知识图谱推理数据集.从表 21 展示的时序多步知识图谱推理方法性能对比可知,基于 GNN 的方法比基于强化学习的方法表现出更优的效果,说明 GNN 在同时编码时间感知的邻居信息和通过消息传播机制建模多步路径信息方面具有一定的优势.但是,基于强化学习的方法能够给出显式的路径,可解释性更好.

表 21 代表性时序多步知识图谱推理方法性能对比

类型	模型	ICEWS14				ICEWS18				ICEWS05-15			
		MRR	H@1	H@3	H@10	MRR	H@1	H@3	H@10	MRR	H@1	H@3	H@10
基于GNN的方法	xERTE	0.408	0.327	0.457	0.573	0.293	0.210	0.335	0.465	—	—	—	—
	T-GAP	0.610	0.509	0.677	0.790	—	—	—	—	0.67	0.568	0.740	0.845
基于强化学习的方法	TPath	—	—	—	—	0.267	0.167	0.257	0.312	—	—	—	—
	CluSTeR	0.460	0.338	—	0.712	0.323	0.206	—	0.559	0.446	0.349	—	0.630
	RTTI	0.602	0.508	0.660	0.699	0.489	0.390	0.550	0.668	—	—	—	—
	TITer	0.417	0.327	0.465	0.584	0.300	0.221	0.335	0.448	—	—	—	—

小样本多步知识图谱推理任务通常使用从 NELL-995、FB15K-237 和 Wikidata 这 3 个常用知识图谱构建的基准数据集 NELL (few-shot)、FB15K (few-shot)、Wiki (few-shot),均是仿照 GMatching 模型构造数据集的方式,选择具有 10 个到上限三元组数 (NELL-995: 114 个, FB15K-237: 137 个, Wikidata: 122 个) 的关系作为小样本关系,对小样本多步推理任务的验证集和测试集,采用 1:1 的比例生成样本,分别用于模型调优和评估.从表 22 所示的性能对比能够看出当前小样本多步知识图谱推理模型在该类任务中尤其在 Wiki (few-shot) 数据集上的性能仍然值得进一步提升,同时反映出针对存在小样本关系的较为稀疏知识图谱中进行多步路径搜索具有较大挑战,需要面向这类任务研究更有效的方法.

表 22 代表性小样本多步知识图谱推理方法性能对比

模型	FB15K (few-shot)				NELL (few-shot)				Wiki (few-shot)			
	MRR	H@1	H@5	H@10	MRR	H@1	H@5	H@10	MRR	H@1	H@5	H@10
Meta-KGR	0.469	0.412	0.457	0.588	0.253	0.197	0.258	0.347	0.230	0.183	0.251	0.325
FIRE	0.478	0.423	0.481	0.597	0.273	0.225	0.276	0.371	0.256	0.215	0.273	0.343
ADK-KG	0.499	0.446	0.538	0.634	0.302	0.249	0.315	0.394	0.277	0.242	0.292	0.361
THML	0.501	0.445	—	0.624	0.304	0.257	—	0.398	—	—	—	—

NELL-ZS 和 Wiki-ZS 是从 NELL 和 Wikidata 知识图谱上抽取子集所构建的小样本多模态知识图谱数据集,更具体的是用于零样本多模态知识图谱推理.每个数据集中,关系被划分为包含已见关系的训练集、未见关系的验证集和测试集,而所有实体均为已见实体.从表 23 提供的小样本多模态知识图谱推理代表性模型的对比中分析可知,两类方法性能相当,说明通过文本和本体信息均能补充有效的信息以增强零样本设置下的推理效果,同时针对该任务,模型性能仍有较大提升空间,未来结合多模态大模型优异的多模态表示和理解能力是一个可能的探索方向.

表 23 代表性小样本多模态知识图谱推理方法性能对比

类型	模型	NELL-ZS				Wiki-ZS			
		MRR	H@1	H@5	H@10	MRR	H@1	H@5	H@10
结合文本描述的方法	ZSGAN (DistMult)	0.253	0.194	0.305	0.371	0.208	0.165	0.241	0.294
	ZSGAN (TransE)	0.240	0.171	0.316	0.376	0.185	0.161	0.210	0.261
	HAPZSL (DistMult)	0.331	0.267	0.394	0.449	0.233	0.189	0.261	0.311
结合本体信息的方法	OntoZSL (DistMult)	0.256	0.188	0.318	0.385	0.211	0.167	0.238	0.289
	OntoZSL (TransE)	0.250	0.172	0.327	0.399	0.184	0.215	0.265	0.265
	DOZSL (RD+GCN)	0.239	0.165	0.312	0.380	0.185	0.138	0.219	0.267
	DOZSL (AGG+GCN)	0.230	0.162	0.293	0.362	0.187	0.136	0.224	0.275
	DMoG (DistMult)	0.258	—	—	0.384	0.191	—	—	0.289
	DMoG (TransE)	0.305	—	—	0.491	0.232	—	—	0.311

ICEWS14-OOG、ICEWS18-OOG、ICEWS05-15-OOG 是 3 个基于时序数据库 ICEWS 构建的时序知识图谱, 分别包含 2014 年、2018 年以及 2005–2015 年的带时间戳的政治事件, 是当前常用的时序归纳式知识图谱推理基准数据集. 特别的是, 这 3 个数据集针对实体满足归纳式设置, 且针对关系满足小样本设置, 因此在这 3 个数据集上的实验结果通常从针对小样本关系的 1-shot 和 3-shot 设置给出时序归纳式知识图谱推理评测结果. 由于在已有文献^[205]中给出了部分面向单一任务的时序知识图谱推理和归纳式知识图谱推理方法在这 3 个时序归纳式知识图谱推理数据集上的测试结果, 因此表 24 和表 25 分别展示了在 1-shot 和 3-shot 设置下面向单一任务的两类方法和面向复杂任务的时序归纳式知识图谱推理方法的性能对比, 从中可以明显发现面向单一任务的时序知识图谱推理方法在该复杂任务上普遍性能受限, 同时时序归纳式知识图谱推理方法性能显著优于面向单一任务的归纳式知识图谱推理方法. 因此, 针对这个具有挑战性的任务, 同时建模时序信息和增强归纳嵌入能力非常关键, 引入逻辑规则增强归纳式推理能力并提高时序推理的可解释性是未来值得思考的研究方向.

表 24 代表性时序归纳式知识图谱推理方法性能对比 (1-shot 设置)

类型	模型	ICEWS14-OOG				ICEWS18-OOG				ICEWS05-15-OOG			
		MRR	H@1	H@3	H@10	MRR	H@1	H@3	H@10	MRR	H@1	H@3	H@10
时序推理	TNTComplEx	0.043	0.015	0.033	0.102	0.046	0.023	0.043	0.087	0.034	0.014	0.031	0.060
	TeLM	0.032	0.012	0.021	0.063	0.049	0.029	0.045	0.084	0.080	0.041	0.077	0.138
	TeRo	0.009	0.002	0.005	0.015	0.007	0.003	0.006	0.013	0.012	0	0.008	0.024
归纳式	MEAN	0.035	0.013	0.032	0.082	0.016	0.003	0.012	0.043	0.019	0.003	0.017	0.052
	LAN	0.168	0.050	0.199	0.421	0.077	0.018	0.067	0.199	0.171	0.081	0.180	0.367
时序归纳式	TITer	0.144	0.105	0.163	0.228	0.064	0.038	0.075	0.011	0.115	0.080	0.130	0.173
	FILT	0.278	0.208	0.305	0.410	0.191	0.129	0.209	0.316	0.273	0.201	0.303	0.405
	FITCARL	0.418	0.284	0.522	0.681	0.297	0.156	0.386	0.584	0.345	0.202	0.482	0.732

表 25 代表性时序归纳式知识图谱推理方法性能对比 (3-shot 设置)

类型	模型	ICEWS14-OOG				ICEWS18-OOG				ICEWS05-15-OOG			
		MRR	H@1	H@3	H@10	MRR	H@1	H@3	H@10	MRR	H@1	H@3	H@10
时序推理	TNTComplEx	0.044	0.016	0.042	0.096	0.048	0.026	0.044	0.082	0.037	0.012	0.036	0.071
	TeLM	0.035	0.009	0.023	0.077	0.019	0.001	0.013	0.054	0.072	0.034	0.072	0.151
	TeRo	0.010	0.002	0.002	0.020	0.006	0.001	0.003	0.006	0.023	0.010	0.017	0.040
归纳式	MEAN	0.144	0.054	0.145	0.339	0.101	0.014	0.114	0.283	0.148	0.039	0.175	0.384
	LAN	0.199	0.061	0.255	0.500	0.127	0.025	0.165	0.344	0.182	0.068	0.191	0.467
时序归纳式	TITer	0.200	0.148	0.226	0.314	0.115	0.076	0.131	0.186	0.228	0.168	0.262	0.331
	FILT	0.321	0.240	0.357	0.475	0.266	0.187	0.298	0.417	0.370	0.299	0.391	0.516
	FITCARL	0.481	0.329	0.646	0.696	0.370	0.193	0.559	0.627	0.513	0.386	0.618	0.700

4.2 知识图谱推理的下游应用

不同于文献 [207,208] 说明知识图谱推理技术在搜索、问答、推荐系统等水平领域的应用, 本文从各类知识图谱推理任务出发, 介绍对应的知识图谱推理技术在下游垂直领域的实际落地应用情况。

(1) 单步和多步知识图谱推理: 反欺诈检测是单步和多步知识图谱推理技术在垂直领域中的一个典型应用, 例如针对金融领域, Kapetanakis 等人^[209]提出了一种基于知识图谱推理的反欺诈检测模型, 利用交易信息间的关联关系以单步或多步推理的方式给出可以提前核验的可疑信息, 从而提升欺诈识别的准确性与可解释性。同时, Franco-Salvador 等人^[210]将知识图谱推理技术融入跨语言抄袭检测中, 通过连续学习方式学习知识图谱嵌入表示, 有效识别不同语言或表述伪装下的文本相似性。

(2) 多模态知识图谱推理: 医学和电商领域由于存在大量实体对应的多模态数据, 因此是多模态知识图谱推理技术广泛应用的领域。面向药物研发等生物医学场景, 知识图谱推理已从传统的文本与图像扩展到分子、蛋白质、基因、药物等多源科学数据, 从而显著丰富了知识表达的深度和研究维度^[211]。针对生物系统本身的复杂性和数据缺失问题, Xu 等人^[212]提出了基于三重协同注意力机制的多模态知识表示学习框架, 通过融合分子结构与文本特征, 并引入关系感知的注意力模块来细化实体-关系交互, 从而有效提升了生物医学领域知识图谱推理的性能。同时, 面向电子商务领域, 多模态电商知识图谱融合了图像、文本和结构化知识, 以丰富对产品的表示, 从而支持产品管理、比较和推荐等关键应用。为此, K3M 模型^[213]通过预训练模型和多模态知识集成实现多模态知识图谱推理, 有效改善了对产品实体的表示能力。FashionKLIP^[214]是一种多模态知识图谱增强的电子商务视觉语言模型, 通过将多模态知识图谱推理技术集成到 CLIP 风格的图像-文本检索模型中, 并利用视觉原型进行对比学习, 实现模态对齐和概念匹配训练, 从而提升了对产品进行跨模态检索的性能。

(3) 时序知识图谱推理: 由于医学诊断和智慧城市领域中的数据普遍存在动态特性, 因此时序知识图谱推理技术在这两个领域中得到了较多应用。Song 等人^[215]设计了基于 GRU 编码时序信息的知识表示学习模型, 并通过时序知识图谱推理提升医疗诊断系统的准确性。Yang 等人^[216]提出了新型中医搜索系统, 使用时序知识图谱表征中医领域知识的动态变化, 并构建时序知识图谱推理模型完成医疗搜索语句的时序意图推理。Lin 等人^[217]通过时序知识图谱推理模型实现对智慧城市的多源数据分析。STKG^[218]将行人等目标的轨迹建模为时序知识图谱, 其中的事件表示移动的轨迹、场所信息和其他时序信息等, 进而将轨迹预测转化为时序知识图谱推理任务。

(4) 小样本知识图谱推理: 在生物领域, 蛋白质相互作用预测是各种生物过程的基础。同时, 考虑到生物领域知识图谱中存在的长尾分布特性, Meta-Graph^[219]和 MetaTNE^[220]研究了小样本知识图谱推理在蛋白质相互作用预测中的应用。在分子属性预测方面, Meta-MGNN^[221]将每个分子视为图结构, 并采用 GNN 进行编码, 进而引入注意力机制增强模型对分子属性差异的感知能力, 在元学习框架下将分子属性预测转换为小样本知识图谱推理任务, 提升了分子属性预测的性能。在此基础上, Pre-PAR^[222]进一步捕捉不同分子属性之间的关联结构, 通过在相似分子间有效传播有限标签信息, 提升了小样本知识图谱推理的性能与效率。

(5) 归纳式知识图谱推理: 电商领域同样是归纳式知识图谱推理技术常用的领域, 这是由于电商知识图谱中存在大量缺失的属性信息, 且属性数据通常非常稀疏, 因此天然满足归纳式知识图谱推理特性。针对这一问题, Wang 等人^[223]提出了面向电商领域的多模态知识图谱推理框架 MPKGAC, 用于对产品属性的推理, 该模型采取三流架构对每种模态进行建模, 并在融合层和解码层进行多模态信息的充分利用来增强属性推理效果。

(6) 时序多步知识图谱推理: 面向全球危机预测中需要针对时序事件进行可解释多步推理的需求, Gastinger 等人^[224]构建了融合国家冲突、贸易与价值网络的时序知识图谱, 将未来事件如制裁升级、冲突爆发或外交影响变化的预测转换为时序知识图谱推理问题, 并利用时序多步知识图谱推理模型来捕捉实体间复杂的时空依赖关系, 以揭示全球危机与贸易动态间的相互作用。

(7) 小样本多模态知识图谱推理: 考虑到电商领域中许多新型或长尾商品可能只有很少的已知属性, 因此需要从极少的样本中对产品属性进行推理。Hu 等人^[225]设计了多模态异质超图模型, 通过建模商品图文信息间的高阶关联, 实现了对多个属性值的准确提取, 有效提升了零样本场景下商品属性推理性能。

(8) 多模态归纳式知识图谱推理: 社交媒体谣言治理是维护信息生态安全的重要任务, 在当前生成式人工智能的时代, 社交媒体上经常出现虚假新闻. 现有检测方法依赖媒体内容与社会上下文特征, 忽视了文本背后潜在的知识, 同时缺乏对未见事件的泛化能力. Wang 等人^[226]提出了基于多模态图卷积网络的多模态归纳式知识图谱推理模型, 该模型将每个帖子的文本、视觉信息和外部知识概念统一建模为知识图谱, 通过 GCN 捕捉非连续语义关系, 并利用知识蒸馏增强对未知事件的泛化能力, 实现虚假新闻检测.

5 未来研究方向展望

综上所述, 面向不同推理任务的知识图谱推理技术已取得了一定的研究成果. 考虑到知识图谱推理的核心是根据已有的知识推理出未知的知识, 因此, 除了以上介绍的几类单一和复杂推理任务, 知识图谱推理领域仍存在几个值得探索的方面, 包括从已有知识视角而言知识图谱存在稀疏性、不确定性和错误知识, 因此需要研究稀疏知识图谱推理、不确定性知识图谱推理和知识图谱错误检测; 从推理未知知识视角, 可解释性知识图谱推理、结合知识图谱推理与大模型越来越受到关注.

5.1 稀疏知识图谱推理

由于实际的知识图谱天然存在稀疏性, 导致知识表示学习方法难以学习有效的拓扑结构特征, 无法进行准确的推理. 为此, 一些研究者针对这一问题开展了稀疏知识图谱推理研究, IterE 模型^[227]和 HoGRN 模型^[228]都利用了逻辑规则捕捉关系之间的相关性来补充一定的语义知识, 增强实体和关系的嵌入表示. Jia 等人^[229]引入外部知识图谱作为补充信息, 并基于 GNN 将外部知识图谱和原本稀疏知识图谱进行融合, 实现了信息增强. KRACL 模型^[230]结合对比损失与交叉熵损失, 通过引入更多的负样本来增强对稀疏实体的反馈. BERT-ConvE^[231]将 BERT 的迁移学习能力与 ConvE 模型相结合, 通过对文本信息的表示来弥补图结构上的稀疏. 同时, 知识图谱的稀疏性会导致实体间的路径同样稀疏, 限制了多步知识图谱推理方法的性能, 针对这一问题, DacKGR 模型^[232]和 RuMER-RL 模型^[233]均在基于强化学习的路径搜索过程中动态添加边作为附加动作, 而 WAR 模型^[234]使用随机游走在路径中增加额外的信息改善了稀疏知识图谱的多步推理效果. 然而, 已有方法主要通过增加一部分的不确定性信息来补充已有知识, 而无法完全解决稀疏问题, 因此稀疏知识图谱推理仍存在较大挑战.

5.2 不确定性知识图谱推理

人工智能领域中, 不确定性知识推理是一个经典且重要的研究方向. 实际上, 知识本来就存在不确定性, 所以近几年一些研究者开始关注带有置信度的不确定性知识图谱及其推理, 该场景的核心在于表示不确定性知识和推理不确定性结果. 由于常用的向量和张量无法表达不确定性, 因此需要采用一些特殊的表示空间来描述嵌入表示的不确定性. 经典的知识表示学习模型 KG2E^[235]将实体和关系表示为高斯分布, 其中实体和关系嵌入表示中的协方差能够体现知识的不确定性. BEUR^[236]将每个实体建模为一个矩形, 用矩形区域表达不确定性, 并将两个实体之间的关系建模为头实体和尾实体矩形嵌入的仿射变换. SUKE 模型^[237]利用正样本三元组的置信度进行训练以得到一个置信度生成器, 用于对推理出的知识进行置信度预测. MUKGE 模型^[238]引入了不确定资源排序推理算法, 实现了更准确的不确定性推理结果. UKRM 模型^[239]采用规则学习建模不确定性知识, 将规则挖掘作为序列到序列的生成过程, 并通过基于 TensorLog^[240]的可微分推理机制得到新的事实三元组, 进而使用预训练语言模型根据挖掘到的规则预测事实三元组的置信度. 但是, 当前方法主要在于表示知识的不确定性, 而在推理的过程中缺乏有效的不确定性度量机制.

5.3 知识图谱错误检测

由于构建知识图谱的数据源中存在噪声, 并且自动化知识抽取技术的准确性无法得到保证, 例如以自动化方式构建的知识图谱 NELL 中存在 26% 的错误知识, 对应于大约 60 万个错误的三元组^[241]. 因此, 在含有噪声的知识图谱基础上得到的推理结果无法保证其有效性, 而针对大规模知识图谱无法完全依靠人工来检验知识图谱的质量, 因此知识图谱错误检测技术需要尽可能自动发现并剔除这些错误知识^[2]. 知识图谱错误检测面临的主要问题

是关于错误知识的真实标签很少甚至不可用,因此如何发现并表示错误知识是该场景中需要关注的重点任务.当前知识图谱错误检测方法可以分为基于规则的方法和基于知识表示学习的方法,前者能够挖掘出无法匹配先验规则的错误知识,而后者通过对三元组的打分来评估每个三元组是否属于错误知识. CAGED 模型^[221]将每个三元组视为一个节点,从而将知识图谱扩展为超视图,并通过知识表示学习和对比学习联合训练,进而评估每个三元组的可信度用于检测出错误知识. Belth 等人^[242]提出了一组图形模式的软规则,由此设计的模型规定了实体之间关系的归纳规则,以识别不满足这些规则的各种错误知识. HEAR 模型^[243]利用三元组中实体对间的路径信息来评估三元组的正确性.考虑到知识图谱错误检测任务需要准确剔除错误知识,而当前的方法在检测过程中仅利用了已有知识而无法保证检测精度,通过人工介入和外部知识能够有助于更准确地检测出错误知识,因此人在环增强的方法与结合多模态信息的方法是值得进一步探索的知识图谱错误检测研究方向.

5.4 具有可解释性的知识图谱推理

当前,知识图谱推理的可解释性主要依靠基于规则学习的方法和多步知识图谱推理方法,通过具有符号特性的逻辑规则^[244]和路径信息^[245]来说明推理的可解释性.然而,这两类方法相比于基于知识表示学习的方法泛化性明显不足.因此,联合符号主义的逻辑规则和连接主义的知识表示学习,采用神经-符号知识图谱推理框架,以兼顾知识图谱推理的可解释性和泛化性是一个值得深入探索的研究方向.此外,就笔者所知,已有的时序规则学习方法包括 StreamLearner^[246]、TLogic^[247]、LCGE^[114]和 TLIP^[248]均只考虑了几类简单的时序模式,其中 StreamLearner 只能生成规则体中所有原子属于同一时间的时序规则, TLogic、LCGE 和 TLIP 在 StreamLearner 的基础上扩展了多种规则模式,考虑了规则体中的原子在时间上非递减的规则模式.然而,当前时序规则方法在挖掘出时序规则的多样化程度和规则搜索效率方面都相比于传统的规则学习方法存在较大差距.因此,亟需能够表示事件间更复杂时序模式的时序规则学习算法,以充分建模事件间的时序性,进而提高时序知识图谱推理的准确性和可解释性.此外,评价知识图谱推理的可解释性是一个值得探索的研究方向, Xu 等人^[249]提出了一个以人为本的评估平台,用于评估知识图谱推理中给出解释的可信度.然而,关于知识图谱推理可解释性评估的研究较为匮乏,缺乏更加标准的可解释性度量指标和方法.

5.5 结合知识图谱推理与大模型

近年来兴起的大模型技术已经在很多领域展示出优秀的推理能力,例如思维链 (CoT) 技术,然而这种方法从已有知识和推理过程两个角度都缺乏可解释性.因此,结合知识图谱推理与大模型的研究逐渐成为研究热点.当前,结合知识图谱推理和大模型的研究主要包括以下几类: (1) 利用大模型的单步推理: KG-GPT^[250]利用大模型来检索相关知识图谱子图,并从中得到推理结果. MPIKGC^[251]利用大模型的推理、解释和总结能力,分别扩展实体描述、理解关系和提取子图结构来提升知识图谱推理的性能. (2) 利用大模型的复杂逻辑推理: LARK^[252]分别利用图抽取算法和大模型将复杂的知识图谱推理表述为知识图谱上下文搜索和逻辑查询推理的结合. (3) 利用大模型的规则学习: ChatRule^[253]设计了基于 LLM 的规则生成器,从知识图谱的语义和结构信息中生成逻辑规则. (4) 利用大模型的多步推理: Nguyen 等人^[106]探讨了 LLM 在逐步推理中的 CoT 推理能力,通过提出的判别和生成 CoT 评估范式,用于评估 LLM 推理新知识和生成 CoT 的准确性. (5) 利用大模型的时序推理: LLM-DA^[254]利用 LLM 来分析历史数据并提取时序逻辑规则,进而用这些规则进行时序知识图谱推理. Xia 等人^[255]和 Luo 等人^[256]均利用大模型 CoT 的推理能力,基于高阶历史信息逐步进行推理,将时序知识图谱推理视为沿历史信息对 LLM 进行微调和生成推理结果的双重过程.此外,借助大模型的复杂推理能力和蕴含的隐式知识,面向单一和复杂任务的各类知识图谱推理、稀疏知识图谱推理和知识图谱错误检测等研究方向,大模型都将有望提升知识图谱推理的性能.

6 总 结

知识图谱推理是实现认知智能的关键技术之一,本文将知识图谱推理领域研究按照面向单一和复杂任务分别进行了总结和归纳,并分析了这些任务间的关联,其中单一任务包括单步知识图谱推理、多步知识图谱推理、时序知识图谱推理、多模态知识图谱推理、小样本知识图谱推理和归纳式知识图谱推理,复杂任务包括时序多步知识图谱推理、小样本多步知识图谱推理、小样本时序知识图谱推理、小样本多模态知识图谱推理、多模态归纳

式知识图谱推理和时序归纳式知识图谱推理. 本文对每类推理任务中的相关代表性方法和前沿工作进行了梳理、总结和分析, 同时对比了不同方法之间的优缺点. 此外, 从已有知识的角度和推理未知知识的角度讨论了知识图谱推理领域仍存在的挑战, 并展望了值得进一步深入探索的发展方向.

References

- [1] Hogan A, Blomqvist E, Cochez M, D'amato C, de Melo G, Gutierrez C, Kirrane S, Gayo JEL, Navigli R, Neumaier S, Ngomo ACN, Polleres A, Rashid SM, Rula A, Schmelzeisen L, Sequeda J, Staab S, Zimmermann A. Knowledge graphs. *ACM Computing Surveys*, 2022, 54(4): 71. [doi: [10.1145/3447772](https://doi.org/10.1145/3447772)]
- [2] Ji SX, Pan SR, Cambria E, Martinen P, Yu PS. A survey on knowledge graphs: Representation, acquisition, and applications. *IEEE Trans. on Neural Networks and Learning Systems*, 2022, 33(2): 494–514. [doi: [10.1109/TNNLS.2021.3070843](https://doi.org/10.1109/TNNLS.2021.3070843)]
- [3] Bollacker K, Evans C, Paritosh P, Sturge T, Taylor J. Freebase: A collaboratively created graph database for structuring human knowledge. In: *Proc. of the 2008 ACM SIGMOD Int'l Conf. on Management of Data*. Vancouver: ACM, 2008. 1247–1250. [doi: [10.1145/1376616.1376746](https://doi.org/10.1145/1376616.1376746)]
- [4] Suchanek FM, Kasneci G, Weikum G. YAGO: A core of semantic knowledge. In: *Proc. of the 16th Int'l Conf. on World Wide Web*. Banff: ACM, 2007. 697–706. [doi: [10.1145/1242572.1242667](https://doi.org/10.1145/1242572.1242667)]
- [5] Miller GA. WordNet: A lexical database for English. *Communications of the ACM*, 1995, 38(11): 39–41. [doi: [10.1145/219717.219748](https://doi.org/10.1145/219717.219748)]
- [6] Carlson A, Betteridge J, Kisiel B, Settles B, Hruschka ER Jr, Mitchell TM. Toward an architecture for never-ending language learning. In: *Proc. of the 24th AAAI Conf. on Artificial Intelligence*. Atlanta: AAAI, 2010. 1306–1313. [doi: [10.1609/aaai.v24i1.7519](https://doi.org/10.1609/aaai.v24i1.7519)]
- [7] Lehmann J, Isele R, Jakob M, Jentzsch A, Kontokostas D, Mendes PN, Hellmann S, Morsey M, van Kleef P, Auer S, Bizer C. DBpedia—A large-scale, multilingual knowledge base extracted from Wikipedia. *Semantic Web*, 2015, 6(2): 167–195. [doi: [10.3233/SW-140134](https://doi.org/10.3233/SW-140134)]
- [8] Zhang NY, Deng SM, Sun ZL, Wang GY, Chen X, Zhang W, Chen JH. Long-tail relation extraction via knowledge graph embeddings and graph convolution networks. In: *Proc. of the 9th Conf. of American Chapter of the Association for Computational Linguistics: Human Language Technologies (Vol. 1: Long and Short Papers)*. Minneapolis: ACL, 2019. 3016–3025. [doi: [10.18653/v1/N19-1306](https://doi.org/10.18653/v1/N19-1306)]
- [9] Berant J, Liang P. Semantic parsing via paraphrasing. In: *Proc. of the 52nd Annual Meeting of the Association for Computational Linguistics*. Baltimore: ACL, 2014. 1415–1425. [doi: [10.3115/v1/P14-1133](https://doi.org/10.3115/v1/P14-1133)]
- [10] Zhou H, Young T, Huang ML, Zhao HZ, Xu JF, Zhu XY. Commonsense knowledge aware conversation generation with graph attention. In: *Proc. of the 27th Int'l Joint Conf. on Artificial Intelligence*. Stockholm: ijcai.org, 2018. 4623–4629. [doi: [10.24963/ijcai.2018/643](https://doi.org/10.24963/ijcai.2018/643)]
- [11] Lin BY, Chen XY, Chen JM, Ren X. KagNet: Knowledge-aware graph networks for commonsense reasoning. In: *Proc. of the 2019 Conf. on Empirical Methods in Natural Language Processing and the 9th Int'l Joint Conf. on Natural Language Processing (EMNLP-IJCNLP)*. Hong Kong: ACL, 2019. 2829–2839. [doi: [10.18653/v1/D19-1282](https://doi.org/10.18653/v1/D19-1282)]
- [12] Wang X, Wang DX, Xu CR, He XN, Cao YX, Chua TS. Explainable reasoning over knowledge graphs for recommendation. In: *Proc. of the 33rd AAAI Conf. on Artificial Intelligence*. Honolulu: AAAI, 2019. 5329–5336. [doi: [10.1609/aaai.v33i01.33015329](https://doi.org/10.1609/aaai.v33i01.33015329)]
- [13] Wang S, Du ZJ, Meng XF. Research progress of large-scale knowledge graph completion technology. *Scientia Sinica Informationis*, 2020, 50(4): 551–575 (in Chinese with English abstract). [doi: [10.1360/N112018-00225](https://doi.org/10.1360/N112018-00225)]
- [14] West R, Gabrilovich E, Murphy K, Sun SH, Gupta R, Lin DK. Knowledge base completion via search-based question answering. In: *Proc. of the 23rd Int'l Conf. on World Wide Web*. Seoul: ACM, 2014. 515–526. [doi: [10.1145/2566486.2568032](https://doi.org/10.1145/2566486.2568032)]
- [15] Krompaß D, Baier S, Tresp V. Type-constrained representation learning in knowledge graphs. In: *Proc. of the 14th Int'l Semantic Web Conf. on the Semantic Web (ISWC 2015)*. Bethlehem: Springer, 2015. 640–655. [doi: [10.1007/978-3-319-25007-6_37](https://doi.org/10.1007/978-3-319-25007-6_37)]
- [16] Guan SP, Jin XL, Jia YT, Wang YZ, Cheng XQ. Knowledge reasoning over knowledge graph: A survey. *Ruan Jian Xue Bao/Journal of Software*, 2018, 29(10): 2966–2994 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/5551.htm> [doi: [10.13328/j.cnki.jos.005551](https://doi.org/10.13328/j.cnki.jos.005551)]
- [17] Qiu R, Zhu ZH. Application of knowledge map in public safety. *Computer Knowledge and Technology*, 2018, 14(35): 196–199 (in Chinese with English abstract). [doi: [10.14004/j.cnki.ckt.2018.4167](https://doi.org/10.14004/j.cnki.ckt.2018.4167)]
- [18] Weng HT, Wang N, Qiu R, Li C. Theoretical study on the combination of knowledge inference and public security based on knowledge graph. *Electronic Test*, 2018(18): 132–133. (in Chinese with English abstract). [doi: [10.3969/j.issn.1000-8519.2018.18.068](https://doi.org/10.3969/j.issn.1000-8519.2018.18.068)]
- [19] Zeng XX, Song X, Ma TF, Pan XQ, Zhou YD, Hou Y, Zhang Z, Li KL, Karypis G, Cheng FX. Repurpose open data to discover therapeutics for COVID-19 using deep learning. *Journal of Proteome Research*, 2020, 19(11): 4624–4636. [doi: [10.1021/acs.jproteome](https://doi.org/10.1021/acs.jproteome)]

- 0c00316]
- [20] Ma HB. Research on construction and application of knowledge graph of enterprise related information for risk control [MS. Thesis]. Beijing: Beijing University of Technology, 2019 (in Chinese with English abstract). [doi: [10.26935/d.cnki.gbjgu.2019.000232](https://doi.org/10.26935/d.cnki.gbjgu.2019.000232)]
 - [21] Ma WZ, Zhang M, Cao Y, Jin W, Wang CY, Liu YQ, Ma SP, Ren X. Jointly learning explainable rules for recommendation with knowledge graph. In: Proc. of the 26th Int'l Conf. on World Wide Web. San Francisco: ACM, 2019. 1210–1221. [doi: [10.1145/3308558.3313607](https://doi.org/10.1145/3308558.3313607)]
 - [22] Zhou MT, Huang ML, Zhu XY. An interpretable reasoning network for multi-relation question answering. In: Proc. of the 27th Int'l Conf. on Computational Linguistics. Santa Fe: ACL, 2018. 2010–2022. [doi: [10.18653/v1/C18-1170](https://doi.org/10.18653/v1/C18-1170)]
 - [23] Hong WX, Hu ZQ, Weng Y, Zhang H, Wang Z, Guo ZX. Automated knowledge graph construction for judicial case facts. Journal of Chinese Information Processing, 2020, 34(1): 34–44 (in Chinese with English abstract). [doi: [10.3969/j.issn.1003-0077.2020.01.005](https://doi.org/10.3969/j.issn.1003-0077.2020.01.005)]
 - [24] Ma A, Yu YH, Yang SL, Shi C, Li J, Cai XX. Survey of knowledge graph based on reinforcement learning. Journal of Computer Research and Development, 2022, 59(8): 1694–1722 (in Chinese with English abstract). [doi: [10.7544/j.issn1000-1239.20211264](https://doi.org/10.7544/j.issn1000-1239.20211264)]
 - [25] Wu Y, Sun HC. An overview of research on knowledge graph completion based on graph neural network. Data Analysis and Knowledge Discovery, 2024, 8(3): 10–28 (in Chinese with English abstract). [doi: [10.11925/infotech.2096-3467.2023.0753](https://doi.org/10.11925/infotech.2096-3467.2023.0753)]
 - [26] Sun SF, Li XL, Li WS, Lei DJ, Li SH, Yang L, Wu YR. Review of graph neural networks applied to knowledge graph reasoning. Journal of Frontiers of Computer Science and Technology, 2023, 17(1): 27–52 (in Chinese with English abstract). [doi: [10.3778/j.issn.1673-9418.2207060](https://doi.org/10.3778/j.issn.1673-9418.2207060)]
 - [27] Liu HB, Chen Y, Lu JC, Hou XM, Yang KW. Survey on rule mining for knowledge graph. Computer Engineering and Applications, 2023, 59(14): 30–38 (in Chinese with English abstract). [doi: [10.3778/j.issn.1002-8331.2210-0014](https://doi.org/10.3778/j.issn.1002-8331.2210-0014)]
 - [28] Yang DW, Zhou G, Lu JC, Ning YL. Review of knowledge graph completion based on knowledge representation learning. Journal of Information Engineering University, 2021, 22(5): 558–565 (in Chinese with English abstract). [doi: [10.3969/j.issn.1671-0673.2021.05.007](https://doi.org/10.3969/j.issn.1671-0673.2021.05.007)]
 - [29] Du XY, Liu MW, Shen LW, Peng X. Survey on representation learning methods of knowledge graph for link prediction. Ruan Jian Xue Bao/Journal of Software, 2024, 35(1): 87–117 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6902.htm> [doi: [10.13328/j.cnki.jos.006902](https://doi.org/10.13328/j.cnki.jos.006902)]
 - [30] Weng JT, Qiu J, Zhang GH. The representation learning method of a knowledge graph for reasoning: A review. Journal of Guangzhou University (Natural Science Edition), 2021, 20(3): 80–89 (in Chinese with English abstract). [doi: [10.3969/j.issn.1671-4229.2021.03.008](https://doi.org/10.3969/j.issn.1671-4229.2021.03.008)]
 - [31] Feng HJ, Duan L, Zhang BY. Overview on knowledge reasoning for knowledge graph. Computer Systems & Applications, 2021, 30(10): 21–30 (in Chinese with English abstract). [doi: [10.15888/j.cnki.csa.008137](https://doi.org/10.15888/j.cnki.csa.008137)]
 - [32] Shen QH, Zhang HJ, Xu YW, Wang H, Cheng K. Comprehensive survey of loss functions in knowledge graph embedding models. Computer Science, 2023, 50(4): 149–158 (in Chinese with English abstract). [doi: [10.11896/jsjx.211200175](https://doi.org/10.11896/jsjx.211200175)]
 - [33] Zhang TC, Tian X, Sun XH, Yu MH, Sun YH, Yu G. Overview on knowledge graph embedding technology research. Ruan Jian Xue Bao/Journal of Software, 2023, 34(1): 277–311 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6429.htm> [doi: [10.13328/j.cnki.jos.006429](https://doi.org/10.13328/j.cnki.jos.006429)]
 - [34] Ma RX, Li ZY, Chen ZK, Zhao L. Review of reasoning on knowledge graph. Computer Science, 2022, 49(S1): 74–85 (in Chinese with English abstract). [doi: [10.11896/jsjx.210100122](https://doi.org/10.11896/jsjx.210100122)]
 - [35] Wang CL, Wang X, Liu K. Multimodal knowledge graph representation learning: A review. Journal of Computer Applications, 2024, 44(1): 1–15 (in Chinese with English abstract). [doi: [10.11772/j.issn.1001-9081.2023050583](https://doi.org/10.11772/j.issn.1001-9081.2023050583)]
 - [36] Shen YH, Jiang XH, Wang YZ, Li ZX, Li ZJ, Tan HX, Shen HW. A survey of temporal knowledge graph reasoning. Chinese Journal of Computers, 2023, 46(6): 1272–1301 (in Chinese with English abstract). [doi: [10.11897/SP.J.1016.2023.01272](https://doi.org/10.11897/SP.J.1016.2023.01272)]
 - [37] Xiao L, Li Q. Survey of temporal knowledge graph completion methods. Computer Engineering and Applications, 2024, 60(6): 43–54 (in Chinese with English abstract). [doi: [10.3778/j.issn.1002-8331.2307-0083](https://doi.org/10.3778/j.issn.1002-8331.2307-0083)]
 - [38] Liang XY, Si GN, Li JX, Tian PX, An ZL, Zhou FY. Survey on inductive learning for knowledge graph completion. Journal of Frontiers of Computer Science and Technology, 2023, 17(11): 2580–2604 (in Chinese with English abstract). [doi: [10.3778/j.issn.1673-9418.2303063](https://doi.org/10.3778/j.issn.1673-9418.2303063)]
 - [39] Liang K, Meng LY, Liu M, Liu Y, Tu WX, Wang SW, Zhou SH, Liu XW, Sun FC, He KL. A survey of knowledge graph reasoning on graph types: Static, dynamic, and multi-modal. IEEE Trans. on Pattern Analysis and Machine Intelligence, 2024, 46(12): 9456–9478. [doi: [10.1109/TPAMI.2024.3417451](https://doi.org/10.1109/TPAMI.2024.3417451)]
 - [40] Cai BR, Xiang Y, Gao LX, Zhang H, Li YF, Li JX. Temporal knowledge graph completion: A survey. In: Proc. of the 32nd Int'l Joint

- Conf. on Artificial Intelligence. Macao: 2023. 734. [doi: [10.24963/ijcai.2023/734](https://doi.org/10.24963/ijcai.2023/734)]
- [41] Liang WY, de Meo P, Tang Y, Zhu J. A survey of multi-modal knowledge graphs: Technologies and trends. *ACM Computing Surveys*, 2024, 56(11): 273. [doi: [10.1145/3656579](https://doi.org/10.1145/3656579)]
 - [42] Zhu XR, Li ZX, Wang XD, Jiang XY, Sun PL, Wang XW, Xiao YH, Yuan NJ. Multi-modal knowledge graph construction and application: A survey. *IEEE Trans. on Knowledge and Data Engineering*, 2024, 36(2): 715–735. [doi: [10.1109/TKDE.2022.3224228](https://doi.org/10.1109/TKDE.2022.3224228)]
 - [43] Hou ZN, Jin XL, Chen JY, Guan SP, Wang YZ, Cheng XQ. Survey of interpretable reasoning on knowledge graphs. *Ruan Jian Xue Bao/Journal of Software*, 2022, 33(12): 4644–4667 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6522.htm> [doi: [10.13328/j.cnki.jos.006522](https://doi.org/10.13328/j.cnki.jos.006522)]
 - [44] Wang YH, Chen ZY, Zhao X, Tan Z, Xiao WD, Cheng XQ. Research progress and trend of temporal knowledge graph representation and reasoning. *Ruan Jian Xue Bao/Journal of Software*, 2024, 35(8): 3923–3951 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/7093.htm> [doi: [10.13328/j.cnki.jos.007093](https://doi.org/10.13328/j.cnki.jos.007093)]
 - [45] Peng YF, Zhang RS, Wang RH, Guo JL. Survey on few-shot knowledge graph completion technology. *Journal of Frontiers of Computer Science and Technology*, 2023, 17(6): 1268–1284 (in Chinese with English abstract). [doi: [10.3778/j.issn.1673-9418.2209069](https://doi.org/10.3778/j.issn.1673-9418.2209069)]
 - [46] Han Z, Chen P, Ma YP, Tresp V. Explainable subgraph reasoning for forecasting on temporal knowledge graphs. In: *Proc. of the 9th Int'l Conf. on Learning Representations*. OpenReview.net, 2021.
 - [47] Lv X, Gu YX, Han X, Hou LJ, Li J, Liu ZY. Adapting meta knowledge graph information for multi-hop reasoning over few-shot relations. In: *Proc. of the 2019 Conf. on Empirical Methods in Natural Language Processing and the 9th Int'l Joint Conf. on Natural Language Processing (EMNLP-IJCNLP)*. Hong Kong: ACL, 2019. 3376–3381. [doi: [10.18653/v1/D19-1334](https://doi.org/10.18653/v1/D19-1334)]
 - [48] Zhu L, Bai LY, Han S, Zhang MC. Few-shot temporal knowledge graph completion based on meta-optimization. *Complex & Intelligent Systems*, 2023, 9(6): 7461–7474. [doi: [10.1007/s40747-023-01146-9](https://doi.org/10.1007/s40747-023-01146-9)]
 - [49] Wang ZH, Lai K, Li PJ, Bing LD, Lam W. Tackling long-tailed relations and uncommon entities in knowledge graph completion. In: *Proc. of the 2019 Conf. on Empirical Methods in Natural Language Processing and the 9th Int'l Joint Conf. on Natural Language Processing (EMNLP-IJCNLP)*. Hong Kong: ACL, 2019. 250–260. [doi: [10.18653/v1/D19-1024](https://doi.org/10.18653/v1/D19-1024)]
 - [50] Shah H, Villmow J, Ulges A, Schwanecke U, Shafait F. An open-world extension to knowledge graph completion models. In: *Proc. of the 33rd AAAI Conf. on Artificial Intelligence*. Honolulu: AAAI, 2019. 3044–3051. [doi: [10.1609/aaai.v33i01.33013044](https://doi.org/10.1609/aaai.v33i01.33013044)]
 - [51] Sun HH, Zhong JL, Ma YP, Han Z, He K. TimeTraveler: Reinforcement learning for temporal knowledge graph forecasting. In: *Proc. of the 2021 Conf. on Empirical Methods in Natural Language Processing*. Punta Cana: ACL, 2021. 8306–8319. [doi: [10.18653/v1/2021.emnlp-main.655](https://doi.org/10.18653/v1/2021.emnlp-main.655)]
 - [52] Liu SX, Li WJ, Liu XY, Ding JP, Su YL, Li HN. Review of reinforcement learning based knowledge graph reasoning research. *Application Research of Computers*, 2024, 41(9): 2561–2572 (in Chinese with English abstract). [doi: [10.19734/j.issn.1001-3695.2023.11.0583](https://doi.org/10.19734/j.issn.1001-3695.2023.11.0583)]
 - [53] Li ZF, Zhao Y, Zhang Y. Survey of knowledge graph reasoning based on representation learning. *Computer Science*, 2023, 50(3): 94–113 (in Chinese with English abstract). [doi: [10.11896/jsjx.220900136](https://doi.org/10.11896/jsjx.220900136)]
 - [54] Cao JH, Fang JY, Meng ZQ, Liang SS. Knowledge graph embedding: A survey from the perspective of representation spaces. *ACM Computing Surveys*, 2024, 56(6): 159. [doi: [10.1145/3643806](https://doi.org/10.1145/3643806)]
 - [55] Liu XL, Mao TY, Shi YY, Ren YZ. Overview of knowledge reasoning for knowledge graph. *Neurocomputing*, 2024, 585: 127571. [doi: [10.1016/j.neucom.2024.127571](https://doi.org/10.1016/j.neucom.2024.127571)]
 - [56] Chen MY, Zhang W, Geng YX, Xu ZZ, Pan JZ, Chen HJ. Generalizing to unseen elements: A survey on knowledge extrapolation for knowledge graphs. In: *Proc. of the 32nd Int'l Joint Conf. on Artificial Intelligence*. Macao: ijcai.org, 2023. 737. [doi: [10.24963/ijcai.2023/737](https://doi.org/10.24963/ijcai.2023/737)]
 - [57] Hubert N, Monnin P, Paulheim H. Beyond transduction: A survey on inductive, few shot, and zero shot link prediction in knowledge graphs. *arXiv:2312.04997*, 2023.
 - [58] Yan Q, Fan JX, Li MH, Qu GQ, Xiao Y. A survey on knowledge graph embedding. In: *Proc. of the 7th IEEE Int'l Conf. on Data Science in Cyberspace (DSC)*. Guilin IEEE, 2022. 576–583. [doi: [10.1109/DSC55868.2022.00086](https://doi.org/10.1109/DSC55868.2022.00086)]
 - [59] Shen T, Zhang F, Cheng JQ. A comprehensive overview of knowledge graph completion. *Knowledge-based Systems*, 2022, 255: 109597. [doi: [10.1016/j.knosys.2022.109597](https://doi.org/10.1016/j.knosys.2022.109597)]
 - [60] Sun ZQ, Vashishth S, Sanyal S, Talukdar P, Yang YM. A re-evaluation of knowledge graph completion methods. In: *Proc. of the 58th Annual Meeting of the Association for Computational Linguistics*. ACL, 2020. 5516–5522. [doi: [10.18653/v1/2020.acl-main.489](https://doi.org/10.18653/v1/2020.acl-main.489)]
 - [61] Akrami F, Saeef MS, Zhang QH, Hu W, Li CK. Realistic re-evaluation of knowledge graph completion methods: An experimental study. In: *Proc. of the 2020 ACM SIGMOD Int'l Conf. on Management of Data*. Portland: ACM, 2020. 1995–2010. [doi: [10.1145/3643806](https://doi.org/10.1145/3643806)]

- 3318464.3380599]
- [62] Bordes A, Usunier N, Garcia-Durán A, Weston J, Yakhnenko O. Translating embeddings for modeling multi-relational data. In: Proc. of the 27th Int'l Conf. on Neural Information Processing Systems—Vol. 2. Lake Tahoe: Curran Associates Inc., 2013. 2787–2795. [doi: [10.5555/2999792.2999923](https://doi.org/10.5555/2999792.2999923)]
 - [63] Mikolov T, Chen K, Corrado G, Dean J. Efficient estimation of word representations in vector space. arXiv:1301.3781, 2013.
 - [64] Wang Z, Zhang JW, Feng JL, Chen Z. Knowledge graph embedding by translating on hyperplanes. In: Proc. of the 28th AAAI Conf. on Artificial Intelligence. Québec City: AAAI Press, 2014. 1112–1119. [doi: [10.1609/aaai.v28i1.8870](https://doi.org/10.1609/aaai.v28i1.8870)]
 - [65] Lin YK, Liu ZY, Sun MS, Liu Y, Zhu X. Learning entity and relation embeddings for knowledge graph completion. In: Proc. of the 29th AAAI Conf. on Artificial Intelligence. Austin: AAAI, 2015. 2181–2187. [doi: [10.1609/aaai.v29i1.9491](https://doi.org/10.1609/aaai.v29i1.9491)]
 - [66] Ji GL, He SZ, Xu LH, Liu K, Zhao J. Knowledge graph embedding via dynamic mapping matrix. In: Proc. of the 53rd Annual Meeting of the Association for Computational Linguistics. Beijing: ACL, 2015. 687–696. [doi: [10.3115/v1/P15-1067](https://doi.org/10.3115/v1/P15-1067)]
 - [67] Sun ZQ, Deng ZH, Nie JY, Tang J. RotatE: Knowledge graph embedding by relational rotation in complex space. In: Proc. of the 7th Int'l Conf. on Learning Representations. New Orleans: OpenReview.net, 2019. 1–18.
 - [68] Zhang S, Tay Y, Yao LN, Liu Q. Quaternion knowledge graph embeddings. In: Proc. of the 33rd Int'l Conf. on Neural Information Processing Systems. Vancouver: Curran Associates Inc., 2019. 246. [doi: [10.5555/3454287.3454533](https://doi.org/10.5555/3454287.3454533)]
 - [69] Chao LL, He JS, Wang TF, Chu W. PairRE: Knowledge graph embeddings via paired relation vectors. In: Proc. of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th Int'l Joint Conf. on Natural Language Processing. ACL, 2021. 4360–4369. [doi: [10.18653/v1/2021.acl-long.336](https://doi.org/10.18653/v1/2021.acl-long.336)]
 - [70] Xiao H, Huang ML, Hao Y, Zhu XY. TransA: An adaptive approach for knowledge graph embedding. arXiv:1509.05490, 2015.
 - [71] Yang BS, Yih WT, He XD, Gao JF, Deng L. Embedding entities and relations for learning and inference in knowledge bases. In: Proc. of the 3rd Int'l Conf. on Learning Representations. San Diego, 2015.
 - [72] Nickel M, Rosasco L, Poggio T. Holographic embeddings of knowledge graphs. In: Proc. of the 30th AAAI Conf. on Artificial Intelligence. Phoenix: AAAI, 2016. 1955–1961. [doi: [10.1609/aaai.v30i1.10314](https://doi.org/10.1609/aaai.v30i1.10314)]
 - [73] Trouillon T, Welbl J, Riedel S, Gaussier É, Bouchard G. Complex embeddings for simple link prediction. In: Proc. of the 33rd Int'l Conf. on Machine Learning. New York: JMLR, 2016. 2071–2080. [doi: [10.5555/3045390.3045609](https://doi.org/10.5555/3045390.3045609)]
 - [74] Dettmers T, Minervini P, Stenetorp P, Riedel S. Convolutional 2D knowledge graph embeddings. In: Proc. of the 32nd AAAI Conf. on Artificial Intelligence. New Orleans: AAAI, 2018. 1811–1818. [doi: [10.1609/aaai.v32i1.11573](https://doi.org/10.1609/aaai.v32i1.11573)]
 - [75] Schlichtkrull M, Kipf TN, Bloem P, van den Berg R, Titov I, Welling M. Modeling relational data with graph convolutional networks. In: Proc. of the 15th Int'l Conf. on The Semantic Web. Heraklion: Springer, 2018. 593–607. [doi: [10.1007/978-3-319-93417-4_38](https://doi.org/10.1007/978-3-319-93417-4_38)]
 - [76] Wang L, Zhao W, Wei ZY, Liu JM. SimKGC: Simple contrastive knowledge graph completion with pre-trained language models. In: Proc. of the 60th Annual Meeting of the Association for Computational Linguistics (Vol. 1: Long Papers). Dublin: ACL, 2022. 4281–4294. [doi: [10.18653/v1/2022.acl-long.295](https://doi.org/10.18653/v1/2022.acl-long.295)]
 - [77] Yao L, Mao CS, Luo Y. KG-BERT: BERT for knowledge graph completion. arXiv:1909.03193, 2019.
 - [78] Galárraga L, Teflioudi C, Hose K, Suchanek FM. Fast rule mining in ontological knowledge bases with AMIE+. The VLDB Journal, 2015, 24(6): 707–730. [doi: [10.1007/s00778-015-0394-1](https://doi.org/10.1007/s00778-015-0394-1)]
 - [79] Chen Y, Wang DZ, Goldberg S. ScaLeKB: Scalable learning and inference over large knowledge bases. The VLDB Journal, 2016, 25(6): 893–918. [doi: [10.1007/s00778-016-0444-3](https://doi.org/10.1007/s00778-016-0444-3)]
 - [80] Wang ZC, Li JZ. RDF2Rules: Learning rules from RDF knowledge bases by mining frequent predicate cycles. arXiv:1512.07734, 2015.
 - [81] Barati M, Bai Q, Liu Q. SWARM: An approach for mining semantic association rules from semantic Web data. In: Proc. of the 14th Pacific Rim Int'l Conf. on Artificial Intelligence. Phuket: Springer, 2016. 30–43. [doi: [10.1007/978-3-319-42911-3_3](https://doi.org/10.1007/978-3-319-42911-3_3)]
 - [82] Ortona S, Meduri VV, Papotti P. RuDiK: Rule discovery in knowledge bases. Proc. of the VLDB Endowment, 2018, 11(12): 1946–1949. [doi: [10.14778/3229863.3236231](https://doi.org/10.14778/3229863.3236231)]
 - [83] Ho VT, Stepanova D, Gad-Elrab MH, Kharlamov E, Weikum G. Rule learning from knowledge graphs guided by embedding models. In: Proc. of the 17th Int'l Semantic Web Conf. on the Semantic Web (ISWC 2018). Monterey: Springer, 2018. 72–90. [doi: [10.1007/978-3-030-00671-6_5](https://doi.org/10.1007/978-3-030-00671-6_5)]
 - [84] Wu LL, Sallinger E, Sherkhonov E, Vahdati S, Gottlob G. Rule learning over knowledge graphs with genetic logic programming. In: Proc. of the 38th IEEE Int'l Conf. on Data Engineering (ICDE). Kuala Lumpur: IEEE, 2022. 3373–3385. [doi: [10.1109/ICDE53745.2022.00318](https://doi.org/10.1109/ICDE53745.2022.00318)]
 - [85] Ceri S, Gottlob G, Tanca L. What you always wanted to know about Datalog (and never dared to ask). IEEE Trans. on Knowledge and Data Engineering, 1989, 1(1): 146–166. [doi: [10.1109/69.43410](https://doi.org/10.1109/69.43410)]

- [86] Yang F, Yang ZL, Cohen WW. Differentiable learning of logical rules for knowledge base reasoning. In: Proc. of the 31st Int'l Conf. on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017. 2316–2325. [doi: [10.5555/3294771.3294992](https://doi.org/10.5555/3294771.3294992)]
- [87] Sadeghian A, Armandpour M, Ding P, Wang DZ. DRUM: End-to-end differentiable rule mining on knowledge graphs. In: Proc. of the 33rd Int'l Conf. on Neural Information Processing Systems. Vancouver: Curran Associates Inc., 2019. 1375. [doi: [10.5555/3454287.3455662](https://doi.org/10.5555/3454287.3455662)]
- [88] Omran PG, Wang KW, Wang Z. An embedding-based approach to rule learning in knowledge graphs. IEEE Trans. on Knowledge and Data Engineering, 2021, 33(4): 1348–1359. [doi: [10.1109/TKDE.2019.2941685](https://doi.org/10.1109/TKDE.2019.2941685)]
- [89] Qu M, Chen JK, Xhonneux LP, Bengio Y, Tang J. RNNLogic: Learning logic rules for reasoning on knowledge graphs. In: Proc. of the 9th Int'l Conf. on Learning Representations. OpenReview.net, 2021.
- [90] Xu ZZ, Ye P, Chen H, Zhao M, Chen HJ, Zhang W. Ruleformer: Context-aware rule mining over knowledge graph. In: Proc. of the 29th Int'l Conf. on Computational Linguistics. Gyeongju: Int'l Committee on Computational Linguistics, 2022. 2551–2560.
- [91] Lao N, Cohen WW. Relational retrieval using a combination of path-constrained random walks. Machine Learning, 2010, 81(1): 53–67. [doi: [10.1007/s10994-010-5205-8](https://doi.org/10.1007/s10994-010-5205-8)]
- [92] Lao N, Mitchell T, Cohen WW. Random walk inference and learning in a large scale knowledge base. In: Proc. of the 2011 Conf. on Empirical Methods in Natural Language Processing. Edinburgh: ACL, 2011. 529–539.
- [93] Gardner M, Talukdar PP, Kisiel B, Mitchell T. Improving learning and inference in a large knowledge-base using latent syntactic cues. In: Proc. of the 2013 Conf. on Empirical Methods in Natural Language Processing. Seattle: ACL, 2013. 833–838.
- [94] Wang Q, Liu J, Luo YF, Wang B, Lin CY. Knowledge base completion via coupled path ranking. In: Proc. of the 54th Annual Meeting of the Association for Computational Linguistics (Vol. 1: Long Papers). Berlin: ACL, 2016. 1308–1318. [doi: [10.18653/v1/P16-1124](https://doi.org/10.18653/v1/P16-1124)]
- [95] Mazumder S, Liu B. Context-aware path ranking for knowledge base completion. In: Proc. of the 26th Int'l Joint Conf. on Artificial Intelligence. Melbourne: AAAI Press, 2017. 1195–1201. [doi: [10.24963/ijcai.2017/166](https://doi.org/10.24963/ijcai.2017/166)]
- [96] Zhu ZC, Yuan XY, Galkin M, Xhonneux S, Zhang M, Gazeau M, Tang J. A*Net: A scalable path-based reasoning approach for knowledge graphs. In: Proc. of the 37th Int'l Conf. on Neural Information Processing Systems. New Orleans: Curran Associates Inc., 2023. 2591. [doi: [10.5555/3666122.3668713](https://doi.org/10.5555/3666122.3668713)]
- [97] Wang HW, Ren HY, Leskovec J. Relational message passing for knowledge graph completion. In: Proc. of the 27th ACM SIGKDD Conf. on Knowledge Discovery & Data Mining. ACM, 2021. 1697–1707. [doi: [10.1145/3447548.3467247](https://doi.org/10.1145/3447548.3467247)]
- [98] Xiong WH, Hoang T, Wang WY. DeepPath: A reinforcement learning method for knowledge graph reasoning. In: Proc. of the 2017 Conf. on Empirical Methods in Natural Language Processing. Copenhagen: ACL, 2017. 564–573. [doi: [10.18653/v1/D17-1060](https://doi.org/10.18653/v1/D17-1060)]
- [99] Das R, Dhuliawala S, Zaheer M, Vilnis L, Durugkar I, Krishnamurthy A, Smola A, McCallum A. Go for a walk and arrive at the answer: Reasoning over paths in knowledge bases using reinforcement learning. In: Proc. of the 6th Int'l Conf. on Learning Representations. Vancouver: OpenReview.net, 2018. 1–18.
- [100] Lin XV, Socher R, Xiong CM. Multi-hop knowledge graph reasoning with reward shaping. In: Proc. of the 2018 Conf. on Empirical Methods in Natural Language Processing. Brussels: ACL, 2018. 3243–3253. [doi: [10.18653/v1/D18-1362](https://doi.org/10.18653/v1/D18-1362)]
- [101] Pan SR, Luo LH, Wang YF, Chen C, Wang JP, Wu XD. Unifying large language models and knowledge graphs: A roadmap. IEEE Trans. on Knowledge and Data Engineering, 2024, 36(7): 3580–3599. [doi: [10.1109/TKDE.2024.3352100](https://doi.org/10.1109/TKDE.2024.3352100)]
- [102] Jiang JH, Zhou K, Dong ZC, Ye KM, Zhao X, Wen JR. StructGPT: A general framework for large language model to reason over structured data. In: Proc. of the 2023 Conf. on Empirical Methods in Natural Language Processing. Singapore: ACL, 2023. 9237–9251. [doi: [10.18653/v1/2023.emnlp-main.574](https://doi.org/10.18653/v1/2023.emnlp-main.574)]
- [103] Feng C, Zhang XY, Fei ZC. Knowledge solver: Teaching LLMs to search for domain knowledge from knowledge graphs. arXiv:2309.03118, 2023.
- [104] Wang KH, Duan FY, Wang SR, Li PG, Xian YS, Yin CT, Rong WG, Xiong Z. Knowledge-driven CoT: Exploring faithful reasoning in LLMs for knowledge-intensive question answering. arXiv:2308.13259, 2023.
- [105] Sun JS, Xu CJ, Tang LMY, Wang SZ, Lin C, Gong YY, Ni LM, Shum HY, Guo J. Think-on-graph: Deep and responsible reasoning of large language model on knowledge graph. In: Proc. of the 12th Int'l Conf. on Learning Representations. Vienna: OpenReview.net, 2024.
- [106] Nguyen MV, Luo LH, Shiri F, Phung D, Li YF, Vu T, Haffari G. Direct evaluation of chain-of-thought in multi-hop reasoning with knowledge graphs. In: Findings of the Association for Computational Linguistics: ACL 2024. Bangkok: ACL, 2024. 2862–2883. [doi: [10.18653/v1/2024.findings-acl.168](https://doi.org/10.18653/v1/2024.findings-acl.168)]
- [107] Jiang JH, Zhou K, Zhao WX, Song Y, Zhu C, Zhu HS, Wen JR. KG-agent: An efficient autonomous agent framework for complex reasoning over knowledge graph. In: Proc. of the 63rd Annual Meeting of the Association for Computational Linguistics (Vol. 1: Long

- Papers). Vienna: ACL, 2025. 9505–9523. [doi: [10.18653/v1/2025.acl-long.468](https://doi.org/10.18653/v1/2025.acl-long.468)]
- [108] Zeng AH, Liu MD, Lu R, Wang BW, Liu X, Dong YX, Tang J. AgentTuning: Enabling generalized agent abilities for LLMs. In: Findings of the Association for Computational Linguistics: ACL 2024. Bangkok: ACL, 2024. 3053–3077. [doi: [10.18653/v1/2024.findings-acl.181](https://doi.org/10.18653/v1/2024.findings-acl.181)]
 - [109] García-Durán A, Dumančić S, Niepert M. Learning sequence encoders for temporal knowledge graph completion. In: Proc. of the 2018 Conf. on Empirical Methods in Natural Language Processing. Brussels: ACL, 2018. 4816–4821. [doi: [10.18653/v1/D18-1516](https://doi.org/10.18653/v1/D18-1516)]
 - [110] Leblay J, Chekol MW. Deriving validity time in knowledge graph. In: Proc. of the 2018 Web Conf. Lyon: Republic and Canton of Geneva, 2018. 1771–1776. [doi: [10.1145/3184558.3191639](https://doi.org/10.1145/3184558.3191639)]
 - [111] Dasgupta SS, Ray SN, Talukdar P. HyTE: Hyperplane-based temporally aware knowledge graph embedding. In: Proc. of the 2018 Conf. on Empirical Methods in Natural Language Processing. Brussels: ACL, 2018. 2001–2011. [doi: [10.18653/v1/D18-1225](https://doi.org/10.18653/v1/D18-1225)]
 - [112] Xu CJ, Nayyeri M, Alkhoury F, Yazdi HS, Lehmann J. TeRo: A time-aware knowledge graph embedding via temporal rotation. In: Proc. of the 28th Int'l Conf. on Computational Linguistics. Barcelona: Int'l Committee on Computational Linguistics, 2020. 1583–1593. [doi: [10.18653/v1/2020.coling-main.139](https://doi.org/10.18653/v1/2020.coling-main.139)]
 - [113] Lacroix T, Obozinski G, Usunier N. Tensor decompositions for temporal knowledge base completion. In: Proc. of the 8th Int'l Conf. on Learning Representations. Addis Ababa: OpenReview.net, 2020.
 - [114] Niu GL, Li B. Logic and commonsense-guided temporal knowledge graph completion. In: Proc. of the 37th AAAI Conf. on Artificial Intelligence. Washington: AAAI, 2023. 4569–4577. [doi: [10.1609/aaai.v37i4.25579](https://doi.org/10.1609/aaai.v37i4.25579)]
 - [115] Trivedi R, Dai HJ, Wang YC, Song L. Know-evolve: Deep temporal reasoning for dynamic knowledge graphs. In: Proc. of the 34th Int'l Conf. on Machine Learning. Sydney: PMLR, 2017. 3462–3471.
 - [116] Jin W, Qu M, Jin XS, Ren X. Recurrent event network: Autoregressive structure inference over temporal knowledge graphs. In: Proc. of the 2020 Conf. on Empirical Methods in Natural Language Processing. ACL, 2020. 6669–6683. [doi: [10.18653/v1/2020.emnlp-main.541](https://doi.org/10.18653/v1/2020.emnlp-main.541)]
 - [117] Pareja A, Domeniconi G, Chen J, Ma TF, Suzumura T, Kanezashi H, Kaler T, Schardl T, Leiserson C. EvolveGCN: Evolving graph convolutional networks for dynamic graphs. In: Proc. of the 34th AAAI Conf. on Artificial Intelligence. New York: AAAI, 2020. 5363–5370. [doi: [10.1609/aaai.v34i04.5984](https://doi.org/10.1609/aaai.v34i04.5984)]
 - [118] Zhu CC, Chen MH, Fan CJ, Cheng GQ, Zhang Y. Learning from history: Modeling temporal knowledge graphs with sequential copy-generation networks. In: Proc. of the 35th AAAI Conf. on Artificial Intelligence. AAAI, 2021. 4732–4740. [doi: [10.1609/aaai.v35i5.16604](https://doi.org/10.1609/aaai.v35i5.16604)]
 - [119] Li ZX, Jin XL, Guan SP, Li W, Guo JF, Wang YZ, Cheng XQ. Search from history and reason for future: Two-stage reasoning on temporal knowledge graphs. In: Proc. of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th Int'l Joint Conf. on Natural Language Processing (Vol. 1: Long Papers). ACL, 2021. 4732–4743. [doi: [10.18653/v1/2021.acl-long.365](https://doi.org/10.18653/v1/2021.acl-long.365)]
 - [120] Xu WJ, Liu B, Peng M, Jia X, Peng M. Pre-trained language model with prompts for temporal knowledge graph completion. In: Findings of the Association for Computational Linguistics: ACL 2023. Toronto: ACL, 2023. 7790–7803. [doi: [10.18653/v1/2023.findings-acl.493](https://doi.org/10.18653/v1/2023.findings-acl.493)]
 - [121] Han Z, Liao RT, Gu JD, Zhang Y, Ding ZF, Gu YJ, Koepl H, Schütze H, Tresp V. ECOLA: Enhancing temporal knowledge embeddings with contextualized language representations. In: Findings of the Association for Computational Linguistics: ACL 2023. Toronto: ACL, 2023. 5433–5447. [doi: [10.18653/v1/2023.findings-acl.335](https://doi.org/10.18653/v1/2023.findings-acl.335)]
 - [122] Gao YF, He YQ, Kan ZG, Han Y, Qiao LB, Li DS. Learning joint structural and temporal contextualized knowledge embeddings for temporal knowledge graph completion. In: Findings of the Association for Computational Linguistics: ACL 2023. Toronto: ACL, 2023. 417–430. [doi: [10.18653/v1/2023.findings-acl.28](https://doi.org/10.18653/v1/2023.findings-acl.28)]
 - [123] Liu WJ, Zhou P, Zhao Z, Wang ZR, Ju Q, Deng HT, Wang P. K-BERT: Enabling language representation with knowledge graph. In: Proc. of the 34th AAAI Conf. on Artificial Intelligence. New York: AAAI, 2020. 2901–2908. [doi: [10.1609/aaai.v34i03.5681](https://doi.org/10.1609/aaai.v34i03.5681)]
 - [124] Lee DH, Ahrabian K, Jin W, Morstatter F, Pujara J. Temporal knowledge graph forecasting without knowledge using in-context learning. In: Proc. of the 2023 Conf. on Empirical Methods in Natural Language Processing. Singapore: ACL, 2023. 544–557. [doi: [10.18653/v1/2023.emnlp-main.36](https://doi.org/10.18653/v1/2023.emnlp-main.36)]
 - [125] Xie RB, Liu ZY, Luan HB, Sun MS. Image-embodied knowledge representation learning. In: Proc. of the 26th Int'l Joint Conf. on Artificial Intelligence. Melbourne: AAAI Press, 2017. 3140–3146. [doi: [10.24963/ijcai.2017/438](https://doi.org/10.24963/ijcai.2017/438)]
 - [126] Pezeshkpour P, Chen LY, Singh S. Embedding multimodal relational data for knowledge base completion. In: Proc. of the 2018 Conf. on Empirical Methods in Natural Language Processing. Brussels: ACL, 2018. 3208–3218. [doi: [10.18653/v1/D18-1359](https://doi.org/10.18653/v1/D18-1359)]
 - [127] Wang M, Wang S, Yang H, Zhang Z, Chen X, Qi GL. Is visual context really helpful for knowledge graph? A representation learning

- perspective. In: Proc. of the 29th ACM Int'l Conf. on Multimedia. ACM, 2021. 2735–2743. [doi: [10.1145/3474085.3475470](https://doi.org/10.1145/3474085.3475470)]
- [128] Cao ZS, Xu QQ, Yang ZY, He Y, Cao XC, Huang QM. OTKGE: Multi-modal knowledge graph embeddings via optimal transport. In: Proc. of the 36th Int'l Conf. on Neural Information Processing Systems. New Orleans: Curran Associates Inc., 2022. 2833. [doi: [10.5555/3600270.3603103](https://doi.org/10.5555/3600270.3603103)]
- [129] Liang S, Zhu AJ, Zhang JS, Shao J. Hyper-node relational graph attention network for multi-modal knowledge graph completion. ACM Trans. on Multimedia Computing, Communications and Applications, 2023, 19(2): 62. [doi: [10.1145/3545573](https://doi.org/10.1145/3545573)]
- [130] Zhao Y, Cai XR, Wu YK, Zhang HW, Zhang Y, Zhao GQ, Jiang N. MoSE: Modality split and ensemble for multimodal knowledge graph completion. In: Proc. of the 2022 Conf. on Empirical Methods in Natural Language Processing. Abu Dhabi: ACL, 2022. 10527–10536. [doi: [10.18653/v1/2022.emnlp-main.719](https://doi.org/10.18653/v1/2022.emnlp-main.719)]
- [131] Xu DR, Xu T, Wu SW, Zhou JB, Chen EH. Relation-enhanced negative sampling for multimodal knowledge graph completion. In: Proc. of the 30th ACM Int'l Conf. on Multimedia. Lisboa: ACM, 2022. 3857–3866. [doi: [10.1145/3503161.3548388](https://doi.org/10.1145/3503161.3548388)]
- [132] Zhang YC, Chen Z, Liang L, Chen HJ, Zhang W. Unleashing the power of imbalanced modality information for multi-modal knowledge graph completion. In: Proc. of the 2024 Joint Int'l Conf. on Computational Linguistics, Language Resources and Evaluation (LREC-COLING 2024). Torino: ELRA, 2024. 17120–17130.
- [133] Zhang YC, Zhang W. Knowledge graph completion with pre-trained multimodal Transformer and twins negative sampling. arXiv:2209.07084, 2022.
- [134] Chen X, Zhang NY, Li L, Deng SM, Tan CQ, Xu CL, Huang F, Si L, Chen HJ. Hybrid Transformer with multi-level fusion for multimodal knowledge graph completion. In: Proc. of the 45th Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. Madrid: ACM, 2022. 904–915. [doi: [10.1145/3477495.3531992](https://doi.org/10.1145/3477495.3531992)]
- [135] Luo KY, Bai YZ, Gao C, Si SZ, Liu Z, Shen YL, Wang ZT, Kong CL, Li WH, Huang YF, Tian Y, Xiong XT, Han L, Sun MS. GLTW: Joint improved graph Transformer and LLM via three-word language for knowledge graph completion. In: Findings of the Association for Computational Linguistics: ACL 2025. Vienna: ACL, 2025. 11328–11344. [doi: [10.18653/v1/2025.findings-acl.591](https://doi.org/10.18653/v1/2025.findings-acl.591)]
- [136] Lin QK, Zhao TZ, He K, Peng Z, Xu FZ, Huang L, Ma JY, Feng ML. Self-supervised quantized representation for seamlessly integrating knowledge graphs with large language models. In: Proc. of the 63rd Annual Meeting of the Association for Computational Linguistics. Vienna: ACL, 2025. 13587–13602. [doi: [10.18653/v1/2025.acl-long.667](https://doi.org/10.18653/v1/2025.acl-long.667)]
- [137] Xiong WH, Yu M, Chang SY, Guo XX, Wang WY. One-shot relational learning for knowledge graphs. In: Proc. of the 2018 Conf. on Empirical Methods in Natural Language Processing. Brussels: ACL, 2018. 1980–1990. [doi: [10.18653/v1/D18-1223](https://doi.org/10.18653/v1/D18-1223)]
- [138] Zhang CX, Yao HX, Huang C, Jiang M, Li ZH, Chawla NV. Few-shot knowledge graph completion. In: Proc. of the 34th AAAI Conf. on Artificial Intelligence. New York: AAAI, 2020. 3041–3048. [doi: [10.1609/aaai.v34i03.5698](https://doi.org/10.1609/aaai.v34i03.5698)]
- [139] Sheng JW, Guo S, Chen ZY, Yue JW, Wang LH, Liu TW, Xu HB. Adaptive attentional network for few-shot knowledge graph completion. In: Proc. of the 2020 Conf. on Empirical Methods in Natural Language Processing (EMNLP 2020). ACL, 2020. 1681–1691. [doi: [10.18653/v1/2020.emnlp-main.131](https://doi.org/10.18653/v1/2020.emnlp-main.131)]
- [140] Liang Y, Zhao S, Cheng B, Yin YW, Yang H. Exploring entity interactions for few-shot relation learning (student abstract). In: Proc. of the 36th AAAI Conf. on Artificial Intelligence. AAAI, 2022. 13003–13004. [doi: [10.1609/aaai.v36i11.21638](https://doi.org/10.1609/aaai.v36i11.21638)]
- [141] Li WJ, Gu JL, Li A, Gao YX, Zhang XY. Few-shot knowledge graph completion model based on relation learning. Applied Sciences, 2023, 13(17): 9513. [doi: [10.3390/app13179513](https://doi.org/10.3390/app13179513)]
- [142] Xiao S, Duan L, Xie GC, Li RH, Chen ZH, Deng G, Nummenmaa J. HMNet: Hybrid matching network for few-shot link prediction. In: Proc. of the 26th Int'l Conf. on Database Systems for Advanced Applications. Taipei: Springer, 2021. 307–322. [doi: [10.1007/978-3-030-73194-6_21](https://doi.org/10.1007/978-3-030-73194-6_21)]
- [143] Jiang ZY, Gao JL, Lv XQ. MetaP: Meta pattern learning for one-shot knowledge graph completion. In: Proc. of the 44th Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. ACM, 2021. 2232–2236. [doi: [10.1145/3404835.3463086](https://doi.org/10.1145/3404835.3463086)]
- [144] Finn C, Abbeel P, Levine S. Model-agnostic meta-learning for fast adaptation of deep networks. In: Proc. of the 34th Int'l Conf. on Machine Learning—Vol. 70. Sydney: JMLR, 2017. 1126–1135. [doi: [10.5555/3305381.3305498](https://doi.org/10.5555/3305381.3305498)]
- [145] Chen MY, Zhang W, Zhang W, Chen Q, Chen HJ. Meta relational learning for few-shot link prediction in knowledge graphs. In: Proc. of the 2019 Conf. on Empirical Methods in Natural Language Processing and the 9th Int'l Joint Conf. on Natural Language Processing (EMNLP-IJCNLP). Hong Kong: ACL, 2019. 4217–4226. [doi: [10.18653/v1/D19-1431](https://doi.org/10.18653/v1/D19-1431)]
- [146] Niu GL, Li Y, Tang CG, Geng RY, Dai J, Liu Q, Wang H, Sun J, Huang F, Si L. Relational learning with gated and attentive neighbor aggregator for few-shot knowledge graph completion. In: Proc. of the 44th Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. ACM, 2021. 213–222. [doi: [10.1145/3404835.3462925](https://doi.org/10.1145/3404835.3462925)]
- [147] Zheng SJ, Mai SJ, Sun Y, Hu HF, Yang YD. Subgraph-aware few-shot inductive link prediction via meta-learning. IEEE Trans. on

- Knowledge and Data Engineering, 2023, 35(6): 6512–6517. [doi: [10.1109/TKDE.2022.3177212](https://doi.org/10.1109/TKDE.2022.3177212)]
- [148] Chen SJ, Yang B, Zhao CX. Simple and effective meta relational learning for few-shot knowledge graph completion. Optimization and Engineering, 2025, 26(2): 869–889. [doi: [10.1007/s11081-024-09880-w](https://doi.org/10.1007/s11081-024-09880-w)]
- [149] Wu H, Yin J, Rajaratnam B, Guo JY. Hierarchical relational learning for few-shot knowledge graph completion. In: Proc. of the 11th Int'l Conf. on Learning Representations. Kigali: OpenReview.net, 2023.
- [150] Yang XH, Wei D, Zhang L, Ma GF, Xu XL, Long HX. Task-related network based on meta-learning for few-shot knowledge graph completion. Applied Intelligence, 2024, 54(8): 5961–5975. [doi: [10.1007/s10489-024-05480-4](https://doi.org/10.1007/s10489-024-05480-4)]
- [151] Hamilton WL, Ying R, Leskovec J. Inductive representation learning on large graphs. In: Proc. of the 31st Int'l Conf. on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017. 1025–1035. [doi: [10.5555/3294771.3294869](https://doi.org/10.5555/3294771.3294869)]
- [152] Hamaguchi T, Oiwa H, Shimbo M, Matsumoto Y. Knowledge transfer for out-of-knowledge-base entities: A graph neural network approach. In: Proc. of the 26th Int'l Joint Conf. on Artificial Intelligence. Melbourne: AAAI Press, 2017. 1802–1808. [doi: [10.24963/ijcai.2017/250](https://doi.org/10.24963/ijcai.2017/250)]
- [153] Zhu ZC, Zhang ZB, Xhonneux LP, Tang J. Neural bellman-ford networks: A general graph neural network framework for link prediction. In: Proc. of the 35th Int'l Conf. on Neural Information Processing Systems. Curran Associates Inc., 2021. 29476–29490.
- [154] Teru KK, Denis EG, Hamilton WL. Inductive relation prediction by subgraph reasoning. In: Proc. of the 37th Int'l Conf. on Machine Learning. JMLR, 2020. 876. [doi: [10.5555/3524938.3525814](https://doi.org/10.5555/3524938.3525814)]
- [155] Xu XH, Zhang P, He YQ, Chao CP, Yan CY. Subgraph neighboring relations infomax for inductive link prediction on knowledge graphs. In: Proc. of the 31st Int'l Joint Conf. on Artificial Intelligence. Vienna: ijcai.org, 2022. 2341–2347. [doi: [10.24963/ijcai.2022/325](https://doi.org/10.24963/ijcai.2022/325)]
- [156] Li JA, Wang Q, Mao ZD. Inductive relation prediction from relational paths and context with hierarchical Transformers. In: Proc. of the 2023 IEEE Int'l Conf. on Acoustics, Speech and Signal Processing (ICASSP 2023). Rhodes Island: IEEE, 2023. 1–5. [doi: [10.1109/ICASSP49357.2023.10096502](https://doi.org/10.1109/ICASSP49357.2023.10096502)]
- [157] Pan YD, Liu J, Zhang LL, Zhao TZ, Lin QK, Hu X, Wang QY. Inductive relation prediction with logical reasoning using contrastive representations. In: Proc. of the 2022 Conf. on Empirical Methods in Natural Language Processing. Abu Dhabi: ACL, 2022. 4261–4274. [doi: [10.18653/v1/2022.emnlp-main.286](https://doi.org/10.18653/v1/2022.emnlp-main.286)]
- [158] Pan YD, Liu J, Zhang LL, Hu X, Zhao TZ, Lin QK. Learning first-order rules with relational path contrast for inductive relation reasoning. arXiv:2110.08810, 2021.
- [159] Chen JJ, He HR, Wu F, Wang J. Topology-aware correlations between relations for inductive link prediction in knowledge graphs. In: Proc. of the 35th AAAI Conf. on Artificial Intelligence. AAAI, 2021. 6271–6278. [doi: [10.1609/aaai.v35i7.16779](https://doi.org/10.1609/aaai.v35i7.16779)]
- [160] Chen ZG, Yu H, Li JP, Luo XF. Entity representation by neighboring relations topology for inductive relation prediction. In: Khanna S, Cao J, Bai Q, Xu GD, eds. PRICAI 2022: Trends in Artificial Intelligence. Cham: Springer, 2022. 59–72. [doi: [10.1007/978-3-031-20865-2_5](https://doi.org/10.1007/978-3-031-20865-2_5)]
- [161] Mai S, Zheng SJ, Yang YD, Hu HF. Communicative message passing for inductive relation reasoning. In: Proc. of the 35th AAAI Conf. on Artificial Intelligence. AAAI, 2021. 4294–4302. [doi: [10.1609/aaai.v35i5.16554](https://doi.org/10.1609/aaai.v35i5.16554)]
- [162] Mohamed HA, Pilutti D, James S, Del Bue A, Pelillo M, Vascon S. Locality-aware subgraphs for inductive link prediction in knowledge graphs. Pattern Recognition Letters, 2023, 167: 90–97. [doi: [10.1016/j.patrec.2023.02.004](https://doi.org/10.1016/j.patrec.2023.02.004)]
- [163] Wu JF, Xiong AL, Mai SJ, Hu HF. Relation-dependent contrastive learning with cluster sampling for inductive relation prediction. Neurocomputing, 2024, 579: 127425. [doi: [10.1016/j.neucom.2024.127425](https://doi.org/10.1016/j.neucom.2024.127425)]
- [164] Zhang YF, Wang WQ, Yin HZ, Zhao PP, Chen W, Zhao L. Disconnected emerging knowledge graph oriented inductive link prediction. In: Proc. of the 39th IEEE Int'l Conf. on Data Engineering. Anaheim: IEEE, 2023. 381–393. [doi: [10.1109/ICDE55515.2023.00036](https://doi.org/10.1109/ICDE55515.2023.00036)]
- [165] Wang PF, Han JL, Li CL, Pan R. Logic attention based neighborhood aggregation for inductive knowledge graph embedding. In: Proc. of the 33rd AAAI Conf. on Artificial Intelligence. Honolulu: AAAI Press, 2019. 7152–7159. [doi: [10.1609/aaai.v33i01.33017152](https://doi.org/10.1609/aaai.v33i01.33017152)]
- [166] Zhong SN, Yue K, Duan L. Attention-based relation prediction of knowledge graph by incorporating graph and context features. In: Proc. of the 23rd Int'l Conf. on Web Information Systems Engineering. Biarritz: Springer, 2022. 259–273. [doi: [10.1007/978-3-031-20891-1_19](https://doi.org/10.1007/978-3-031-20891-1_19)]
- [167] Du ZJ, Du ZR, Wang L. Open knowledge graph representation learning based on neighbors and semantic affinity. Journal of Computer Research and Development, 2019, 56(12): 2549–2561 (in Chinese with English abstract). [doi: [10.7544/j.issn1000-1239.2019.20190648](https://doi.org/10.7544/j.issn1000-1239.2019.20190648)]
- [168] Zhang YX, Li YX, Zhang YN, Wang YL, Yang YS, Wei X, Luo JH. Missing-edge aware knowledge graph inductive inference through dual graph learning and traversing. Expert Systems with Applications, 2023, 213: 118969. [doi: [10.1016/j.eswa.2022.118969](https://doi.org/10.1016/j.eswa.2022.118969)]
- [169] Yan ZY, Ma TF, Gao LC, Tang Z, Chen C. Cycle representation learning for inductive relation prediction. In: Proc. of the 39th Int'l

- Conf. on Machine Learning. Baltimore: PMLR, 2022. 24895–24910.
- [170] Zhang YQ, Yao QM. Knowledge graph reasoning with relational digraph. In: Proc. of the 2022 ACM Web Conf. (WWW 2022). Lyon: ACM, 2022. 912–924. [doi: [10.1145/3485447.3512008](https://doi.org/10.1145/3485447.3512008)]
 - [171] He YQ, Wang ZH, Zhang P, Tu ZP, Ren ZC. VN network: Embedding newly emerging entities with virtual neighbors. In: Proc. of the 29th ACM Int'l Conf. on Information & Knowledge Management. ACM, 2020. 505–514. [doi: [10.1145/3340531.3411865](https://doi.org/10.1145/3340531.3411865)]
 - [172] Jung J, Jung J, Kang U. Learning to walk across time for interpretable temporal knowledge graph completion. In: Proc. of the 27th ACM SIGKDD Conf. on Knowledge Discovery & Data Mining. ACM, 2021. 786–795. [doi: [10.1145/3447548.3467292](https://doi.org/10.1145/3447548.3467292)]
 - [173] Bai LY, Yu WT, Chen MZ, Ma XN. Multi-hop reasoning over paths in temporal knowledge graphs using reinforcement learning. Applied Soft Computing, 2021, 103: 107144. [doi: [10.1016/j.asoc.2021.107144](https://doi.org/10.1016/j.asoc.2021.107144)]
 - [174] Liu RN, Yin GS, Liu ZC, Tian Y. Reinforcement learning with time intervals for temporal knowledge graph reasoning. Information Systems, 2024, 120: 102292. [doi: [10.1016/j.is.2023.102292](https://doi.org/10.1016/j.is.2023.102292)]
 - [175] Zhang CX, Yu L, Saebi M, Jiang M, Chawla NV. Few-shot multi-hop relation reasoning over knowledge bases. In: Findings of the Association for Computational Linguistics: EMNLP 2020. ACL, 2020. 580–585. [doi: [10.18653/v1/2020.findings-emnlp.51](https://doi.org/10.18653/v1/2020.findings-emnlp.51)]
 - [176] Zhang YM, Qian YY, Ye YF, Zhang CX. Adapting distilled knowledge for few-shot relation reasoning over knowledge graphs. In: Proc. of the 2022 SIAM Int'l Conf. on Data Mining (SDM). 2022. 666–674. [doi: [10.1137/1.9781611977172.75](https://doi.org/10.1137/1.9781611977172.75)]
 - [177] Zheng SF, Chen W, Zhao PP, Liu A, Fang JH, Zhao L. When hardness makes a difference: Multi-hop knowledge graph reasoning over few-shot relations. In: Proc. of the 30th ACM Int'l Conf. on Information & Knowledge Management. ACM, 2021. 2688–2697. [doi: [10.1145/3459637.3482402](https://doi.org/10.1145/3459637.3482402)]
 - [178] Bai LY, Han S, Zhu L. Multi-hop interpretable meta learning for few-shot temporal knowledge graph completion. Neural Networks, 2025, 183: 106981. [doi: [10.1016/j.neunet.2024.106981](https://doi.org/10.1016/j.neunet.2024.106981)]
 - [179] Zhang H, Bai LY. Few-shot link prediction for temporal knowledge graphs based on time-aware translation and attention mechanism. Neural Networks, 2023, 161: 371–381. [doi: [10.1016/j.neunet.2023.01.043](https://doi.org/10.1016/j.neunet.2023.01.043)]
 - [180] Gong X, Qin JY, Chai HY, Ding Y, Jia Y, Liao Q. Temporal-relational matching network for few-shot temporal knowledge graph completion. In: Proc. of the 28th Int'l Conf. on Database Systems for Advanced Applications. Tianjin: Springer, 2023. 768–783. [doi: [10.1007/978-3-031-30672-3_52](https://doi.org/10.1007/978-3-031-30672-3_52)]
 - [181] Bai LY, Zhang MC, Zhang H, Zhang H. FTMF: Few-shot temporal knowledge graph completion based on meta-optimization and fault-tolerant mechanism. World Wide Web, 2023, 26(3): 1243–1270. [doi: [10.1007/s11280-022-01091-6](https://doi.org/10.1007/s11280-022-01091-6)]
 - [182] Zhu L, Xing YZ, Bai LY, Chen XW. Few-shot link prediction with meta-learning for temporal knowledge graphs. Journal of Computational Design and Engineering, 2023, 10(2): 711–721. [doi: [10.1093/jcde/qwad016](https://doi.org/10.1093/jcde/qwad016)]
 - [183] Wang RJ, Li Z, Sun DC, Liu SZ, Li JN, Yin B, Abdelzaher T. Learning to sample and aggregate: Few-shot reasoning over temporal knowledge graphs. In: Proc. of the 36th Int'l Conf. on Neural Information Processing Systems. New Orleans: Curran Associates Inc., 2022. 1227. [doi: [10.5555/3600270.3601497](https://doi.org/10.5555/3600270.3601497)]
 - [184] Ding ZF, Cai HL, Wu JP, Ma YP, Liao RT, Xiong B, Tresp V. zrLLM: Zero-shot relational learning on temporal knowledge graphs with large language models. In: Proc. of the 2024 Conf. of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (Vol. 1: Long Papers). Mexico City: ACL, 2024. 1877–1895. [doi: [10.18653/v1/2024.naacl-long.104](https://doi.org/10.18653/v1/2024.naacl-long.104)]
 - [185] Qin PD, Wang X, Chen WH, Zhang CY, Xu WR, Wang WY. Generative adversarial zero-shot relational learning for knowledge graphs. In: Proc. of the 34th AAAI Conf. on Artificial Intelligence. New York: AAAI, 2020. 8673–8680. [doi: [10.1609/aaai.v34i05.6392](https://doi.org/10.1609/aaai.v34i05.6392)]
 - [186] Li XW, Ma JM, Yu J, Xu TY, Zhao MK, Liu HW, Yu M, Yu RG. HAPZSL: A hybrid attention prototype network for knowledge graph zero-shot relational learning. Neurocomputing, 2022, 508: 324–336. [doi: [10.1016/j.neucom.2022.07.038](https://doi.org/10.1016/j.neucom.2022.07.038)]
 - [187] Geng YX, Chen JY, Chen Z, Pan JZ, Ye ZQ, Yuan ZG, Jia YT, Chen HJ. OntoZSL: Ontology-enhanced zero-shot learning. In: Proc. of the 2021 Web Conf. Ljubljana: ACM, 2021. 3325–3336. [doi: [10.1145/3442381.3450042](https://doi.org/10.1145/3442381.3450042)]
 - [188] Geng YX, Chen JY, Zhang W, Xu YJ, Chen Z, Z. Pan J, Huang YF, Xiong FY, Chen HJ. Disentangled ontology embedding for zero-shot learning. In: Proc. of the 28th ACM SIGKDD Conf. on Knowledge Discovery and Data Mining. Washington: ACM, 2022. 443–453. [doi: [10.1145/3534678.3539453](https://doi.org/10.1145/3534678.3539453)]
 - [189] Song R, He SZ, Zheng SC, Gao SX, Liu K, Yu ZT, Zhao J. Decoupling mixture-of-graphs: Unseen relational learning for knowledge graph completion by fusing ontology and textual experts. In: Proc. of the 29th Int'l Conf. on Computational Linguistics. Gyeongju: Int'l Committee on Computational Linguistics, 2022. 2237–2246.
 - [190] Xu JW, Zhang J, Ke XR, Dong YX, Chen H, Li CP, Liu YB. P-INT: A path-based interaction model for few-shot knowledge graph completion. In: Findings of the Association for Computational Linguistics: EMNLP 2021. Punta Cana: ACL, 2021. 385–394. [doi: [10.1145/3459637.3482402](https://doi.org/10.1145/3459637.3482402)]

- 18653/v1/2021.findings-emnlp.35]
- [191] Ma RX, Yu MF, Gao BY, Guo JQ, Chen ZK, Zhao L. Enhancing path information with reinforcement learning for few-shot knowledge graph completion. In: Proc. of the 29th IEEE Int'l Conf. on Parallel and Distributed Systems (ICPADS). Ocean Flower Island: IEEE, 2023. 1603–1611. [doi: [10.1109/ICPADS60453.2023.00225](https://doi.org/10.1109/ICPADS60453.2023.00225)]
 - [192] Ren C, Zhang L, Fang LT, Xu T, Wang ZF, Yuan SC, Chen EH. Ontological concept structure aware knowledge transfer for inductive knowledge graph embedding. In: Proc. of the 2021 Int'l Joint Conf. on Neural Networks. Shenzhen: IEEE, 2021. 1–8. [doi: [10.1109/IJCNN52387.2021.9533852](https://doi.org/10.1109/IJCNN52387.2021.9533852)]
 - [193] Zhou YY, Shi SM, Huang HY. Weighted aggregator for the open-world knowledge graph completion. In: Proc. of the 6th Int'l Conf. of Pioneering Computer Scientists. Taiyuan: Springer, 2020. 283–291. [doi: [10.1007/978-981-15-7981-3_19](https://doi.org/10.1007/978-981-15-7981-3_19)]
 - [194] Wang YH, Xiao WD, Tan Z, Zhao X. Caps-OWKG: A capsule network model for open-world knowledge graph. Int'l Journal of Machine Learning and Cybernetics, 2021, 12(6): 1627–1637. [doi: [10.1007/s13042-020-01259-4](https://doi.org/10.1007/s13042-020-01259-4)]
 - [195] Zhu WP, Zhi XL, Tong WQ. Extracting short entity descriptions for open-world extension to knowledge graph completion models. In: Proc. of the 13th Int'l Conf. on Knowledge Science, Engineering and Management. Hangzhou: Springer, 2020. 16–27. [doi: [10.1007/978-3-030-55130-8_2](https://doi.org/10.1007/978-3-030-55130-8_2)]
 - [196] Shah H, Villmow J, Ulges A. Relation specific transformations for open world knowledge graph completion. In: Proc. of the Graph-based Methods for Natural Language Processing (TextGraphs). Barcelona: ACL, 2020. 79–84. [doi: [10.18653/v1/2020.textgraphs-1.9](https://doi.org/10.18653/v1/2020.textgraphs-1.9)]
 - [197] Wang JB, Lei J, Sun SN, Guo K. Embeddings based on relation-specific constraints for open world knowledge graph completion. Applied Intelligence, 2023, 53(12): 16192–16204. [doi: [10.1007/s10489-022-04247-z](https://doi.org/10.1007/s10489-022-04247-z)]
 - [198] Shi BX, Weninger T. Open-world knowledge graph completion. In: Proc. of the 32nd AAAI Conf. on Artificial Intelligence. New Orleans: AAAI Press, 2018. 1957–1964. [doi: [10.1609/aaai.v32i1.11535](https://doi.org/10.1609/aaai.v32i1.11535)]
 - [199] Niu L, Fu CP, Yang Q, Li ZX, Chen ZG, Liu QS, Zheng K. Open-world knowledge graph completion with multiple interaction attention. World Wide Web, 2021, 24(1): 419–439. [doi: [10.1007/s11280-020-00847-2](https://doi.org/10.1007/s11280-020-00847-2)]
 - [200] Chen XJ, Jia SB, Ding L, Shen H, Xiang Y. SDT: An integrated model for open-world knowledge graph reasoning. Expert Systems with Applications, 2020, 162: 113889. [doi: [10.1016/j.eswa.2020.113889](https://doi.org/10.1016/j.eswa.2020.113889)]
 - [201] Peng BH, Liang SH, Islam M. Bi-link: Bridging inductive link predictions from text via contrastive learning of Transformers and prompts. arXiv:2210.14463, 2022.
 - [202] Gesese GA, Sack H, Alam M. RAILD: Towards leveraging relation features for inductive link prediction in knowledge graphs. In: Proc. of the 11th Int'l Joint Conf. on Knowledge Graphs. Hangzhou: ACM, 2022. 82–90. [doi: [10.1145/3579051.3579066](https://doi.org/10.1145/3579051.3579066)]
 - [203] Zha H, Chen ZY, Yan XF. Inductive relation prediction by BERT. In: Proc. of the 36th AAAI Conf. on Artificial Intelligence. AAAI, 2022. 5923–5931. [doi: [10.1609/aaai.v36i5.20537](https://doi.org/10.1609/aaai.v36i5.20537)]
 - [204] Wang B, Wang GT, Huang J, You JX, Leskovec J, Kuo CCJ. Inductive learning on commonsense knowledge graph completion. In: Proc. of the 2021 Int'l Joint Conf. on Neural Networks (IJCNN). Shenzhen: IEEE, 2021. 1–8. [doi: [10.1109/IJCNN52387.2021.9534355](https://doi.org/10.1109/IJCNN52387.2021.9534355)]
 - [205] Ding ZF, Wu JP, Li ZY, Ma YP, Tresp V. Improving few-shot inductive learning on temporal knowledge graphs using confidence-augmented reinforcement learning. In: Proc. of the 2023 European Conf. on Machine Learning and Knowledge Discovery in Databases: Research Track. Turin: Springer, 2023. 550–566. [doi: [10.1007/978-3-031-43418-1_33](https://doi.org/10.1007/978-3-031-43418-1_33)]
 - [206] Ding ZF, Wu JP, He BL, Ma YP, Han Z, Tresp V. Few-shot inductive learning on temporal knowledge graphs using concept-aware information. In: Proc. of the 4th Conf. on Automated Knowledge Base Construction. London, 2022.
 - [207] Wang JP, Wang BY, Qiu MK, Pan SR, Xiong B, Liu H, Luo LH, Liu TF, Hu YL, Yin BC, Gao W. A survey on temporal knowledge graph completion: Taxonomy, progress, and prospects. arXiv:2308.02457, 2023.
 - [208] Wang Q, Mao ZD, Wang B, Guo L. Knowledge graph embedding: A survey of approaches and applications. IEEE Trans. on Knowledge and Data Engineering, 2017, 29(12): 2724–2743. [doi: [10.1109/TKDE.2017.2754499](https://doi.org/10.1109/TKDE.2017.2754499)]
 - [209] Kapetanakis S, Samakovitis G, Gunasekera PVGBD, *et al.* Monitoring financial transaction fraud with the use of case-based reasoning. In: Proc. of the 17th UK Workshop on Case-based Reasoning. Cambridge, 2012.
 - [210] Franco-Salvador M, Gupta P, Rosso P, Banchs RE. Cross-language plagiarism detection over continuous-space- and knowledge graph-based representations of language. Knowledge-based Systems, 2016, 111: 87–99. [doi: [10.1016/j.knosys.2016.08.004](https://doi.org/10.1016/j.knosys.2016.08.004)]
 - [211] MacLean F. Knowledge graphs and their applications in drug discovery. Expert Opinion on Drug Discovery, 2021, 16(9): 1057–1069. [doi: [10.1080/17460441.2021.1910673](https://doi.org/10.1080/17460441.2021.1910673)]
 - [212] Xu DR, Zhou JB, Xu T, Xia Y, Liu J, Chen EH, Dou DJ. Multimodal biological knowledge graph completion via triple co-attention mechanism. In: Proc. of the 39th IEEE Int'l Conf. on Data Engineering (ICDE). Anaheim: IEEE, 2023. 3928–3941. [doi: [10.1109/](https://doi.org/10.1109/)

- ICDE55515.2023.10231041]
- [213] Zhu YS, Zhao HX, Zhang W, Ye GQ, Chen H, Zhang NY, Chen HJ. Knowledge perceived multi-modal pretraining in e-commerce. In: Proc. of the 29th ACM Int'l Conf. on Multimedia. ACM, 2021. 2744–2752. [doi: [10.1145/3474085.3475648](https://doi.org/10.1145/3474085.3475648)]
 - [214] Wang XD, Wang CY, Li L, Li ZX, Chen B, Jin LB, Huang J, Xiao YH, Gao M. FashionKLIP: Enhancing e-commerce image-text retrieval with fashion multi-modal conceptual knowledge graph. In: Proc. of the 61st Annual Meeting of the Association for Computational Linguistics (Vol. 5: Industry Track). Toronto: ACL, 2023. 149–158. [doi: [10.18653/v1/2023.acl-industry.16](https://doi.org/10.18653/v1/2023.acl-industry.16)]
 - [215] Song FF, Wang B, Tang YF, Sun J. Research of medical aided diagnosis system based on temporal knowledge graph. In: Proc. of the 16th Int'l Conf. on Advanced Data Mining and Applications. Foshan: Springer, 2020. 236–250. [doi: [10.1007/978-3-030-65390-3_19](https://doi.org/10.1007/978-3-030-65390-3_19)]
 - [216] Yang CB, Li WZ, Zhang XP, Zhang RS, Qi GL. A temporal semantic search system for traditional Chinese medicine based on temporal knowledge graphs. In: Proc. of the 9th Joint Int'l Conf. on Semantic Technology. Hangzhou: Springer, 2020. 13–20. [doi: [10.1007/978-981-15-3412-6_2](https://doi.org/10.1007/978-981-15-3412-6_2)]
 - [217] Zhao L, Deng HH, Qiu LY, Li SM, Hou ZX, Sun H, Chen Y. Urban multi-source spatio-temporal data analysis aware knowledge graph embedding. Symmetry, 2020, 12(2): 199. [doi: [10.3390/sym12020199](https://doi.org/10.3390/sym12020199)]
 - [218] Wang HD, Yu QH, Liu Y, Jin DP, Li Y. Spatio-temporal urban knowledge graph enabled mobility prediction. Proc. of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2021, 5(4): 184. [doi: [10.1145/3494993](https://doi.org/10.1145/3494993)]
 - [219] Bose AJ, Jain A, Molino P, Hamilton WL. Meta-Graph: Few shot link prediction via meta learning. In: Proc. of the 2020 Int'l Conf. on Learning Representations. Addis Ababa, 2020.
 - [220] Lan L, Wang PH, Du XF, Song KK, Tao J, Guan XH. Node classification on graphs with few-shot novel labels via meta transformed network embedding. In: Proc. of the 34th Int'l Conf. on Neural Information Processing Systems. Vancouver: Curran Associates Inc., 2020. 1386. [doi: [10.5555/3495724.3497110](https://doi.org/10.5555/3495724.3497110)]
 - [221] Guo ZC, Zhang CX, Yu WH, Herr J, Wiest O, Jiang M, Chawla NV. Few-shot graph learning for molecular property prediction. In: Proc. of the 2021 Web Conf. Ljubljana: ACM, 2021. 2559–2567. [doi: [10.1145/3442381.3450112](https://doi.org/10.1145/3442381.3450112)]
 - [222] Wang YQ, Abuduweili A, Yao QM, Dou DJ. Property-aware relation networks for few-shot molecular property prediction. In: Proc. of the 35th Int'l Conf. on Neural Information Processing Systems. Curran Associates Inc., 2021. 1334. [doi: [10.5555/3540261.3541595](https://doi.org/10.5555/3540261.3541595)]
 - [223] Wang K, Shao JZ, Zhang T, Chen QJ, Huo HF. MPKGAC: Multimodal product attribute completion in e-commerce. In: Proc. of the 2023 ACM Web Conf. Austin: ACM, 2023. 336–340. [doi: [10.1145/3543873.3584623](https://doi.org/10.1145/3543873.3584623)]
 - [224] Gastinger J, Szttyler T, Steinert N, Gründer-Fahrer S, Martin M, Schuelke A, Stuckenschmidt H. Dynamic representations of global crises: A temporal knowledge graph for conflicts, trade and value networks. In: Proc. of the 3rd Learning on Graphs Conf. PMLR, 2025. 47:1–47:22.
 - [225] Hu JZ, Gong JY, Shen HD, Eldardiry H. Hypergraph-based zero-shot multi-modal product attribute value extraction. In: Proc. of the 2025 ACM Web Conf. Sydney: ACM, 2025. 4853–4862. [doi: [10.1145/3696410.3714714](https://doi.org/10.1145/3696410.3714714)]
 - [226] Wang YZ, Qian SS, Hu J, Fang Q, Xu CS. Fake news detection via knowledge-driven multimodal graph convolutional networks. In: Proc. of the 2020 Int'l Conf. on Multimedia Retrieval. Dublin: ACM, 2020. 540–547. [doi: [10.1145/3372278.3390713](https://doi.org/10.1145/3372278.3390713)]
 - [227] Zhang W, Paudel B, Wang L, Chen JY, Zhu H, Zhang W, Bernstein A, Chen HJ. Iteratively learning embeddings and rules for knowledge graph reasoning. In: Proc. of the 2019 Web Conf. San Francisco: ACM, 2019. 2366–2377. [doi: [10.1145/3308558.3313612](https://doi.org/10.1145/3308558.3313612)]
 - [228] Chen WJ, Cao YX, Feng FL, He XN, Zhang YD. HoGRN: Explainable sparse knowledge graph completion via high-order graph reasoning network. IEEE Trans. on Knowledge and Data Engineering, 2024, 36(12): 8462–8475. [doi: [10.1109/TKDE.2024.3422226](https://doi.org/10.1109/TKDE.2024.3422226)]
 - [229] Jia HT, Zhang BY, Huang C, Li WH, Xu WB, Bi YF, Ren L. Application of graph neural network and feature information enhancement in relation inference of sparse knowledge graph. Journal of Electronic Science and Technology, 2023, 21(2): 100194. [doi: [10.1016/j.jnlest.2023.100194](https://doi.org/10.1016/j.jnlest.2023.100194)]
 - [230] Tan ZX, Chen ZL, Feng SB, Zhang QY, Zheng QH, Li JD, Luo MN. KRACL: Contrastive learning with graph context modeling for sparse knowledge graph completion. In: Proc. of the 2023 ACM Web Conf. Austin: ACM, 2023. 2548–2559. [doi: [10.1145/3543507.3583412](https://doi.org/10.1145/3543507.3583412)]
 - [231] Liu XL, Hussain H, Razouk H, Kern R. Effective use of BERT in graph embeddings for sparse knowledge graph completion. In: Proc. of the 37th ACM/SIGAPP Symp. on Applied Computing. ACM, 2022. 799–802. [doi: [10.1145/3477314.3507031](https://doi.org/10.1145/3477314.3507031)]
 - [232] Lv X, Han X, Hou L, Li JZ, Liu ZY, Zhang W, Zhang YC, Kong H, Wu SH. Dynamic anticipation and completion for multi-hop reasoning over sparse knowledge graph. In: Proc. of the 2020 Conf. on Empirical Methods in Natural Language Processing. ACL, 2020. 5694–5703. [doi: [10.18653/v1/2020.emnlp-main.459](https://doi.org/10.18653/v1/2020.emnlp-main.459)]
 - [233] Zeng ZF, Cheng Q, Si YH, Liu Z. RuMER-RL: A hybrid framework for sparse knowledge graph explainable reasoning. Information Sciences, 2024, 680: 121144. [doi: [10.1016/j.ins.2024.121144](https://doi.org/10.1016/j.ins.2024.121144)]

- [234] Manchanda S. Walk-and-relate: A random-walk-based algorithm for representation learning on sparse knowledge graphs. arXiv:2209.08769, 2022.
- [235] He SZ, Liu K, Ji GL, Zhao J. Learning to represent knowledge graphs with Gaussian embedding. In: Proc. of the 24th ACM Int'l on Conf. on Information and Knowledge Management. Melbourne: ACM, 2015. 623–632. [doi: [10.1145/2806416.2806502](https://doi.org/10.1145/2806416.2806502)]
- [236] Chen XL, Boratko M, Chen MH, Dasgupta SS, Li XL, McCallum A. Probabilistic box embeddings for uncertain knowledge graph reasoning. In: Proc. of the 2021 Conf. of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. ACL, 2021. 882–893. [doi: [10.18653/v1/2021.naacl-main.68](https://doi.org/10.18653/v1/2021.naacl-main.68)]
- [237] Wang JB, Nie K, Chen XY, Lei J. SUKE: Embedding model for prediction in uncertain knowledge graph. IEEE Access, 2021, 9: 3871–3879. [doi: [10.1109/ACCESS.2020.3047086](https://doi.org/10.1109/ACCESS.2020.3047086)]
- [238] Chen XL, Chen MH, Shi WJ, Sun YZ, Zaniolo C. Embedding uncertain knowledge graphs. In: Proc. of the 33rd AAAI Conf. on Artificial Intelligence. Honolulu: AAAI, 2019. 3363–3370. [doi: [10.1609/aaai.v33i01.33013363](https://doi.org/10.1609/aaai.v33i01.33013363)]
- [239] Chen YL, Wu TX, Liu YC, Wang YX, Qi GL. Uncertain knowledge graph completion with rule mining. In: Proc. of the 21st Int'l Conf. on Web Information Systems and Applications. Yinchuan: Springer, 2024. 100–112. [doi: [10.1007/978-981-97-7707-5_9](https://doi.org/10.1007/978-981-97-7707-5_9)]
- [240] Cohen WW. TensorLog: A differentiable deductive database. arXiv:1605.06523, 2016.
- [241] Zhang QG, Dong JN, Duan KY, Huang X, Liu YZ, Xu LC. Contrastive knowledge graph error detection. In: Proc. of the 31st ACM Int'l Conf. on Information & Knowledge Management. Atlanta: ACM, 2022. 2590–2599. [doi: [10.1145/3511808.3557264](https://doi.org/10.1145/3511808.3557264)]
- [242] Belth C, Zheng XY, Vreeken J, Koutra D. What is normal, what is strange, and what is missing in a knowledge graph: Unified characterization via inductive summarization. In: Proc. of the 2020 Web Conf. Taipei: ACM, 2020. 1115–1126. [doi: [10.1145/3366423.3380189](https://doi.org/10.1145/3366423.3380189)]
- [243] Zhang Z, Zhang FW, Zhuang FZ, Xu YJ. Knowledge graph error detection with hierarchical path structure. In: Proc. of the 32nd ACM Int'l Conf. on Information and Knowledge Management. Birmingham: ACM, 2023. 4430–4434. [doi: [10.1145/3583780.3615201](https://doi.org/10.1145/3583780.3615201)]
- [244] Zeng ZF, Cheng Q, Si YH. Logical rule-based knowledge graph reasoning: A comprehensive survey. Mathematics, 2023, 11(21): 4486. [doi: [10.3390/math11214486](https://doi.org/10.3390/math11214486)]
- [245] Chang H, Ye JN, Lopez-Avila A, Du JH, Li J. Path-based explanation for knowledge graph completion. In: Proc. of the 30th ACM SIGKDD Conf. on Knowledge Discovery and Data Mining. Barcelona: ACM, 2024. 231–242. [doi: [10.1145/3637528.3671683](https://doi.org/10.1145/3637528.3671683)]
- [246] Omran PG, Wang KW, Wang Z. Learning temporal rules from knowledge graph streams. In: Proc. of the 2019 AAAI Spring Symp. on Combining Machine Learning with Knowledge Engineering. Palo Alto: CEUR-WS.org, 2019.
- [247] Liu YS, Ma YP, Hildebrandt M, Joblin M, Tresp V. TLogic: Temporal logical rules for explainable link forecasting on temporal knowledge graphs. In: Proc. of the 36th AAAI Conf. on Artificial Intelligence. AAAI, 2022. 4120–4127. [doi: [10.1609/aaai.v36i4.20330](https://doi.org/10.1609/aaai.v36i4.20330)]
- [248] Xiong SH, Yang Y, Fekri F, Kerce JC. TILP: Differentiable learning of temporal logical rules on knowledge graphs. In: Proc. of the 11th Int'l Conf. on Learning Representations. Kigali: OpenReview.net, 2023.
- [249] Xu Z, Ben Rim W, Gashteovski K, Szttyler T, Lawrence C. A human-centric evaluation platform for explainable knowledge graph completion. In: Proc. of the 18th Conf. of the European Chapter of the Association for Computational Linguistics: System Demonstrations. St. Julians: ACL, 2024. 18–26. [doi: [10.18653/v1/2024.eacl-demo.3](https://doi.org/10.18653/v1/2024.eacl-demo.3)]
- [250] Kim J, Kwon Y, Jo YH, Choi E. KG-GPT: A general framework for reasoning on knowledge graphs using large language models. In: Findings of the Association for Computational Linguistics: EMNLP 2023. Singapore: ACL, 2023. 9410–9421. [doi: [10.18653/v1/2023.findings-emnlp.631](https://doi.org/10.18653/v1/2023.findings-emnlp.631)]
- [251] Xu DR, Zhang ZH, Lin ZX, Wu X, Zhu ZH, Xu T, Zhao XY, Zheng YF, Chen EH. Multi-perspective improvement of knowledge graph completion with large language models. In: Proc. of the 2024 Joint Int'l Conf. on Computational Linguistics, Language Resources and Evaluation (LREC-COLING 2024). Torino: ELRA, 2024. 11956–11968.
- [252] Choudhary N, Reddy CK. Complex logical reasoning over knowledge graphs using large language models. In: Proc. of the 12th Int'l Conf. on Learning Representations. Vienna: OpenReview.net, 2024.
- [253] Luo LH, Ju JX, Xiong B, Li YF, Haffari G, Pan SR. ChatRule: Mining logical rules with large language models for knowledge graph reasoning. In: Proc. of the 29th Pacific-Asia Conf. on Knowledge Discovery and Data Mining. Sydney: Springer, 2025. 314–325. [doi: [10.1007/978-981-96-8173-0_25](https://doi.org/10.1007/978-981-96-8173-0_25)]
- [254] Wang JP, Sun K, Luo LH, Wei W, Hu YL, Liew AWC, Pan SR, Yin BC. Large language models-guided dynamic adaptation for temporal knowledge graph reasoning. In: Proc. of the 38th Int'l Conf. on Neural Information Processing Systems. Vancouver: Curran Associates Inc., 2024. 269. [doi: [10.5555/3737916.3738185](https://doi.org/10.5555/3737916.3738185)]
- [255] Xia YW, Wang D, Liu Q, Wang L, Wu S, Zhang XY. Chain-of-history reasoning for temporal knowledge graph forecasting. In:

- Findings of the Association for Computational Linguistics: ACL 2024. Bangkok: ACL, 2024. 16144–16159. [doi: [10.18653/v1/2024.findings-acl.955](https://doi.org/10.18653/v1/2024.findings-acl.955)]
- [256] Luo RL, Gu TL, Li HL, Li JZ, Lin ZC, Li JY, Yang YJ. Chain of history: Learning and forecasting with LLMs for temporal knowledge graph completion. arXiv:2401.06072, 2024.

附中文参考文献

- [13] 王硕, 杜志娟, 孟小峰. 大规模知识图谱补全技术的研究进展. 中国科学: 信息科学, 2020, 50(4): 551–575. [doi: [10.1360/N112018-00225](https://doi.org/10.1360/N112018-00225)]
- [16] 官赛萍, 靳小龙, 贾岩涛, 王元卓, 程学旗. 面向知识图谱的知识推理研究进展. 软件学报, 2018, 29(10): 2966–2994. <http://www.jos.org.cn/1000-9825/5551.htm> [doi: [10.13328/j.cnki.jos.005551](https://doi.org/10.13328/j.cnki.jos.005551)]
- [17] 邱瑞, 朱振华. 知识图谱在公共安全方面的应用. 电脑知识与技术, 2018, 14(35): 196–199. [doi: [10.14004/j.cnki.ckt.2018.4167](https://doi.org/10.14004/j.cnki.ckt.2018.4167)]
- [18] 翁海腾, 汪宁, 邱瑞, 李超. 基于知识图谱的知识推理与公共安全结合的理论研究. 电子测试, 2018(18): 132–133. [doi: [10.3969/j.issn.1000-8519.2018.18.068](https://doi.org/10.3969/j.issn.1000-8519.2018.18.068)]
- [20] 马海波. 面向风控的企业关联信息知识图谱构建与应用研究 [硕士学位论文]. 北京: 北京工业大学, 2019. [doi: [10.26935/d.cnki.gbju.2019.000232](https://doi.org/10.26935/d.cnki.gbju.2019.000232)]
- [23] 洪文兴, 胡志强, 翁洋, 张恒, 王竹, 郭志新. 面向司法案件的案情知识图谱自动构建. 中文信息学报, 2020, 34(1): 34–44. [doi: [10.3969/j.issn.1003-0077.2020.01.005](https://doi.org/10.3969/j.issn.1003-0077.2020.01.005)]
- [24] 马昂, 于艳华, 杨胜利, 石川, 李劼, 蔡修秀. 基于强化学习的知识图谱综述. 计算机研究与发展, 2022, 59(8): 1694–1722. [doi: [10.7544/issn1000-1239.20211264](https://doi.org/10.7544/issn1000-1239.20211264)]
- [25] 吴越, 孙海春. 基于图神经网络的知识图谱补全研究综述. 数据分析与知识发现, 2024, 8(3): 10–28. [doi: [10.11925/infotech.2096-3467.2023.0753](https://doi.org/10.11925/infotech.2096-3467.2023.0753)]
- [26] 孙水发, 李小龙, 李伟生, 雷大江, 李思慧, 杨柳, 吴义榕. 图神经网络应用于知识图谱推理的研究综述. 计算机科学与探索, 2023, 17(1): 27–52. [doi: [10.3778/j.issn.1673-9418.2207060](https://doi.org/10.3778/j.issn.1673-9418.2207060)]
- [27] 刘洪波, 陈越, 卢记仓, 侯雪梅, 杨奎武. 面向知识图谱的规则挖掘研究综述. 计算机工程与应用, 2023, 59(14): 30–38. [doi: [10.3778/j.issn.1002-8331.2210-0014](https://doi.org/10.3778/j.issn.1002-8331.2210-0014)]
- [28] 杨大伟, 周刚, 卢记仓, 宁原隆. 基于知识表示学习的知识图谱补全研究综述. 信息工程大学学报, 2021, 22(5): 558–565. [doi: [10.3969/j.issn.1671-0673.2021.05.007](https://doi.org/10.3969/j.issn.1671-0673.2021.05.007)]
- [29] 杜雪盈, 刘名威, 沈立炜, 彭鑫. 面向链接预测的知识图谱表示学习方法综述. 软件学报, 2024, 35(1): 87–117. <http://www.jos.org.cn/1000-9825/6902.htm> [doi: [10.13328/j.cnki.jos.006902](https://doi.org/10.13328/j.cnki.jos.006902)]
- [30] 翁金塔, 仇晶, 张光华. 面向推理的知识图谱表示学习方法综述. 广州大学学报 (自然科学版), 2021, 20(3): 80–89. [doi: [10.3969/j.issn.1671-4229.2021.03.008](https://doi.org/10.3969/j.issn.1671-4229.2021.03.008)]
- [31] 封皓君, 段立, 张碧莹. 面向知识图谱的知识推理综述. 计算机系统应用, 2021, 30(10): 21–30. [doi: [10.15888/j.cnki.csa.008137](https://doi.org/10.15888/j.cnki.csa.008137)]
- [32] 申秋慧, 张宏军, 徐有为, 王航, 程恺. 知识图谱嵌入模型中的损失函数研究综述. 计算机科学, 2023, 50(4): 149–158. [doi: [10.11896/jsjx.211200175](https://doi.org/10.11896/jsjx.211200175)]
- [33] 张天成, 田雪, 孙相会, 于明鹤, 孙艳红, 于戈. 知识图谱嵌入技术研究综述. 软件学报, 2023, 34(1): 277–311. <http://www.jos.org.cn/1000-9825/6429.htm> [doi: [10.13328/j.cnki.jos.006429](https://doi.org/10.13328/j.cnki.jos.006429)]
- [34] 马瑞新, 李泽阳, 陈志奎, 赵亮. 知识图谱推理研究综述. 计算机科学, 2022, 49(S1): 74–85. [doi: [10.11896/jsjx.210100122](https://doi.org/10.11896/jsjx.210100122)]
- [35] 王春雷, 王肖, 刘凯. 多模态知识图谱表示学习综述. 计算机应用, 2024, 44(1): 1–15. [doi: [10.11772/j.issn.1001-9081.2023050583](https://doi.org/10.11772/j.issn.1001-9081.2023050583)]
- [36] 沈英汉, 江旭晖, 王元卓, 李紫宣, 李子健, 谭鹤翔, 沈华伟. 动态知识图谱的推理研究综述. 计算机学报, 2023, 46(6): 1272–1301. [doi: [10.11897/SP.J.1016.2023.01272](https://doi.org/10.11897/SP.J.1016.2023.01272)]
- [37] 肖蕾, 李琪. 时序知识图谱补全方法研究综述. 计算机工程与应用, 2024, 60(6): 43–54. [doi: [10.3778/j.issn.1002-8331.2307-0083](https://doi.org/10.3778/j.issn.1002-8331.2307-0083)]
- [38] 梁新雨, 司冠南, 李建辛, 田鹏新, 安兆亮, 周凤余. 面向知识图谱补全的归纳学习研究综述. 计算机科学与探索, 2023, 17(11): 2580–2604. [doi: [10.3778/j.issn.1673-9418.2303063](https://doi.org/10.3778/j.issn.1673-9418.2303063)]
- [43] 侯中妮, 靳小龙, 陈剑赞, 官赛萍, 王元卓, 程学旗. 知识图谱可解释推理研究综述. 软件学报, 2022, 33(12): 4644–4667. <http://www.jos.org.cn/1000-9825/6522.htm> [doi: [10.13328/j.cnki.jos.006522](https://doi.org/10.13328/j.cnki.jos.006522)]
- [44] 王俞涵, 陈子阳, 赵翔, 谭真, 肖卫东, 程学旗. 时序知识图谱表示与推理的研究进展与趋势. 软件学报, 2024, 35(8): 3923–3951. <http://www.jos.org.cn/1000-9825/7093.htm> [doi: [10.13328/j.cnki.jos.007093](https://doi.org/10.13328/j.cnki.jos.007093)]
- [45] 彭晏飞, 张睿思, 王瑞华, 郭家隆. 少样本知识图谱补全技术研究. 计算机科学与探索, 2023, 17(6): 1268–1284. [doi: [10.3778/j.issn.1673-9418.2209069](https://doi.org/10.3778/j.issn.1673-9418.2209069)]

- [52] 刘世侠, 李卫军, 刘雪洋, 丁建平, 苏易礪, 李浩南. 基于强化学习的知识图谱推理研究综述. 计算机应用研究, 2024, 41(9): 2561–2572. [doi: [10.19734/j.issn.1001-3695.2023.11.0583](https://doi.org/10.19734/j.issn.1001-3695.2023.11.0583)]
- [53] 李志飞, 赵月, 张龔. 基于表示学习的知识图谱推理研究综述. 计算机科学, 2023, 50(3): 94–113. [doi: [10.11896/jsjcx.220900136](https://doi.org/10.11896/jsjcx.220900136)]
- [167] 杜治娟, 杜治蓉, 王璐. 基于相邻和语义亲和力的开放知识图谱表示学习. 计算机研究与发展, 2019, 56(12): 2549–2561. [doi: [10.7544/issn1000-1239.2019.20190648](https://doi.org/10.7544/issn1000-1239.2019.20190648)]

作者简介

牛广林, 博士, CCF 专业会员, 主要研究领域为知识图谱, 多模态学习, 机器学习.

粟思悦, 硕士生, 主要研究领域为知识图谱, 大模型, 自然语言处理.

李波, 博士, 教授, 博士生导师, CCF 会士, 主要研究领域为计算机视觉, 机器学习, 知识推理.