

知识图谱补全技术及应用^{*}

郑修林^{1,2}, 周 鹏^{1,3}, 李培培^{1,2}, 张 赞^{1,2}, 黄艳香⁴, 吴信东^{1,2,5}



¹(大数据知识工程教育部重点实验室(合肥工业大学), 安徽 合肥 230009)

²(合肥工业大学 计算机与信息学院, 安徽 合肥 230601)

³(安徽大学 计算机科学与技术学院, 安徽 合肥 230601)

⁴(北京市教育委员会, 北京 100091)

⁵(之江实验室 知识工程研究中心, 浙江 杭州 311121)

通信作者: 吴信东, E-mail: xwu@hfut.edu.cn

摘 要: 知识图谱以其独特的知识管理方式和表示能力被广泛运用于知识问答等知识计算领域. 但是, 现实中的知识图谱或多或少存在信息不完整的问题, 影响知识图谱的质量, 限制了下游任务的效果, 如不完整知识图谱不能给出准确的知识问答结果. 因此, 知识图谱补全技术应运而生, 旨在通过不同的策略对知识图谱事实三元组中缺失的内容进行预测以改善知识图谱的质量. 近年来, 人们对知识图谱补全进行了大量的研究. 根据构建模型所需样本的数量将现有的知识图谱补全技术分为 3 大类, 即零样本知识图谱补全、少样本知识图谱补全和多样本知识图谱补全. 为了调研并作为研究人员掌握知识图谱补全研究核心思想和研究现状的第一手材料, 从理论研究、实验分析以及具体应用, 如华谱系统, 对已有的知识图谱补全技术进行全面的回顾, 总结当前知识图谱补全技术所面临的问题与挑战, 并对未来可能的研究方向进行探讨.

关键词: 知识图谱; 知识图谱补全; 大模型; 华谱系统

中图法分类号: TP182

中文引用格式: 郑修林, 周鹏, 李培培, 张赞, 黄艳香, 吴信东. 知识图谱补全技术及应用. 软件学报, 2025, 36(12): 5599–5628. <http://www.jos.org.cn/1000-9825/7400.htm>

英文引用格式: Zheng XL, Zhou P, Li PP, Zhang Z, Huang YX, Wu XD. Knowledge Graph Completion: Techniques and Applications. Ruan Jian Xue Bao/Journal of Software, 2025, 36(12): 5599–5628 (in Chinese). <http://www.jos.org.cn/1000-9825/7400.htm>

Knowledge Graph Completion: Techniques and Applications

ZHENG Xiu-Lin^{1,2}, ZHOU Peng^{1,3}, LI Pei-Pei^{1,2}, ZHANG Zan^{1,2}, HUANG Yan-Xiang⁴, WU Xin-Dong^{1,2,5}

¹(Key Laboratory of Knowledge Engineering with Big Data (Hefei University of Technology), Ministry of Education, Hefei 230009, China)

²(School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230601, China)

³(School of Computer Science and Technology, Anhui University, Hefei 230601, China)

⁴(Beijing Municipal Education Commission, Beijing 100091, China)

⁵(Knowledge Engineering Research Center, Zhejiang Lab, Hangzhou 311121, China)

Abstract: Knowledge graph (KG), with their unique approach to knowledge management and representation capabilities, have been widely applied in various knowledge computing fields, including question answering. However, incomplete information is often present in KG, which undermines their quality and limits the performance of downstream tasks. As a result, knowledge graph completion (KGC) has emerged, aiming to enhance the quality of KG by predicting the missing information in triples using different methods. In recent years, extensive research has been conducted in the field of KGC. This study classifies KGC techniques into three categories based on the

* 基金项目: 国家自然科学基金(62120106008); 中央高校基本科研业务费专项资金(JZ2023HGTB0270, PA2022GDSK0038)

收稿时间: 2023-11-15; 修改时间: 2024-10-02, 2024-12-02; 采用时间: 2025-02-11; jos 在线出版时间: 2025-06-25

CNKI 网络首发时间: 2025-06-26

number of samples used: zero-shot KGC, few-shot KGC, and multi-shot KGC. To investigate and provide a first-hand reference for the core concepts and current status of KGC research, this study offers a comprehensive review of the latest research advancements in KGC from theoretical research, experimental analysis, and practical applications, such as the Huapu system. The problems and challenges faced by the current KGC technologies are summarized, and potential research directions for the future are discussed.

Key words: knowledge graph (KG); knowledge graph completion (KGC); large language model (LLM); Huapu system

知识图谱 (knowledge graph, KG)^[1]自首次被谷歌提出以来,很多领域都能见其活跃的身影,如智能问答^[2-5]、自动推荐^[6,7]和实体对齐^[8,9]等. KG 是一种有向的语义信息网络,包含实体、概念以及实体对象间的各种语义关系. 伴随着人工智能 (AI) 的快速发展, KG 的作用日益凸显,逐渐成为 AI 发展的重要驱动力量. KG 是将客观世界的实体对象及其相互之间的关系以结构化的形式进行展现,模仿人类认识世界的方式,提高了人们对海量、多源、异构数据信息的组织管理、理解和访问能力.

尽管 KG 在现代科学和工程领域扮演的角色越来越重要,但是由于构建算法及演变复杂特征. 现有的 KG 质量仍然不够完美,影响下游任务的效果,如在不完整的 KG 上执行知识问答任务,则很难得到准确的答案. 另外, KG 中有数以亿级的节点和边,单纯依靠人工检索所有的事实元组去完善 KG,则需要投入大量的人力和时间成本,且效果不一定明显. 因而,人们寄希望于一种能够自动识别和预测事实三元组的技术来改善 KG 的质量. 知识图谱补全 (knowledge graph completion, KGC)^[10-12]由此应运而生,其目的是通过各种智能算法检索识别事实三元组,对缺失的信息 (如: 头实体或尾实体或关系) 进行预测完善,从而以较低的人力成本来实现 KG 质量的改善,进而提高下游任务的效果,如知识问答的准确性. KGC 技术是知识发现和获取的重要应用,目前主要途径是将整个 KG,包括实体及其相互关系,映射到低维的连续向量空间中 (知识图谱嵌入或表示学习),简化操作的同时保留 KG 固有结构,然后对低维嵌入式实体和关系进行预测,通过评分函数来表征其在该空间中的合理性,以提高 KG 的质量,使其内容更加丰富、信息更加完备.

近年来,尽管研究者们提出了大量的 KGC 模型,但是目前多数仍然是通过 KG 中观察到的事实进行嵌入式学习,再执行补全操作. 具体地说,给定一个不完整的 KG,首先对 KG 的实体和关系进行嵌入式学习得到相应的嵌入式向量,且给每个三元组设计一个评分函数衡量其在相应空间中的合理性. 由于整个过程学习的嵌入式仅在每个单独的事实中兼容,因此对下游任务的预测性不够强^[13]. 为此,越来越多的学者也开始探索进一步使用 KG 以外的其他辅助信息,如关系路径、逻辑规则、邻居信息等来学习更多的预测嵌入信息.

本文第 1 节介绍相关调研与一些符号定义. 第 2 节形式化定义了 KGC 及本文对已有 KGC 模型分类的规则. 第 3-5 节主要从基于零样本知识图谱补全、少样本知识图谱补全以及多样本知识图谱补全 3 个方面对已有的 KGC 模型进行了全面的综述,包括模型优缺点以及适应性进行了探讨. 第 6 节通过实验比较分析当前 KGC 模型的性能,并梳理现有 KGC 模型的不足和所面临的挑战. 第 7 节介绍 KGC 技术的一些典型应用,包括一般应用和华谱系统中的具体实现. 第 8 节对 KGC 未来可能的研究方向进行了探讨. 最后,第 9 节对全文工作进行总结.

1 相关调研与符号定义

1.1 相关调研

有关 KGC 综述性文章主要包括知识图谱嵌入^[14,15],知识图谱补全^[9,16-18],中文知识图谱构建^[19]以及知识表示学习^[20,21]等方面. Wang 等人^[14]总结了 2012-2016 年间的 KGC 模型,根据输入数据 (仅包括事实或辅助信息) 对 KGE (knowledge graph embedding) 模型进行粗略分组,但该项工作不是对 KGC 模型的具体概述,而是作为 KGE 下游任务的补充. Rossi 等人^[15]只总结了 16 个基于嵌入的 KGC 的链接预测方法. 然而,该项工作未提及 KGC 的其他任务. Shen 等人^[16]对多样本 KGC 模型进行了综述,但内容未涉及零样本和少样本 KGC 相关模型及具体应用. Gesese 等人^[22]对 KGC 模型做了简单总结,该工作主要集中与与文字信息相关的 KGE 技术,其文字信息包括文本描述、图像或其组合. 杜雪盈等人^[17]、吴国栋等人^[18]、Chen 等人^[23]和 Zamini 等人^[24]总结了已有的 KGC 模型,但只关注多样本 KGC 模型中的图结构有关的方法,忽视其他辅助信息的作用,更没提到零样本和少样本 KGC

方法及其应用. 彭晏飞等人^[25]概述了少样本 KGC 模型, 但未涉及零样本和多样本的 KGC 模型及应用, 更没对新兴技术大模型的补全技术进行探讨. Wang 等人^[26]和 Cai 等人^[27]梳理了动态时序 KGC 技术以及应用, 但没有囊括非时序特征的 KGC 技术及其应用. 也有工作^[28,29]简单陈述了 KGC 相关的研究, 但既未详细介绍具体的 KGC 技术, 也未涵盖主要的 KGC 方法. 与上述工作相比, 本文首次根据模型构建过程中所需样本数量对 KGC 模型进行归类, 并分别从零样本、少样本以及多样本这 3 类 KGC 技术的理论研究、实验分析和具体应用等方面对现有的 KGC 技术进行了全面综述, 并着重介绍了 KGC 技术在现实中的运用和具体实现, 如华谱系统. 同时, 总结了当下包括大模型在内的 KGC 技术所面临的挑战和未来可能的研究方向.

1.2 符号定义

本节定义几种基本符号, 定义任一不完整的知识图谱为 $G = (E, R, T)$, 其中 $E = \{e_1, e_2, \dots, e_{|E|}\}$ 是含有 $|E|$ 种不同实体的事实集合; $R = \{r_1, r_2, \dots, r_{|R|}\}$ 是有 $|R|$ 种不同关系的关系集合; 而 $T \subseteq E \times R \times E$ 表示事实三元组的集合, 一般格式为 (h, r, t) , 其中 h 和 t 分别表示头、尾实体, r 表示 h 和 t 间的关系. 例如三元组 (Beijing, CapitalOf, China) 表示 Beijing 和 China 之间存在关系 CapitalOf. 表 1 列举了一些基本符号及相关描述.

表 1 基本符号及描述

符号	描述	符号	描述
G	任一不完整的知识图谱	(h, r, t)	任一事实三元组
T	事实三元组集合	$(\mathbf{h}, \mathbf{r}, \mathbf{t})$	三元组嵌入表示
R	关系集合	E	实体集合
$s(h, r, t)$	评分函数	L	损失函数
$\circ$	Hadamard乘积	$\otimes$	Hamilton乘积

2 知识图谱补全概述

2.1 知识图谱补全形式化定义

给定一个不完整的知识图谱 $G = (E, R, T)$ 和知识图谱补全技术支持样本 S_r , 其中 $|S_r| = K$ 为样本的数量. 对于任一缺失的三元组, 基于评分函数找到一个潜在缺失三元组的候选集 T^* , 满足 $T^* = \{(h, r, t) | h, t \in E \text{ 或 } E^* (\text{实体超集}), r \in R, (h, r, t) \notin T\}$, 其中用评分最高的元组取代缺失的元组对知识图谱进行补全. 当 K 很小时, 称为少样本 KGC (few-shot knowledge graph completion, FKGC). 在极端情况下, K 为 0, 称为零样本 KGC (zero-shot knowledge graph completion, ZKGC). 在 K 很大时, 称为多样本 KGC (multiple-shot knowledge graph completion, MKGC). 表 2 总结了零样本、少样本和多样本 KGC 的特点.

表 2 知识图谱补全总结

KGC类型	优点	缺点	适用场景
零样本KGC	训练模型样本数据要求低; 稀疏图谱补全效果较好; 新实体凸现情形	对实体描述依赖; 复杂关系处理不好; 受文本长短噪声影响大; 测试数据匮乏	动态KG有新实体或新关系出现; 稀疏、连通性较差的知识图谱
少样本KGC	样本数要求少; 训练代价小; 稀疏图补全效果好	邻域噪音干扰; 少样本复杂关系学习较差; 路径稀疏查询困难	训练样本不足; 随时间连续变化的; 稀疏的知识图谱
多样本KGC	连通性好的知识图效果好; 学习更加丰富的语义和结构信息; 知识表示精度更高	训练数据要求较高, 训练代价较大; 不适应稀疏知识图; 复杂关系处理能力较弱	静态的、连通性好的、语义信息丰富的知识图谱

2.2 知识图谱补全技术研究

基于关键字“知识图谱补全”“knowledge graph completion”等在 DBLP、Web of Science 等数据库检索筛选了 100 余篇 KGC 相关文献. 根据模型构造所需样本的数量, 本文将已有的 KGC 模型分为零样本 KGC 模型、少样本 KGC 模型和多样本 KGC 模型. 其中, 零样本 KGC 模型分为基于描述信息以及大模型的模型, 少样本 KGC 模型分为基于度量学习、元学习、优化学习以及大模型相关模型, 而多样本 KGC 模型分为张量分解、神经网络、Trans

距离、大模型、多模态、辅助信息 (邻居信息、关系路径、逻辑规则和时序特性) 的模型. 根据分类, 本文对 KGC 模型主要研究如表 3 所示.

表 3 知识图谱补全模型概览

模型类别	模型技术分类	模型名称
零样本 KGC	描述信息	OWE ^[30] 、OWE-MRC ^[31] 、WOWE ^[32] 、EmReCo ^[33] 、ConMask ^[34] 、MIA ^[35]
	大模型	KG-BERT ^[36] 、MTL-KGC ^[37] 、MEM-KGC ^[38] 、KG-LLM ^[39] 、KoPA ^[40] 、MPIKGC ^[41] 、KG-LLM ^[42]
	度量学习	Matching-Nets、GMatching ^[43] 、FSRL ^[44] 、FAAN ^[45] 、TransAM ^[46]
少样本 KGC	元学习 ^[47,48]	MetaR ^[49] 、GANA ^[50] 、HiRe ^[51] 、Meta-iKG ^[52] 、Meta-KGR ^[53]
	优化学习	FIRE ^[54] 、ADK-KG ^[55] 、THML ^[56] 、ZSGAN ^[57]
	其他模型	CogKR ^[58] 、wRAN ^[59] 、AMmodel ^[60] 、KnowCo-Tuning ^[112] 、文献 ^[61] 、GPT-3 ^[62] 、KoPA ^[40] 、MuKDC ^[63]
多样本 KGC	张量分解	RESCAL ^[64] 、DistMult ^[65] 、Complex ^[66] 、QuartE ^[67] 、TuckER ^[68] 、ANALOGY ^[69]
	神经网络	ConvE ^[70] 、InteractE ^[71] 、ConvKB ^[72] 、ConvR ^[73] 、R-GCN ^[74] 、TransGCN ^[75] 、SACN ^[76] 、COMPGCN ^[77]
	Trans距离 ^[78]	TransE ^[79] 、TransH ^[80] 、TransR ^[81] 、TransD ^[82] 、lppTransD ^[83] 、TransF ^[84] 、TransM ^[85] 、ITransF ^[86]
	邻居信息	TransE-MRR ^[87] 、LENA ^[88] 、G2SKGEatt ^[89] 、RGHAT ^[90] 、CACL ^[91] 、CNNIM ^[92] 、CAFE ^[93]
	关系路径	mh-KGC ^[94] 、PRA ^[95] 、PRA+ ^[96] 、PATH-RNN ^[97] 、PTransE ^[98] 、RTransE ^[99] 、PTransD ^[100]
	逻辑规则	MLN-based ^[101] 、NeuralLP ^[102] 、TensorLog ^[103] 、RLvLR ^[104] 、NTP ^[105] 、AnyBURL ^[106] 、ELPKG ^[107] 、RPJE ^[108]
	时序特征	T-TransE ^[109] 、ST-TransE ^[110] 、HyTE ^[111] 、TDG2E ^[112]
	大模型	KG-BERT ^[36] 、MTL-KGC ^[37] 、KG-LLM ^[39] 、KEPLER ^[113] 、KoPA ^[40] 、TSTR ^[114] 、K-BERT ^[115]
	多模态	RSME ^[116] 、MULTIFORM ^[117] 、MMSN ^[118] 、HRGAT ^[119] 、MACO ^[120] 、AdaMF-MAT ^[121] 、NativeE ^[122] 、MoSE ^[123] 、MNFormer ^[124] 、MyGO ^[125] 、MOMOK ^[126]

注: 文献^[39]及文献^[42]提出的模型名称均为KG-LLM, 后文使用不同文献编号作为上标来区分两者

3 基于零样本 KGC (ZKGC) 模型

零样本知识图谱补全 (zero-shot KGC, ZKGC) 模型指的是在模型构造过程中, 无需标记的训练样本训练模型. 根据采用的技术, 进一步分为基于描述信息和大模型的 ZKGC 模型.

3.1 基于描述的 ZKGC 模型

基于描述的 ZKGC 模型指的是借助描述信息如实体描述来学习没样本实体及关系的表示. OWE^[30]扩展封闭空间 KGC 模型对新实体预测. 然而, OWE 忽视了实体描述长短对表示学习的影响, OWE-MRC^[31]在学习实体文本表示前采用 MRC (机器阅读理解模型) 对长文本描述进行预处理提高 OWE 的稳定性. 考虑实体描述中不同的词有不同的特性, WOWE^[32]摒弃平均聚合, 采用加权注意力机制聚合器对实体描述的词嵌入进行聚合, 提高了聚合效率. 考虑到关系限制对表示学习的积极影响, EmReCo^[33]提出特定关系的映射机制, 限制实体文本嵌入对齐到图空间的特定位置, 提高了预测的性能. ConMask^[34]通过实体名称及部分描述与已有 KG 建立联系, 借助特定关系屏蔽器减少不相关信息的影响. 但 ConMask 没充分挖掘实体描述特征, 一些潜在的语义和统计信息易丢失. MIA^[35]引入多重交互的注意力机制捕获与关系相关的文本描述, 进而提高模型的整体性能. 以上表明文本描述能够辅助提高表示学习的性能, 然而现实中很难获取每个实体或关系的高质量文本描述. 表 4 总结了基于描述的 ZKGC 模型.

表 4 基于描述的 ZKGC 模型

模型名称	优点	不足
OWE ^[30]	能够预测凸现实体和已有KG的关系; 新实体无需重新训练模型, 减少训练代价	忽视实体描述长短, 引入不相关信息甚至噪音; 平均聚合忽视描述中不同词的特性
OWE-MRC ^[31]	精炼长描述提高性能; 新实体无需重新训练模型, 减少训练代价	平均聚合忽视文本描述中不同词具有不同特性; 可能引入不相关信息或噪音
WOWE ^[32]	无需重新训练模型避免高昂开销; 注意力机制提高表示学习性能	忽视特定关系的作用, 引入与关系无关的信息, 削弱了模型表示学习性能

表 4 基于描述的 ZKGC 模型 (续)

模型名称	优点	不足
EmReCo ^[33]	无需重新训练模型避免高昂开销; 注意力机制和特定关系限制减少无关信息的干扰	对多模态知识图任务效果不明显; 模型相对复杂, 产生额外时空开销
ConMask ^[34]	新实体文本表示与已有图谱建立联系; 特定关系屏蔽器减少不相关信息及噪音干扰	文本描述信息特征使用不充分; 特定关系的屏蔽器易错过目标相关词
MIA ^[35]	多重交互注意力机制充分捕获实体间交互信息; 充分挖掘文本和图结构语义信息	模型相对复杂, 时间复杂度较大; 不同词的特性没充分考虑, 易受不相关信息影响

3.2 基于大模型的 ZKGC 模型

预训练语言表示模型 (pre-trained language model, PLM) 在自然语言处理中表现出优越的性能. KG-BERT^[36]首次将 PLM 用于知识图谱补全, 将知识图谱的三元组看成文本序列, 则 KGC 问题被转化成序列分类问题. KG-BERT 在 KGC 上效果显著, 但在排序指标上不理想. 为此, MTL-KGC^[37]提出了多任务学习框架提高 KG-BERT 的性能. MEM-KGC^[38]通过规避频繁的负采样降低时间开销. 扩展已有 PLM 规模对下游任务效果显著. 因此, ChatGPT 和 GPT-4 等大语言模型得到广泛关注. KG-LLM^[39]使用大模型丰富的实体和关系语义描述作为提示, 并利用响应进行预测, 表现出较好的性能, 尤其对新实体的预测. 然而, 其忽视了 KG 中关键结构语义信息, 严重限制了其推理能力. KoPA^[40]提出将三元组结构信息融入到 LLM 中, 以促进模型的结构感知推理能力. MPIKGC^[41]从不同角度查询 LLM 包括推理、解释和总结能力扩展实体描述、理解关系和捕捉结构以弥补其上下文学习的不足. KG-LLM^[42]通过学习实体及关系的表示将结构图谱转化成自然语言提示微调 LLM, 提高其多条链路预测能力. 大模型包含丰富的知识库, 囊括几乎所有实体对象的名称及其文本描述, 有效缓解传统方法对客观实体描述受限的缺陷. 通过提供丰富的语义信息和推理性能极大地推动了包括 ZKGC 的补全技术的发展. 然而, 大模型工作类似于黑匣子, 对捕获的事实缺乏一定的可解释性. 同时, 大模型经常产生幻觉和庞大的参数规模带来的巨大计算开销等问题, 限制其泛化能力. 表 5 总结了基于大模型的 ZKGC 模型.

表 5 基于大模型的 ZKGC 模型

模型名称	优点	不足
KG-BERT ^[36]	充分利用上下文和外部语料信息, 提高了表示学习精度; 对零样本学习效果显著; 同时适用少样本、多样本补全情形	未对知识图关联信息进行建模; 排序性能表现不理想; 计算开销较大; 对相似信息区分能力较差
MTL-KGC ^[37]	多任务学习框架, 学习更多的关联信息; 在相似的词汇时也能正确执行; 一定程度上提高了排序指标	效果提升不是很明显, 在不同数据上表现不稳定; 计算开销较大
MEM-KGC ^[38]	结构相对简单, 避免负采样, 一定程度上缓解了部分计算开销; 对未见实体链接预测也具有较好的效果	计算开销较大; 未充分使用图结构信息, 往往导致次优解
KG-LLM ^[39]	扩大语言表示模型的规模, 提高自然语言处理能力; 补全性能得到显著提高; 零样本和少样本中都表现良好	参数规模很大, 计算开销较大; 性能可解释性较差; 效果不稳定, 易出现幻觉问题
KoPA ^[40]	利用图结构语义和文本语料信息; 结构嵌入式表示作为提示, 改善了补全的性能; 适用零样本和少样本情形	结构比较复杂, 计算开销较大; 效果不稳定, 时常出现幻觉问题; 可解释性较差
MPIKGC ^[41]	丰富了实体描述, 改进传统 PLM 模型现实世界实体描述不足问题; 提高推理能力; 改善了实体描述的质量;	计算开销较大; 可解释性较差; 大模型幻觉问题, 性能不够稳定
KG-LLM ^[42]	改善提示模版微调 LLM, 提高了补全性能; 多条链路预测能力较高; 推理能力较强	可解释性较差; 大模型幻觉问题, 性能不够稳定; 参数规模较大, 计算开销大

ZKGC 模型对训练样本的规模没有特别要求, 其中基于描述的方法仅需要部分文本描述就可以学习零样本实体关系的表示弥补传统依赖图谱连通性的 KGC 模型的不足, 如有限的结构信息难以对长尾实体表示等, 但是获取每个实体关系高质量的描述是不现实的. 相比之下, 大模型技术能够提供丰富的实体关系语义, 几乎包含所有实体的名称和描述, 以弥补基于描述 ZKGC 模型的不足.

4 基于少样本的 KGC (FKGC) 模型

少样本的 KGC 模型指的是现实中互联网社交媒体产生的 KG, 数据频繁更新, 最后只剩下少量完备的关系三

元组数据, Xiong 等人^[43]提出少样本 KGC (FKGC) 的概念并提出采用 GMatching 模型解决 FKGC. 根据解决问题的角度, 已有的少样本 KGC 方法可以分为基于度量学习、元学习、优化学习以及大模型的方法.

4.1 度量学习的 FKGC 模型

基于度量学习的 FKGC 模型从训练任务中学习一般通用的距离公式或匹配函数, 然后推广到新的任务. 已有的基于度量的 FKGC 模型通常共享基于匹配网络的框架. GMatching^[43]使用局部图结构和实体嵌入信息构建匹配函数, 包括邻居编码器和匹配处理模块. 与传统 KGC 模型相比, 该模型可对任意关系预测, 无需重新训练模型, 训练代价较低. 然而, 该模型邻居编码器通过平均聚合捕获实体邻域表示, 忽视无效实体的负面影响. 为此, FSRL^[44]采用注意力机制的关系感知异构邻居编码器对不同邻域信息分配不同的权重, 同时聚合更多的三元组信息增强交互, 减少无效实体影响. 但是, FSRL 在所有的任务关系中给不同的邻居分配固定的权重, 影响系统有效性. 因此, Sheng 等人^[45]提出 FAAN 模型, 它采用自适应注意力邻居编码器动态获取实体预训练的嵌入及其角色感知的邻居嵌入, 同时使用 Transformer 获取关系和实体对嵌入的动态信息, 提高了模型的鲁棒性. 然而, FAAN 的邻居编码器只针对实体的动态信息进行改善, 忽视了三元组间和三元组内的交互信息. 实体交互能够提供有价值的细粒度语义信息, TransAM^[46]将查询实体和参考实体序列化为序列, 并应用具有局部全局注意力机制的转换器结构来捕获三元组实体内部和实体间的交互信息. 与其他模型比, 该模型能够捕获更多的三元组结构语义, 但忽视了三元组内部的信息, 不能很好地处理复杂少样本关系. 基于度量学习的 FKGC 模型, 在改进已有方法不足的同时, 也在寻求更好的匹配方法计算参考集和查询集相似得分. 表 6 总结了基于度量学习的 FKGC 模型.

表 6 基于度量学习的 FKGC 模型

模型名称	优点	不足
GMatching ^[43]	局部图信息; 能处理新关系, 无需重新训练模型, 代价小	忽视无效实体的影响, 对邻域中的信息看成同等重要, 没有区别看待
FSRL ^[44]	不同邻域信息赋予不同权重; 增加参考三元组集成更多的语义信息	给邻域不同信息赋予静态的权重, 导致实体固定嵌入, 影响系统整体性能
FAAN ^[45]	使用实体和关系动态属性特征自适应动态加权	淡化了实体三元组内部和三元组间的交互特征
TransAM ^[46]	捕获三元组内部和之间的交互信息; 新的匹配函数	三元组内部信息使用不足; 不能处理复杂的少样本关系

4.2 元学习的 FKGC 模型

元学习 (meta learning)^[47], 又称学会学习^[48], 旨在帮助新任务在训练样本匮乏的场合快速学习. 在 FKGC 中, 元学习在训练任务中学习对应三元组的公共特征, 然后在新的任务上泛化使用, 典型的有 MetaR、GANA、Meta-iKG 等模型. MetaR^[49]是元学习在 FKGC 上的首次尝试, 核心是特定关系元生成器生成实体对表示, 梯度元加速模型迭代学习以完成 FKGC 任务. MetaR 能最大限度减少查询损失总和, 独立于参考集, 因此更加稳健. 但是, MetaR 计算关系元时忽视了参考集中不同实体三元组对关系表示的作用不同. GANA^[50]采用全局和局部结合的框架, 借助注意力机制和 LSTM 聚合器改进 MetaR 嵌入和关系元计算, 以减少在稀疏或缺少恰当邻居表示少样本关系时噪音邻居的影响. 然而, 该模型在 N-N 复杂关系上表现不佳. HiRe^[51]扩展 GANA 提出联合捕获包括实体、三元组及上下文这 3 个级别关系信息的框架, 以实现更好的性能. 但是, 训练参数和复杂度相对较高. 基于 MetaR, Meta-iKG^[52]用局部子图传递子图特定消息, 并通过元梯度和元学习快速学习可转移模式. 与其他元学习模型相比, Meta-iKG 引入多样本关系学习的更新过程以对少样本学习进行泛化. 然而, 它只能提取子图结构语义, 无法对有向图反对称关系建模. 同时, 对任务查询集参数的学习存在偏差. Meta-KGR^[53]把元学习和强化学习相结合, 用强化学习训练代理搜索目标尾实体和推理路径, 同时元学习参数快速适应少样本的任务. 该模型能够提供多条路径推理, 且解释性较好. 但是, 推理性能对路径依赖较强, 缺失路径时, 效果较差. 上述方法都是基于元学习的典型, 各个关注的方面不同, MetaR 关心元学习解决少样本学习问题, GANA 强调消除邻居噪音, HiRe 捕获 3 个级别的关系信息丰富学习特征, 而 Meta-iKG 则关注用局部子图建模处理 FKGC 和 Meta-KGR 侧重元学习和强化学习结合等. 表 7 总结了基于元学习的 FKGC 模型.

表 7 基于元学习的 FKGC 模型

模型名称	优点	不足
MetaR ^[49]	关系元学习实体的嵌入; 梯度元加速更新以适应更新的关系; 查询损失少	忽视了参考集中不同实体三元组对关系表示的作用不同
GANA ^[50]	门控注意力机制过滤邻居噪音; GAT提高实体嵌入质量; 可处理复杂关系建模	在N-N复杂关系效果不佳
HiRe ^[51]	三级别关系学习; 交互信息更丰富	模型训练参数规模较大, 复杂度较高
Meta-iKG ^[52]	局部子图建模; 多样本关系更新; 元学习加速迭代适应	只提取结构语义, 对有向图的反对称关系建模效果不好
Meta-KGR ^[53]	元学习和强化学习结合; 多条路径推理, 可解释性较好	推理过程对路径依赖性强, 找不到没有路径的查询结果

4.3 优化学习的 FKGC 模型

基于优化学习 FKGC 模型依赖 MAML (model-agnostic meta-learning) 进行模型优化, 即这种模型采用 MAML 优化 GNN 来解决少样本关系预测问题的挑战. FIRE^[54]使用异构邻居聚合器和搜索空间修剪策略扩展了 Meta-KGR, 旨在采用强化学习对多跳推理的路径进行建模, 并用元学习进行优化, 以快速适应少样本任务关系. 与 Meta-KGR 比, FIRE 能够对异构图结构编码, 获取更加丰富的语义, 且具有较强的可解释性. 但是, 该模型只对推理过程编码, 忽视了 KG 上下文和结构信息. ADK-KG^[55]借助预训练语言模型在 FKGC 任务上获取上下文信息预训练实体和关系嵌入, 并通过自注意力机制分配不同的权重区分不同关系的不同含义. 然而, 该模型受限于硬关系的低推理性能, 关系训练损失太大. 另外, 模型在训练阶段倾向于推断具有相似语义的路径, 使得模型结果局部最优. 为此, THML^[56]识别训练集中的硬关系, 并聚类这些关系生成新的硬度感知训练集以进一步训练模型. 同时, 采用多样性奖励机制鼓励模型寻找不同的路径. 然而, 该模型更复杂, 时间复杂度较高. ZSGAN^[57]利用生成对抗性网络建立文本和知识图之间的联系, 通过文本描述表征新标签的语义特征. 该模型能够适应少样本和零样本条件下的关系预测, 但对多条路径关系推理性能不好. 表 8 中总结了基于优化的 FKGC 模型.

表 8 基于优化的 FKGC 模型

模型名称	优点	不足
FIRE ^[54]	关系元学习; 强化学习; 多条路径推理; 异构知识图语义, 解释性强	只对推理过程编码, 忽视知识图上下文和结构信息
ADK-KG ^[55]	预训练语言模型获取上下文语义信息; 自注意力机制获取不同关系语义	硬关系低推理性能, 训练损失大; 模型倾向相似语义的路径, 局部最优解
THML ^[56]	识别硬关系, 减少关系训练损失; 多样性奖励机制寻找不同的关系路径	模型训练参数规模较大, 复杂度较高
ZSGAN ^[57]	生成对抗性网络, 少样本和多样本情形	多路径推理性能不好

4.4 大模型的 FKGC 模型

除了以上 3 种思路外, 也有研究探索其他思路, 为后续研究提供了新的方向. CogKR^[58]模拟人类推理逻辑的过程 (检索和推理) 来获取最终预测结果. 相比其他方法, 认知图谱数据结构更加灵活, 检索效率高 (局部子图), 可以大大降低时间复杂度, 因而可扩展到大型 KG 上. 但是, 对于长路径的推理, CogKR 效果不明显, 需要借助更多的辅助信息以增强推理能力. 受对抗迁移学习的启发, wRAN^[59]将对抗迁移学习和少样本学习相结合, 采用门控机制减少迁移过程负迁移影响. 该模型在少样本提取关系效率显著. 但是, 语义相似的不相关样本区分性不强. 基于注意力机制, AMmodel^[60]设计了一种新的匹配函数优化 GMatching 匹配构件以适应少样本场景. 该模型可以学习更多的关系表示, 减少训练参数规模. 但是, 实体嵌入仅简单拼接实体关系信息, 忽视了实体邻居的噪音影响. 近年来, 大模型在自然语言处理领域的优异表现以及快速发展, 结合 KG 结构的显示知识和 PLM 以及 LLM 的隐式知识是值得研究的方向, 研究者关注如何使用提示学习对下游任务微调以改进效果. 代表性工作包括: 张宁豫等人^[12]提出 KnowCo-Tuning 协同微调算法学习最优模板和标签计算模. 该模型可扩展性强, 但是其忽视实体邻域信息.

Li 等人^[61]利用 PLM 在语言理解和生成方面的出色能力, 自动生成知识图谱相关实体关系的文本描述用于少样本知识图谱补全. GPT-3^[62]通过在给定训练提示和无输入时估计模型的回答偏差, 然后拟合校准参数, 提高预测的准确率, 减少不同提示选择之间的差异. 扩大语言模型规模可以极大地提高任务无关性、少样本学习的性能. 然而, 以上基于语言模型的研究未能充分考虑图结构语义信息, 进而限制了其推理能力. KoPA^[40]将结构信息整合到大模型中, 以促进结构感知推理. 针对少样本知识图的长尾实体问题, MuKDC^[63]使用大模型生成知识弥补少样本情形下数据稀缺, 通过多级知识蒸馏技术补全少样本知识图谱. 大模型的 FKGC 技术缓解了少样本情形下数据稀缺问题, 提供更加丰富的语义促进性能的提高. 然而, 大模型工作类似黑匣子, 对捕获和获取事实知识及推理过程缺乏一定的可解释性. 同时, 还有幻觉问题和巨大的计算开销一定程度上限制了其泛化能力. 表 9 总结了基于大模型的 FKGC 方法.

表 9 基于大模型等的 FKGC 模型

模型名称	优点	不足
CogKR ^[58]	结构灵活, 检索效率高, 时间复杂度低, 适应大型图谱	对长路径推理能力差
KnowCo-Tuning ^[12]	预训练语言模型提供丰富的语义、可扩展性强	直接使用实体信息, 忽视了实体邻域信息的作用
wRAN ^[59]	门控机制解决负迁移; 关系提取效果较好, 适合少样本学习	对语义相似的不相关样本的区分能力不是很强
AMmodel ^[60]	丰富的关系表示; 训练参数规模小, 训练负担较小	实体嵌入简单拼接, 忽视实体邻域噪音的影响
KoPA ^[40]	大模型提供丰富的知识; 解决长尾问题; 提供结构语义, 推理性能	模型参数规模较大, 时空开销较大; 可解释性较差; 性能因数据而异
MuKDC ^[63]	提供丰富的知识缓解数据稀缺; 解决长尾问题	计算资源消耗较大; 可解释性较差; 性能不稳定

FKGC 方法包括基于度量学习、元学习、优化学习以及大模型相关的方法, 它们对训练样本数据的规模要求不是很高. 基于度量的方法聚焦学习丰富的关系嵌入信息和优化匹配算法. 基于元学习的方法侧重于少样本学习和消除邻居噪音. 优化学习侧重采用优化方案对嵌入学习以及性能进行优化. 结合元学习和优化学习可以实现快速学习和效果提升, 且能同时适应 ZKGC 和 FKGC 场景. 大模型相关方法为少样本 (训练样本不足) 的 KGC 提供丰富的语义和推理性能, 因此能够表现出较好的性能, 能够同时适应 ZKGC 和 FKGC 情形.

5 基于多样本的 KGC (MKGC) 模型

基于多样本的 KGC (MKGC) 模型指这些模型在构造过程中, 需要很多训练样本. MKGC 模型可以分为张量分解、神经网络、Trans 距离、辅助信息、大模型、多模态的方法.

5.1 张量分解的 MKGC 模型

张量分解 (tensor factorization, TF) 是矩阵分解在高阶上的泛化, 该类模型用张量表示 KG 中的事实三元组及其内部相互关系, 用张量乘积来捕获丰富的相互关系. 整个 KG 可以看成是一个三阶二元的张量 (如图 1), 其中每一个元素代表一个三元组. 张量分解旨在推断出一个张量近似替代目标. 该类模型一般处理高维数据和复杂的关系模式效果较好, 但是参数规模较大, 训练代价比较高.




图 1 知识图谱张量表示

典型的 TF 模型如 RESCAL^[64]将 KG 表示成三元张量, 如图 1. RESCAL 通过矩阵分解从相应三元组中获取特征信息以预测其他缺失关系的三元组中关系. 为降低 RESCAL 的复杂度, DistMult^[65]用对角矩阵替换其满秩矩阵. 然而, 乘积算子在实数上的对称性质使得 DistMult 只能对对称的关系进行建模. ComplEx^[66]引入复数域, 在复数空

间对实体进行向量化, 能够对复杂的非对称关系进行建模. 因此, 该模型能同时处理好对称和非对称关系. QuatE^[67]创造性地引入超复数表示, 表现力更强, 通过四元组空间中的旋转来表示关系. QuatE 是 ComplEx 在超复杂空间上的推广, 几何解释性更好, 也满足对称、反对称等复杂关系的建模. TuckER^[68]分解模型和张量分解诸多模型都是基于三阶二元张量对 KG 中三元组进行补全, 而 TuckER 模型用 TuckER 分解技术处理张量分解问题. TuckER 分解是一个强大的线性模型, 对二元张量表示, 参数较少, 效果好. 因此, 它能跨关系进行多任务学习. 然而, TuckER 分解并不唯一, 如果对矩阵进行逆变换, 核心张量在不影响拟合的情况下也进行变换. 不同于 TuckER 分解, DEDICOM 分解能够检测多个互连节点之间的相关性. 另外, ANALOGY^[69]是 RESCAL 的扩展, 它对实体和关系嵌入的类比特性进行显式建模, 应用了 RESCAL 中的双线性评分函数, 但受限于关系映射矩阵必须是正规且正交的. 表 10 总结了基于张量分解的 MKGC 模型.

表 10 基于张量分解的 MKGC 模型

模型名称	优点	不足
RESCAL ^[64]	张量化知识图, 实现简单	结构单一, 不能处理复杂关系模式
DistMult ^[65]	实现简单, 可以处理对称关系	矩阵乘积计算开销大; 不能处理非对称关系
ComplEx ^[66]	引入复数域, 可处理对称和非对称关系; 双线性评分函数更加精准	实现比较复杂, 计算开销大
QuatE ^[67]	引入超复数域, 处理复杂关系, 表现力强, 解释性好	结构较复杂, 训练代价较大
TuckER ^[68]	线性分解, 参数规模小, 多任务学习	TuckER 分解不唯一, 结果具有随机性
ANALOGY ^[69]	显性建模, 双线性评分, 可处理复杂关系	矩阵运算计算代价较大

5.2 神经网络的 MKGC 模型

神经网络中 2D 卷积操作比 1D 卷积能够获得更多的交互点, 可以获取更多的交互特征, 以实现更强的表现能力. ConvE^[70]在图嵌入上采用链接预测的多层 2D 卷积替代 1D 卷积来探索更有价值的特征交互. 它只需较少的参数就能实现对具有高阶节点数高规模的 KG 高效建模. InteractE^[71]增加捕获的交互促进链接预测效果, 进一步提升 ConvE 性能. 基于 ConvE, ConvKB^[72]采用 1D 卷积对单个实体和关系之间的拼接操作进行了改变, 将不同的实体嵌入拼接重塑以获得实体间更多的交互特征. 但是, 拼接和重塑都无法保证嵌入式学习的整体部分都能够参与交互过程. ConvR^[73]将关系嵌入表示作为卷积核, 确保实体和关系之间获得最大的交互. 但是, 卷积核是不可分割的固定维度的张量, 因而限制了其泛化水平. 由于张量的边角、中心区和卷积核之间的交互程度差异使得 CNN 很难均匀的获取实体和关系之间的嵌入特征, 而 InteractE 基于循环卷积计算, 使卷积核免受边界限制影响, 因此可以获取更多的交互特征.

图卷积网络 (GCN) 将图中的数据通过映射函数聚合自身和邻域特征信息, 但对邻域信息的聚合是采用统一的函数来实现的, 因此没有对不同的邻域节点、关系加以有效区分. R-GCN^[74]根据节点之间不同的关系对其相应的节点采取不同的信息聚合方式, 对局部图邻域操作实现 KGC 任务, 能够防止稀疏关系的过度拟合和模型参数的过度增长. 但它的训练代价较大, 参数量多, 且聚合时没考虑关系本身, 因此对于实体和关系嵌入特征的捕获不充分. 在不同的语义环境中, 实体之间的关系会随之发生变化, 因此, 实体之间的关系是有方向的. TransGCN^[75]通过基于消息传递的实体和关系更新, 并定义实体间关系的方向. 通过传递的消息嵌入, 与消息和实体特征结合可以获得更丰富的实体特征. SACN^[76]是一种端到端模型, 利用多个 WGCN 层堆栈学习图结构及属性信息, 可缓解过度参数化问题. COMPGCN^[77]对与关系相关的相邻节点执行 KGE 来缓解过度参数化问题, 通过共享关系嵌入实现可扩展性. COMPGCN 比 R-GCN 更具参数有效性. 后文表 11 总结了基于神经网络的 MKGC 模型.

5.3 Trans 距离的 MKGC 模型

Trans 模型是简单高效的 KGC 模型, 它将实体及关系编码为低维嵌入, 并将实体之间的关系编码为 Trans 向量^[78]. 典型的 TransE^[79]将整个 KG 编码嵌入到同一个低维连续的向量空间, 实体间关系看成是实体之间的平移操作. 然而, TransE 太简单, 处理不好复杂的关系. 因此, TransE 得到进一步扩展. TransH^[80]在引入了一个特定关系对

应的矩阵 (一个超平面), 基于矩阵相乘执行投影操作实现实体到超平面的映射, 然后在该超平面上执行向量平移操作. 由于实体在不同语义关系下有不同的语义, 但 TransH 只考虑了一个语义环境, 因此获取的上下文语义不够丰富, 表现力较弱. 考虑到实体及关系之间存在语义差异, TransR^[81]分别在不同的实体、关系空间中构建实体和关系的嵌入. 然后, 对实体和关系一一建立映射得到相同实体在不同语义环境中的关系表示. 尽管 TransR 处理复杂关系表现较好, 但涉及太多额外参数导致对大型 KG 学习的鲁棒性和可扩展性较差. TransD^[82]通过给头尾实体分配不同的关系映射矩阵来进一步提高 TransR 性能, 并通过矩阵乘法替换为向量乘法以加速计算效率. lppTransD^[83]进一步扩展 TransD, 认为传递性和对称性等关系的逻辑性质不能通过对头部和尾部实体使用相同的投影矩阵来表示. 与 lppTransD 类似, TransF^[84]用相同的思想分别计算头/尾实体的投影矩阵. 不同的是, TransF 使用独立的矩阵对投影矩阵建模以减轻关系投影的负担. 相比于 TransR, TransF 具有健壮和轻量级的特点, 可以处理大规模的 KG. 针对 TransE 不灵活, TransM^[85]根据训练集中三元组对优化目标的作用大小为每个三元组分配不同的权重. 充分利用关系的共享特性, ITransF^[86]使用稀疏注意力机制来发现共享规律来充分捕捉关系和共享概念之间的隐藏关联. 表 12 总结了基于 Trans 距离的 MKGC 模型.

表 11 基于神经网络的 MKGC 模型

模型名称	优点	不足
ConvE ^[70]	2D卷积, 交互信息丰富, 表现力强	链接预测效果较差; 存在测试泄露问题
InteractE ^[71]	检查重塑, 交互特征充分; 循环卷积免受边界限制, 表现力更强	模型相对比较复杂; 不能保证整个KG嵌入参与交互
ConvKB ^[72]	1D卷积, 结构较简单	交互较弱, 表现力不强
ConvR ^[73]	实体和关系交互最大化; 效果明显提高	卷积核维度固定, 模型泛化能力不强
R-GCN ^[74]	局部图邻域节点和关系有效区分; 可避免过拟合; 可处理稀疏关系	实体节点, 忽视了关系本身信息获取; 训练参数规模大
TransGCN ^[75]	显性建模, 双线性评分, 可处理复杂关系	矩阵运算计算代价较大
SACN ^[76]	不同关系加以区分; 性能较好	模型泛化能力弱, 局限于图数据处理
COMPGCN ^[77]	特定关系邻居, 减少噪音影响; 缓解过度参数化	可扩展性差, 泛化能力弱

表 12 基于 Trans 系列的 MKGC 模型

模型名称	优点	不足
TransE ^[79]	实现简单; 计算效率高; 时空开销小; 训练复杂度低	过于简单, 难以处理复杂关系模式; 上下文语义难以获取
TransH ^[80]	引入超平面, 可以处理相对简单的复杂关系	只考虑了同一个语义环境, 语义不够丰富
TransR ^[81]	不同环境不同语义表示, 语义更丰富; 可处理复杂关系	参数规模大; 模型鲁棒性和可扩展性差
TransD ^[82]	关系映射语义丰富, 表现力强, 计算效率高; 处理较丰富的复杂关系	结构相对较复杂; 训练代价较高
TransF ^[84]	关系投影负担小; 轻量级; 健壮性好	稀疏性数据效果差
TransM ^[85]	灵活性好; 注意力机制; 可解释性较好; 挖掘潜在关联	结构较复杂, 训练过程代价较大

5.4 辅助信息的 MKGC 模型

辅助信息在 KGC 任务中发挥重要作用, 如邻居信息、关系路径、逻辑信息、时序信息等. 早期的 NMM^[87]将有邻居信息的 TransE 合并为 TransE-MRR, 仅学习邻居上的固定混合, 但易受噪音干扰. 受注意力机制启发, LENA^[88]使用注意力机制以加权组合的方式聚合邻居, 避免邻居不相关信息的影响. G2SKGEatt^[89]使用融合注意力机制 Graph2Seq 学习 KG 中实体的子图结构信息嵌入. 考虑到表征一个实体不同关系的重要性有差异并且同一关系不同邻居实体的重要性不同, RGHAT^[90]通过一种新颖的分层注意力机制来计算不同相邻关系和实体的不同权重. CACL^[91]是利用相邻上下文信息探索实体之间连接模式, 使用多跳邻域中包含的连接模式来促进实体和关系嵌入的学习. CNNIM^[92]使用最近邻概念执行链接预测识别公共图模式中的相似实体. 由于只在推理步骤中花费时间, 因此降低了训练时间的消耗, 且具有较好的可解释性. CAFE^[93]使用邻域感知特征集为每个关系训练模型, 直接使

用 KG 连通性而不需要对其进行预处理, 因此适用于规模不断扩大的 KG.

KG 中多跳关系路径可以表示实体间丰富的语义关系, 反映知识图中关系之间复杂的推理模式, 有助于促进基于路径的关系推理的发展. mh-KGC^[94]旨在基于关系路径推理实现 KGC 任务. PRA^[95]是在大型 KG 中学习推理路径的方法, 基于深度优先搜索使用随机游走策略生成给定实体对之间的关系路径. 然而, PRA 具有特征爆炸问题和巨大的计算开销. PRA+^[96]是 PRA 的扩展, 更高效且更具表现力, 通过预先训练的关系向量表示来缓解特征爆炸问题, 但他们的核心机制仍然是基于原子路径特征的分类器. PATH-RNN^[97]将路径视为非原子特征, 不仅可以在路径上联合推理, 还可以推导到向量嵌入空间中, 以非原子和组合的方式对路径的元素进行推理. 将多跳路径信息引入到经典翻译模型中, PTransE^[98]为每个现有关系创建反向关系, 使 KG 中的边数加倍并且使用路径约束资源分配算法来选择可靠路径输入. RTransE^[99]把 TransE 中学习的关系组成关系序列, 在路径之间进行推理以达到预期的结果. PTransD^[100]是一个路径扩充的 TransD, 认为关系路径是 KG 中实体之间的转换. PTransD 将实体和关系考虑到不同的语义空间中, 对每个实体和关系同时采用两个向量表示.

逻辑规则通过有关专业领域知识的规则来转移特定领域的知识, 使得基于规则的推理实现较高的精度. 此外, 逻辑规则独立于任意实体, 可解释性较好. MLN-based^[101]在最大似然估计下使用 MLN (Markov logic network) 执行 KGC 任务, 并从理论上讨论了数据缺失情况下从 KG 中学习 MLN 权重的适用性. NeuralLP^[102]是一种端到端可微框架, 它结合了一阶规则推理和稀疏矩阵乘法, 可以同时学习逻辑规则的参数和结构. 此外, 它通过注意力机制神经控制器为逻辑规则分配不同的置信分数控制 LSTM 中 TensorLog^[103]的可微运算合成过程, 以学习可变规则长度. RLvLR^[104]利用 RESCAL 嵌入技术从 KG 中学习规则, 在谓词和自变量嵌入空间中引入引导规则的挖掘以解决规则挖掘可扩展性问题. 相对于 NeuralLP, RLvLR 在规则质量和系统可扩展性方面都表现良好. 类似于 NeuralLP, NTP^[105]专注于神经网络和规则推理的融合, 按照 ProLog 中提到的反向链接对神经网络进行建模. 但是 NTP 计算复杂, 可扩展性较差. AnyBURL^[106]自下而上地从大型 KG 中学习逻辑规则, 是一个有效的规则挖掘器. 通过学习模糊、不确定的规则, 候选排名可以通过生成排名的规则来解释, 所以具有很好的解释性. 同时, 运行速度快, 资源使用较少. ELPKG^[107]将路径信息、嵌入表示和软概率逻辑规则结合在一起实现 KGC 任务, 能够缓解知识不一致和冲突问题, 具有很高的运行效率和链接预测精度. RPJE^[108]通过 Horn 规则结合路径和语义级别的关联关系, 将逻辑规则和路径表示结合, 充分利用逻辑规则的准确性和可解释性的优势.

现实的 KG 动态变化具有时序特征, 如 Twitter 中社交 KG, 只有在一定时间段内有效, 这类 KG 的补全称为时序知识图谱补全 (TKGC). 将时间戳与相应的实体或关系相关联, 以实现实体或关系的演变. T-TransE^[109]扩展了经典的 TransE 模型, 在同一嵌入空间中引入时间戳一起学习, 认为特定事件的发生时间可以表示事实和关系的特定时间顺序. 但是, 该模型不是直接学习时间的嵌入, 而是先学习关系之间的时间关系, 然后作为约束. 因此, 该嵌入不是显示时间感知的. 为此, ST-TransE^[110]进一步提出一种特定的时间嵌入来约束实体和关系的表示学习. T-TransE 和 S-TTransE 都致力于有效地处理时间演变的事实. 受 TransH 的启发, HyTE^[111]将时间戳与对应超平面关联, 显示地将时间嵌入实体关系空间中, 充分利用时间引导知识推理和预测时间敏感事实关系的有效时间范围. TDG2E^[112]提出一种动态感知时间间隔变化的方法, 既可以保留当前的子图状态, 又可以保留变化的模式. 表 13 总结了基于辅助信息的 MKGC 模型.

表 13 基于辅助信息的 MKGC 模型

模型名称	优点	不足
NMM ^[87]	结合邻居信息, 简单高效, 提高补全性能	仅学习邻居上的固定混合, 不能全面获取邻居信息
LENA ^[88]	注意力机制捕获有效邻居, 减少邻居噪音影响	模型结构比较复杂, 训练代价较高
G2SKGEatt ^[89]	融合注意力机制有效融合邻居信息, 考虑不同邻居信息的重要性不同	模型相对比较复杂, 训练参数规模比较大, 计算开销较大
CACL ^[91]	上下文邻居获取丰富的特征语义, 改善性能	模型相对比较复杂, 训练代价比较大
CNNIM ^[92]	推理能力较强; 可解释性较好	链接预测任务性能一般; 模型泛化能力较差
CAFE ^[93]	邻域感知模块捕获邻域信息, 无需预处理, 相对来说时间开销小	不适用稀疏知识图谱, 对图谱连通性要求高

表 13 基于辅助信息的 MKGC 模型 (续)

模型名称	优点	不足
PRA ^[95]	推理能力较强; 考虑路径丰富语义; 表示能力强	枚举所有路径时间复杂度较高; 特征爆炸问题; 计算开销大
PRA+ ^[96]	效率更高、表现力更强, 缓解特征爆炸问题	对训练样本要求高, 不适用于零样本、少样本情形
PATH-RNN ^[97]	任意长度联合推理; 适合无路径条件查询推理, 也可推理不存在的关系	模型相对比较复杂, 开销较大, 路径越长, 关系指数增长
PTransE ^[98]	多条路径表示, 语义更丰富, 推理能力强	路径表示学习简单的数值运算, 可解释性差, 准确性也差
RTransE ^[99]	路径推理能力强; 语义融合扩充训练集, 效率和性能权衡	难以处理复杂关系模式; 复杂路径计算开销大
PTransD ^[100]	路径推理性能较好; 获取不同环境语义特征	链接预测任务性能较差; 计算开销大; 特征爆炸问题
NeuralLP ^[101]	能够学习可变规则; 逻辑语义丰富; 效果较好	模型相对复杂; 参数规模较大
AnyBURL ^[106]	规则学习能力强; 适应大型KG; 可解释性强; 资源利用率较低	训练代价较大, 参数较多
ELPKG ^[107]	软逻辑推理强; 解决了知识不一致和冲突问题; LP 预测精度高	计算开销较大; 训练代价较大
RPJE ^[108]	路径推理能力较强; 语义特征丰富; 可解释性较好	规则学习增加了额外开销
T-TransE ^[109]	引入时间特征维度编码, 进行约束	不是时间感知的模型; 动态知识图时间戳分布不平衡
ST-TransE ^[110]	特定的时间嵌入约束实体和关系学习; 捕获时序变化	不是时间感知的; 动态知识图时间戳分布不平衡
HyTE ^[111]	显式地学习时间的嵌入表示	无法感知时间变化; 时间戳分布不平衡; 不能显示建模动态KG演化过程
TDG2E ^[112]	保留当前子图结构和知识图动态演化过程; 解决动态知识图时间戳分布不平衡	模型相对比较复杂; 计算开销较大

5.5 大模型的 MKGC 模型

大模型在自然语言处理任务中表现优越, 如 KG-BERT^[36]首次将大模型用于 KGC 任务, 但排序性能不佳. MTL-KGC^[37]提出多任务学习框架对 KG-BERT 进行改善. 扩展语言模型的规模对下游任务有显著效果. 因此, ChatGPT 等大语言模型引起了普遍关注. KG-LLM^[39]将大模型运用于知识图谱补全, 实现了较好的性能. 然而, 已有的方法只使用了大模型丰富的语义信息, 忽视了关键的结构语义信息, 严重限制了其推理性能. KEPLER^[113]将 LLM 和传统嵌入 KGC 技术相结合, 充分使用知识图元组结构的语义信息和文本语义信息, 克服单一模型和传统的基于嵌入 KGC 技术的不足. 该模型使用语言模型作为编码器对文本实体描述进行编码, 然后共同优化知识嵌入目标和语言建模 MLM 目标. TSTR^[114]通过传统嵌入 KGC 技术进行二次评分引入结构语义信息, 使用 BERT 对实体名称和描述进行编码, 实现 LLM 和传统 KGC 结合. KoPA^[40]提出通过结构预训练理解 KG 内部复杂的实体和关系, 将其表示为结构嵌入三元组结构信息融入到 LLM 中, 以促进模型的结构感知推理能力. K-BERT^[115]把固定实体嵌入直接集成到大语言模型中, 以提供外部知识. 然而, 实体嵌入来自单独的嵌入模型, 很难与语言表示空间对齐; 实体链接将文本链接到相应实体易受到错误传播的困扰. 同时, 复杂的机制增加额外的推理开销. 另外, 大模型无法回忆事实, 经常生成事实幻觉. 同时, 大模型工作类似于黑匣子, 通过隐含参数表示事实及推理缺乏一定的可解释性, 以及高昂的计算开销一定程度上限制了其泛化能力. 后文表 14 总结了基于大模型的 MKGC 模型.

5.6 基于多模态 MKGC 模型

随着多媒体数据的爆炸式增长, 多模态知识图谱 (multi-modal knowledge graph, MMKG) 日益受到关注, 它们融合了文本、图像、视频等多种模态的信息, 能够更全面地描述现实世界中的实体和关系. 然而, MMKG 同样面临数据不完整的问题. 多模态知识图谱补全 (MMKGC) 主要对不完整 MKG 缺失的信息进行预测进而提高其质量. 一般扩展传统结构单一模态的知识图表示技术以融合多模态信息. RSME^[116]首次尝试视觉模态信息对传统单一结构模态 KG 表示性能的探索. MULTIFORM^[117]把图像、文本等模态连接起来增强训练样本不足的 KGC 任务, 而 MMSN^[118]进一步使用暹罗注意力网络和门控机制对邻居的多模态特征进行融合. HRGAT^[119]使用低阶多模态融合对模态内和模态间的动态特性进行建模, 并采用特定关系注意力网络对多模态信息进行选择性融合. 然而,

MMKGC 可能存在实体模态特征缺失或者模态信息不平衡导致模态间交互能力及融合效果减弱. MACO^[120]采用模态对抗训练生成器和判别器生成缺失的模态特征. AdaMF-MAT^[121]通过自适应模态权重实现多模态信息融合和模态对抗训练产生对抗样本以增强不平衡的模态信息, 而 NativE^[122]使用关系引导的双自适应融合模块实现任意模态的自适应融合, 并借助协作模态对抗训练来改善模态信息间的不平衡. MoSE^[123]模态分割关系表示学习, 采用集成推理框架结合不同权重的预测以动态调整模态重要性, 减少传统 MNFormer^[124]共享关系表示引起训练过程模态相互干扰. 然而, 上述方法忽略了模态间特征细粒度的语义差别及其交互. MyGO^[125]从细粒度模态信息对模态信息进行融合. MOMOK^[126]使用关系引导的混合模态知识专家学习自适应多模态实体表示, 并整合来自多模态的预测, 以实现联合决策. Chen 等人^[127]只融合特定任务相关的多模态特征, 使用当前任务微调过的编码器获取不同模态的特征表示, 过滤无关模态的信息, 以提高模态融合的性能. 然而, 现实多模态知识图更加复杂, 各模态之间的信息如何有效协同才能达到更好的效果仍是一大挑战. 表 15 总结了基于多模态的 MKGC 模型.

表 14 基于大模型的 MKGC 模型

模型名称	优点	不足
KG-BERT ^[36]	大模型提供丰富语义; 丰富实体关系描述; 提高表示学习性能	参数规模大, 计算开销大; 性能稳定性相对较差; 可解释性较低
MTL-KGC ^[37]	多任务框架, 学习语义更丰富; 相似性词汇区分性强	参数规模大, 计算开销较大; 可解释性较弱
KG-LLM ^[39]	补全性能得到显著提高; 零样本和少样本中都表现良好	参数规模很大, 计算开销较大; 性能可解释性较差; 效果不稳定, 易出现幻觉问题
KoPA ^[40]	结构和文本语义相结合, 表示能力和推理能力较好	参数规模较大; 可解释性较弱
KEPLER ^[113]	结构和文本语义相结合, 表示能力和推理能力较好	计算开销较大; 可解释性较弱; 避免硬引入结构嵌入的不灵活性
TSTR ^[114]	二次评分引入结构语义; 整体性能提升; 时间开销相对减少; 适用稀疏数据	性能取决于数据集; 可解释性较弱
K-BERT ^[115]	引入固定实体嵌入, 提供结构语义信息, 语义更丰富	空间异构难以对齐; 错误信息传播; 复杂机制带来额外开销

表 15 基于多模态的 MKGC 模型

模型名称	优点	不足
RSME ^[116]	引入视觉模态, 获取更多特征语义; 可过滤模态中不相关信息影响	单一视觉模态传达的信息有限; 图片模态信息部总是有用
MULTIFORM ^[117]	适合少样本学习场景; 长尾实体表示学习	忽略了外部文本信息对于多模态少样本学习的积极作用
MMSN ^[118]	考虑少样本场景下关系补全; 充分挖掘邻居模态信息; 促进模态间的交互	难以处理少样本场景下 1-N, N-1 以及 N-N 复杂关系的建模
MNFormer ^[124]	缓解模态信息缺失; 促进模态交互; 对抗训练; 过滤模态噪音	模态补全性能不能代替图谱补全性能; 对抗训练模型复杂性提高
HRGAT ^[119]	特定关系注意力机制过滤不相关模态信息的干扰; 快速的收敛速度	忽视模态信息间的不平衡、模态信息缺失; 对图像交互特征获取不足
MACO ^[120]	缓解模态信息缺失; 促进模态交互; 对抗训练; 过滤模态噪音	模态补全和知识图谱补全协调较差
AdaMF-MAT ^[121]	缓解模态信息不平衡、模态融合不充分以及原始模态使用不高效	模态确实场景设置偏离现实; 模态信息使用不充分
NativE ^[122]	模态种类繁多, 缓解模态间分布不平衡	对复杂的多模态场景效果不好
MoSE ^[123]	多种模态获取更多特征语义; 缓解模态信息冲突; 过滤不相关模态信息; 动态加权不同模态信息	对视觉模态信息利用不足; 在多重图像场景下, 模态关系矛盾问题依然存在
MyGO ^[125]	能够捕获多模态细微的、细粒度的语义细节及其交互	不适用更加复杂的多模态场景
MOMOK ^[126]	捕获不同关系环境下隐藏在模态中的多视角特征; 过滤关系无关的模态信息	任务场景比较局限; 缺乏对大模型的探索

多样本 KGC 方法包括基于张量分解、Trans 距离、神经网络、大模型、多模态以及辅助信息的方法. 张量分解是矩阵分解在高阶上的泛化, 擅长高维和复杂关系的 KG. 神经网络能获取深度交互特征, 适用于高维复杂的图数据, 具有很好的表现力. Trans 距离方法简单高效, 适用于大规模 KG. 辅助信息的模型适用于训练样本不足以及稀疏的 KG, 同时适用于 ZKGC 以及 FKGC 情形. 大模型 KGC 模型能够为 ZKGC 和 FKGC 提供丰富的语义信息提高表示学习的性能, 也能在 MKGC 情形和多模态 KGC 中表现出优势. 但是, 大模型的幻觉问题和对捕获的事实缺乏一定的可解释性限制其泛化能力. 多模态 KGC 模型能为张量分解、Trans 距离和神经网络提供丰富的模态特征以促进 KGC 的性能. 同时, 也适用于 ZKGC 和 FKGC 场景.

从数据规模来说, ZKGC 模型对训练数据规模要求不苛刻, 其中基于描述信息的方法要求高质量的实体描述才能实现较好的性能. 但现实中高质量的实体描述难以获取, 而大模型的方法对训练样本没有要求且可以提供丰富的语义信息. FKGC 模型如元学习、度量学习、优化学习这 3 种方法对训练数据的规模有一定的要求, 需要小规模的标记数据进行初步学习, 而大模型的方法与 ZKGC 模型差不多, 对数据规模没要求. MKGC 模型如 Trans 距离、张量分解、神经网络等需要大量的训练样本, 现实中完全标记的数据难以获取. 因此, 受到一定限制. 而大模型的方法对训练数据规模没有要求, 因此同时适用 ZKGC、FKGC 和 MKGC 场景.

6 已有知识图谱补全模型比较

本节主要通过实验对已有的 KGC 模型进行比较, 包括常用评估指标、公开实验数据集、实验设计以及结果分析. 为确保实验公平, 本节涉及所有实验均在服务器上完成, 服务器参数为: NVIDIA RTX 2080S GPU、Intel Xeon E5-2687W v2 3.40 GHz CPU 和 64 GB RAM, 且实验参数设置与原始文献保持一致.

6.1 知识图谱补全模型常用评估指标

知识图谱补全本质上是给定查询条件下的排序问题, 一般包括: 已知实体预测对应的关系和已知关系预测对应的缺失的实体, 即 $(h, ?, t)$ 和 $(?, r, t)$ 或 $(h, r, ?)$, 其中 $(h, ?, t)$ 、 $(?, r, t)$ 、 $(h, r, ?)$ 为查询 Q . 常用评价指标包括 MR (mean rank) 表示一系列查询 Q 返回排序的平均值; Hits@ k 表示排名在前 k 名中所占的比例取值在 $[0, 1]$ 之间, 取值越高模型效果越好; MRR (mean reciprocal rank) 表示一系列查询 Q 返回排序取倒数之后的平均值, 取值越大, 模型预测性能越好.

6.2 知识图谱补全常用公开数据集

- WordNet: 是一种基于认知语言学的大型 KG 数据集, 它通过各种英文单词作为实体, 单词之间不同的语义关系作为实体间关系构建的知识图谱.
- Freebase: 是一个超大规模的百科类型的知识图谱数据集, 里面涉及了多种学科知识, 可以看成是一个由主题扩展的多个域组成的数据库, 每个主题的图结构都由其类型和类型属性控制.
- NELL: 是一个阅读网络搜集结构化的知识数据集. NELL-One 去除了 NELL 的反向关系.
- Wikidata: 是维基百科数据, 基于此构建 FKGC 数据集 Wiki-One. 表 16 例举了不同补全任务下常用的公开数据集.

表 16 KGC 常用公共数据集汇总

适用任务	数据集名称	关系数	实体数	训练集元组数	验证集元组数	测试集元组数
多样本KGC	WN18	18	40943	141 442	5 000	5 000
	FB5K	1 345	14 951	483 142	50 000	59 071
	WN11	11	38 696	112 581	2 609	10 544
	FB13	13	75 043	316 232	5 908	23 733
	FB5M	1 192	5 385 322	19 193 556	50 000	59 071
	FB40K	1 336	39 528	370 640	67 946	96 678
	FB15K-237	237	14 541	272 115	17 535	20 466
	WN18RR	11	40 943	86 835	3 034	3 134

表 16 KGC 常用公共数据集汇总 (续)

适用任务	数据集名称	关系数	实体数	训练集元组数	验证集元组数	测试集元组数
多样本KGC	YAGO3-10	37	123 182	1 079 040	5 000	5 000
	DB15K	279	12 842	79 222	9 902	904
	KVC16K	4	16 015	180 190	22 523	22 525
	NELL-One	358	68 545	51	5	11
少样本KGC	Wiki-One	822	4 838 244	133	16	34
	NELL-995	37	3 078	—	—	—
	Umls	46	135	329	652	661
	DBPedia50k	24 624	351	32 388	123	2 095
零样本KGC	FB5K-237-OWE	12 324	235	242 489	12 806	—
	DBPedia500k	517 475	654	3 102 677	10 000	1 155 937

6.3 不同类型的 KGC 模型实验分析

本节通过复现相关实验对各类模型进行了比较, 并对结果进行了分析和讨论.

6.3.1 零样本的 KGC (ZKGC) 模型比较

在数据集 DBPedia50k 和 FB5K-237-OWE 上进行对比实验, 结果如表 17 所示.

表 17 ZKGC 模型的实验结果 (%)

模型名称	DBPedia50k				FB5K-237-OWE			
	Hits@1	Hits@3	Hits@10	MRR	Hits@1	Hits@3	Hits@10	MRR
OWE	51.9	65.2	76.0	60.3	31.6	43.9	56.0	40.1
DKRL	—	—	40.0	23.0	—	—	—	—
ConMask	47.1	64.5	81.0	58.4	21.5	39.9	45.8	29.9
WOWE	52.7	66.5	76.9	61.2	31.9	44.1	56.4	40.4
OWE-RCT	54.2	68.6	79.1	63.1	33.0	45.7	58.2	41.7
OWE-RST	55.7	69.1	80.1	64.3	33.2	46.0	58.8	42.0
OWE-MRC	37.8	45.5	58.8	44.2	37.7	52.2	61.4	41.5
EmReCo	60.2	73.8	83.2	68.5	33.8	47.2	60.2	42.9
MIA	64.0	83.0	93.0	75.0	35.1	47.3	58.7	41.4

从表 17 可知: 1) 与其他 ZKGC 模型相比, MIA 在 DBPedia50k 数据集上表现最佳, 而在数据集 FB5K-237-OWE 上, 效果略差; OWE-MRC 在数据集 FB5K-237-OWE 上效果比其他模型基本上都要好, 原因可能是 FB5K-237-OWE 数据集有较多的长文本描述, 而 MIA 对长文本处理不具优势, 而 OWE-MRC 使用 MRC 处理长文本, 提高了模型处理长文本的能力, 进而获得更加精准的实体表示; 2) 对比 OWE、WOWE、OWE-MRC、OWE-RST 以及 EmReCo 等 ZKGC 模型, 效果依次递增, 原因可能是 WOWE 改变了 OWE 平均聚合文本嵌入方式, 采用注意力机制对不同文本描述词赋予不同的权重, 减少了不相关信息的影响, 提高了表示学习的准确性.

OWE-MRC 在 OWE 基础上, 增加了 MRC 模块, 对实体描述长文本进行提炼, 得到短文本, 进而提高模型处理文本的能力; OWE-RST/RCT 在 OWE 基础上, 采用特定关系的映射函数对齐文本嵌入到图嵌入空间, 缩小了待预测目标实体的类型范围, 提高了准确度; EmReCo 使用基于注意力机制的聚合方式、特定关系的对齐函数, 提高了实体表示的准确性.

6.3.2 少样本的 KGC (FKGC) 模型比较

在 NELL-One 和 Wiki-One 上进行对比实验, 结果如表 18 和表 19 所示.

从表 18 和表 19 可知: 1) 在 NELL-One 数据集上, FKGC 在多数指标上都比传统的 KGC 模型效果好, 这表明 FKGC 模型在少样本条件下处理 KGC 任务的优越性. 2) 基于度量学习的 FKGC 模型中, 在 1-shot 条件下, TransAM 在 MRR 指标比其他方法好, 原因可能是利用注意力机制捕捉三元组内和三元组间实体的交互信息进而获得更完美的实体表示. 3) 在 Wiki-One 数据上, FKGC 性能并不都比传统 KGC 模型效果好, 原因可能是 Wiki-One 数据集

比 NELL-One 数据集大一个数量级,使得传统的 KGC 能够学到更多的信息. 4) 在基于其他的 FKGC 模型, CogKR 模型在 1-shot 条件下表现最佳; 而基于度量的模型, TransAM 模型效果最好. 5) 总的来说, 无论在 NELL-One 还是 Wiki-One 上, GANA 模型效果最好, 原因可能是门控网络和图注意力机制过滤邻域中的噪音信息, 使得表示更加精准.

表 18 FKGC 模型的实验结果 (MRR、Hits@5)

模型名称	NELL-One						Wiki-One					
	MRR			Hits@5			MRR			Hits@5		
	1-shot	3-shot	5-shot	1-shot	3-shot	5-shot	1-shot	3-shot	5-shot	1-shot	3-shot	5-shot
GMatching	0.200	0.171	—	0.272	0.235	—	0.185	0.279	—	0.260	0.370	—
MetaR	0.314	—	0.323	0.375	—	0.385	0.164	—	0.209	0.238	—	0.280
FSRL	0.149	0.241	0.158	—	0.327	0.206	0.170	0.318	0.153	—	0.433	0.212
FAAN	0.215	—	0.341	—	—	0.395	0.187	—	0.279	—	—	0.364
CogKR	0.288	—	—	0.334	—	—	0.256	—	—	0.314	—	—
AMmodel	0.218	—	0.248	0.243	—	0.283	0.171	—	0.201	0.234	—	0.264
GANA	0.301	0.331	0.351	0.350	0.389	0.407	0.307	0.322	0.344	0.409	0.432	0.437
TransAM	0.242	—	—	—	—	—	0.225	—	—	—	—	—
TransE	0.105	0.162	0.168	0.111	0.180	0.186	0.036	0.040	0.052	0.024	0.027	0.057
DisMult	0.165	0.201	0.214	0.174	0.223	0.246	0.046	0.052	0.077	0.034	0.041	0.078
ComplEx	0.179	0.228	0.239	0.212	0.252	0.253	0.055	0.064	0.070	0.044	0.053	0.063

表 19 FKGC 模型的实验结果 (Hits@1、Hits@10)

模型名称	NELL-One						Wiki-One					
	Hits@1			Hits@10			Hits@1			Hits@10		
	1-shot	3-shot	5-shot	1-shot	3-shot	5-shot	1-shot	3-shot	5-shot	1-shot	3-shot	5-shot
GMatching	0.120	0.095	—	0.336	0.324	—	0.119	0.198	—	0.313	0.464	—
MetaR	0.266	—	0.270	0.404	—	0.418	0.093	—	0.141	0.331	—	0.355
FSRL	0.091	0.155	0.097	0.267	0.406	0.287	0.114	0.211	0.073	0.294	0.507	0.319
FAAN	0.146	—	0.281	0.362	—	0.463	0.116	—	0.200	0.316	—	0.428
CogKR	0.249	—	—	0.366	—	—	0.205	—	—	0.353	—	—
AMmodel	0.142	—	0.182	0.327	—	0.357	0.113	—	0.143	0.281	—	0.311
GANA	0.231	0.283	0.299	0.416	0.425	0.446	0.211	0.225	0.246	0.483	0.510	0.517
TransAM	0.184	—	—	0.358	—	—	0.152	—	—	0.360	—	—
TransE	0.041	0.085	0.082	0.226	0.317	0.345	0.011	0.013	0.042	0.059	0.072	0.090
DisMult	0.106	0.146	0.140	0.285	0.295	0.319	0.014	0.020	0.035	0.087	0.091	0.134
ComplEx	0.112	0.165	0.176	0.299	0.345	0.364	0.021	0.029	0.030	0.100	0.113	0.124

6.3.3 多样本 KGC (MKGC) 模型比较

文中多样本 KGC (MKGC) 模型介绍的比较多, 本节对 MKGC 模型的实验将按照不同的分类分别进行介绍.

● 张量分解的 MKGC 模型实验分析

在 WN18 和 FB15K 数据集上对张量分解 (TF) 的 MKGC 模型进行了实验, 结果如表 20 所示.

从表 20 中可知: 1) TuckER 不仅优于其他线性模型, 还优于其他类别的多数复杂模型的结果, 如 ConvE 和 MINERVA. TuckER 和 ComplEx 取得了较好的效果, 可推断尽管它们在具体的方法细节上有所不同, 但它们都从多任务学习中获得了很大收益. 2) 从 TuckER 模型还可以得知, 简单的线性模型具有很强的表现能力, 在转向更精细的模型之前, 仍值得作为基本模型. 总体而言, 在探索新的改进时, 也应注意潜在的挑战. 例如, TuckER 参数的规模将随着实体或关系的数量线性增加, 因此应该考虑算法的可扩展性和经济性问题. 3) 使用旋转或其他操作对具有更高自由度的高维空间 (如 QuatE 和 TuckER) 中的实体和关系进行建模, 有助于提高 KGC 的性能.

● 神经网络的 MKGC 模型实验分析

在数据集 WN18RR 和 FB15K-237 上进行了实验, 结果如表 21 所示.

表 20 张量分解的 MKGC 模型实验比较

模型名称	WN18					FB15K				
	MRR	Hits@1	Hits@3	Hits@10	MR	MRR	Hits@1	Hits@3	Hits@10	MR
RESCAL	0.892	0.843	0.904	0.928	—	0.354	0.235	0.409	0.587	—
DistMult	0.831	0.733	0.804	0.943	655	0.351	—	—	0.577	—
ANALOGY	0.943	0.939	0.944	0.947	—	0.725	0.646	0.785	0.854	—
ComplEx	0.942	0.936	0.945	0.947	—	0.692	0.599	0.759	0.840	—
SimplE	0.943	0.939	0.944	0.947	—	0.727	0.662	0.774	0.838	—
TuckER	0.954	0.949	0.955	0.958	—	0.795	0.741	0.833	0.892	—
QuatE	0.949	0.941	0.954	0.960	388	0.770	0.700	0.821	0.878	41

表 21 神经网络的 MKGC 模型实验比较

模型名称	NELL-One						Wiki-One					
	MRR			Hits@5			MRR			Hits@5		
	1-shot	3-shot	5-shot	1-shot	3-shot	5-shot	1-shot	3-shot	5-shot	1-shot	3-shot	5-shot
GMatching	0.200	0.171	—	0.272	0.235	—	0.185	0.279	—	0.260	0.370	—
MetaR	0.314	—	0.323	0.375	—	0.385	0.164	—	0.209	0.238	—	0.280
FSRL	0.149	0.241	0.158	—	0.327	0.206	0.170	0.318	0.153	—	0.433	0.212
FAAN	0.215	—	0.341	—	—	0.395	0.187	—	0.279	—	—	0.364
CogKR	0.288	—	—	0.334	—	—	0.256	—	—	0.314	—	—
AMmodel	0.218	—	0.248	0.243	—	0.283	0.171	—	0.201	0.234	—	0.264
GANa	0.301	0.331	0.351	0.350	0.389	0.407	0.307	0.322	0.344	0.409	0.432	0.437
TransAM	0.242	—	—	—	—	—	0.225	—	—	—	—	—
TransE	0.105	0.162	0.168	0.111	0.180	0.186	0.036	0.040	0.052	0.024	0.027	0.057
DisMult	0.165	0.201	0.214	0.174	0.223	0.246	0.046	0.052	0.077	0.034	0.041	0.078
ComplEx	0.179	0.228	0.239	0.212	0.252	0.253	0.055	0.064	0.070	0.044	0.053	0.063

从表 21 中可知: 1) 在前 4 个基于 CNN 的 KGC 模型中, CapsE 在 WN18RR 上表现良好, 可能是在 CapsE 中, 第 1 层中向量长度和方向有助于对相应维度中的重要特征进行建模, 因此 CapsE 擅长处理更稀疏的数据集, 如 WN18RR. 另外, CapsE 模型使用预先训练的词嵌入进行初始化, 并使用辅助信息. 2) R-GCN、SACN 以及 COMPGCN 都是 GCN 的扩展, SACN 和 COMPGCN 利用加权的 GCN 通过可学习的权重来聚合邻居信息. 因此, 它们在所有数据集上都表现出较好的结果. 3) ParamE-Gate 基本上优于所有其他神经网络模型, 这明显反映在 MRR, Hits@1 和 Hits@3 在两个数据集上的表现. 需要注意的是 ConvE 和 ParamE-CNN 具有相似的网络架构, 但 ParamE-CNN 比 ConvE 有实质性的改进. ParamE-CNN 将参数本身作为关系嵌入, 可以捕捉内在属性. ParamE-MLP、ParamE-CNN 和 ParamE-Gate 的性能比较结果表明, MLP 的建模能力弱于卷积层和门结构. 此外, 尽管卷积层擅长提取特征, 但 ParamE-CNN 的性能比 ParamE-Gate 差, 因为门结构可以选择性地过滤无关信息.

• Trans 距离的 MKGC 模型实验分析

在数据集 WN18、FB15K、WN18RR 和 FB15K-237 上进行了实验, 结果如表 22 所示.

从表 22 中可知: 1) 基于 TransE 模型有必要进一步考虑实体和关系之间的语义差异. 与其他模型相比, TransF 实现了明显和实质性的改进. 可能是 TransF 将关系空间分解为多个子空间的组合表示 KG 中不同类型的关系. 此外, TransF 通过对特定关系投影矩阵子空间建模来显式学习各种关系比同类方法更高效. 2) 借助注意力机制的模型 TransM、ITransF 和 TransAt 几乎都比 TransE 效果好. 具体而言, ITransF 在 WN18 和 FB5K 的多个评估指标上表现更好, 而 TransM 在稀疏的数据集 WN18 的结果较差. 可能因为 ITransF 采用了稀疏注意力机制促进不同关系之间的关系共享. TransAt 考虑实体中属性之间的层次结构, 使用两阶段判别方法来实现注意力机制. 这表明, 适当的注意机制有助于有效地适应人类对分层的认知. 3) TorusE 和 RotatE 在 WN18 和 FB5K 上都有很好的表现. RotatE 擅长建模, 通过将每个关系定义为复杂向量空间中的旋转. 相比之下, TorusE 专注于 TransE 中的正则化问题. 尽

管 TorusE 可以被视为 RotatE 的一个特例, 它将知识图谱嵌入定义为紧致的平移, 但 TorusE 中嵌入的模是固定的, 而 RotatE 中嵌入的模是在整个复空间上定义的, 这对于建模和推断合成模式非常关键. 因此, RotatE 比 TorusE 具有更好的表现能力, 这可能有助于解释为什么 RotatE 在 WN18 和 FB5K 上比 TorusE 性能更好. 4) TransGate 在 4 个数据集上都获得了好的结果, 尤其是在 FB5K 和 FB5K-237 上. 结果表明共享判别参数的适当性和门结构的强大能力. TransGates 遵循参数共享策略, 在复杂性和表现力之间取得了更好的权衡. 借助门结构的共享判别机制, TransGate 可以同时优化嵌入和减少参数. 然而, TransGate 在 WN18RR 上的性能较差, 因为 WN18RR 去除了反向关系并破坏了 WordNet 的固有结构, 这导致关系之间的相关性较低, 并进一步降低了参数共享的影响.

表 22 Trans 距离的 MKGC 模型实验比较

模型名称	WN18			FB15K			WN18RR			FB15K-237		
	MR	MRR	Hits@10	MR	MRR	Hits@10	MR	MRR	Hits@10	MR	MRR	Hits@10
TransE	251	—	0.892	125	—	0.471	2300	0.243	0.53	323	0.279	0.441
TransH	303	—	0.867	87	—	0.644	—	—	—	—	—	—
TransR	225	—	0.920	77	—	0.687	—	—	—	—	—	—
TransD	212	—	0.922	91	—	0.773	—	—	—	—	—	—
lppTransD	270	—	0.943	78	—	0.787	—	—	—	—	—	—
TransF	198	0.856	0.953	62	0.564	0.823	3246	0.505	0.49	210	0.286	0.472
STransE	206	0.657	0.934	69	0.543	0.797	—	—	—	—	—	—
Trans-FT	342	—	0.953	49	—	0.735	—	—	—	—	—	—
TransM	281	—	0.854	94	—	0.551	—	—	—	—	—	—
lTransF	223	—	0.952	77	—	0.814	—	—	—	—	—	—
TransAt	157	—	0.950	82	—	0.782	—	—	—	—	—	—
TransRS	357	—	0.945	77	—	0.750	—	—	—	—	—	—
TransA	392	—	0.943	74	—	0.804	—	—	—	—	—	—
TorusE	—	0.947	0.954	—	0.733	0.832	—	—	—	—	—	—
RotatE	309	0.949	0.959	40	0.797	0.884	3340	0.476	0.57	177	0.388	0.533
TransGate	—	—	—	33	0.832	0.914	3420	0.409	0.51	177	0.404	0.581

● 辅助信息的 MKGC 模型实验分析

在数据集 NELL995、FB5K-237、Kinship 和 Countries 进行了实验, 结果如表 23 所示.

从表 23 可知, 与其他方法相比, PRANN 可以更准确地预测大型数据集上的缺失链接. 当与非路径模型进行比较时, PRNN 在所有评估指标上, 特别是 MRR 和 Hits@k, 具有明显的优势. 在具有大量关系的知识图上, 如 FB15K-237, 与其他模型相比, PRNN 表现更好. 相反, MINERVA 在关系数较少的知识图 (如 Countries) 上表现略好. 另外, 在小型数据集, 如 Kinship 和 Countries 上, PRNN 在 Kinship 上取得了较好的结果, 与其他数据集相比, 该数据集是为了评估具有更可预测路径的逻辑规则学习系统的推理能力. 然而, 在 Countries 上, 与 MINERVA 相比, PRNN 表现略差, 可能是因为 Countries 数据集中的训练三元组数量太少, 无法有效训练模型.

表 23 基于辅助信息的 MKGC 模型结果对比

模型名称	NELL995			FB15K-237			Kinship			Countries		
	MRR	Hits@1	Hits@3	MRR	Hits@1	Hits@3	MRR	Hits@1	Hits@3	MRR	Hits@1	Hits@3
PRA	0.696	0.637	0.747	0.412	0.323	0.33	0.799	0.699	0.90	0.739	0.577	0.901
MINERVA	0.879	0.814	0.932	0.615	0.491	0.66	0.824	0.711	0.94	0.960	0.925	0.996
PRANN	0.898	0.838	0.952	0.660	0.545	0.71	0.953	0.918	0.98	0.947	0.916	0.986
Single-Model	0.859	0.788	0.914	0.575	0.513	0.57	0.804	0.814	0.88	0.941	0.918	0.956

● 大模型的 MKGC 模型实验分析

在数据集 NAGO3-10、WN18RR 和 YAGO3-10-100 上进行了实体预测实验, 结果如表 24 所示.

Hits@1 得分为头尾实体预测的均分. 从表 24 可知, KG-BERT 是基本规模的语言模型, 而后面如 KG LLaMA 是规模大的语言模型, 大模型的性能得分明显高于基本规模的语言模型. 另外, 加入结构嵌入, 性能显著提高. 这表明, 扩大语言模型规模有助于补全性能的提高. 同时, 合理地引入结构嵌入可以大大提高模型的性能.

表 24 基于大模型的 MKGC 模型 Hits@1 结果对比

模型名称	NAGO3-10	WN18RR	YAGO3-10-100
KG-BERT	—	0.1102	—
StAR	—	0.2430	—
LLaMA-7B	0.0254	0.0849	0.03
LLaMA-13B	0.0276	0.0991	0.01
KG-LLaMA-7B	0.0782	0.2415	0.16
KG-LLaMA-13B	0.0872	0.2559	0.13
KG-LLaMA2-13B	0.0949	0.2682	0.16
KG-LLaMA2-13B+Struct	0.1330	0.3151	0.22

● 多模态的 MKGC 模型实验分析

在多模态数据集 DB15K (含图像 12818, 文本 9078) 和 KVC16K (含图像 14822, 文本 768) 的实验结果如表 25 所示.

表 25 基于多模态的 MMKGC 模型结果对比 (%)

模型名称	DB15K				KVC16K			
	MRR	Hits@1	Hits@3	Hits@10	MRR	Hits@1	Hits@3	Hits@10
TransAE	28.09	21.25	31.17	41.17	10.81	5.31	11.34	21.89
MMKRL	26.81	13.85	35.07	49.39	8.78	3.89	8.99	18.34
RSME	29.76	24.15	32.12	40.29	12.31	7.14	13.21	22.05
VBKGC	30.61	19.75	37.18	49.44	14.66	8.28	15.81	27.04
MOSE	28.38	21.56	30.91	41.76	8.81	4.75	9.46	16.40
IMF	32.25	24.20	36.00	48.19	12.01	7.42	12.82	21.01
QEB	28.18	14.82	36.67	51.55	12.06	5.57	13.03	25.01
VISTA	30.42	22.49	33.56	45.94	11.89	6.97	12.66	21.27
AdaMF	32.51	21.31	39.67	51.68	15.26	8.56	16.71	28.29
MOMOK	39.57	32.38	43.45	54.14	16.87	10.53	18.26	29.20

从表 25 可知, 实验模型中, MOMOK 结果最好, 原因可能是它充分利用了上下文的潜在优势, 而其他模型只是为不同模态分配不同权重, 忽视了关系上下文等复杂因素的影响. 另外, 在 2 个数据集的 Hits@1 指标上性能表现最明显, 表明与其他模型比较, MOMOK 模型将正确答案排在前面的方面更有效, 表明该模型对多模态信息和关系上下文对 MMKGC 模型的精细、准确推理能力发挥了重要作用.

6.4 已有 KGC 模型的不足

尽管这些年越来越多的研究在 KGC 任务上实现了很好的效果, 但是分析总结发现当前 KGC 模型仍存在以下问题和挑战.

● 复杂关系的处理

三元组的关系越复杂, 需要学习的样本就越多, 因此在少样本和零样本条件下模型处理复杂关系极具挑战. 探索模型在样本不足条件下的复杂关系表示是值得关注的课题.

● 模型关系复杂性高

KG 本质上是通过语义关系连接的数据, 其中的关系类型复杂多样, 依靠单一的模型处理复杂多样的关系, 很难面面俱到. 单一结构模型数据处理效率高, 但是不适应较复杂的关系模式. 因此, 如何改进现有的 KGC 模型, 使得能够学习更大规模更加复杂的关系模式, 是当下 KGC 领域需要研究的课题.

- 语义信息获取困难

知识图谱作为非欧数据结构,采用传统的欧氏几何处理方法会带来计算复杂,维度过高等问题.一些 KGC 模型对大型 KG 采用分割成子图处理,这种机械的分割方式人为地破坏了知识图不同三元组本身的相互关系,拟合知识图语义时容易产生偏差,导致本身语义信息获取困难.

- 通用性和可扩展性差

现实世界是不断变化的,因此 KG 应该迭代更新,即需要不断地将新知识添加到 KG 中,以扩展其结构,并正确地映射和描述现实世界.其中关键挑战之一是多源信息的融合,主要问题是如何正确地连接和融合不同语言的信息和已有 KG 的信息.多源信息融合的关键步骤是在补全过程中将信息转化为与 KG 现有结构化信息一致的形式,这增加了 KGC 任务的难度.

- 可解释性问题

新兴的大模型技术在 KGC 及相关任务表现较好,但是大模型工作类似于黑匣子,对捕获的事实知识缺乏一定的可解释性,难以用于精度较高的如医疗领域.

7 知识图谱补全技术的应用

KGC 技术在实践中具有广泛的运用,本节主要介绍一般应用和华谱系统中的具体实现.

7.1 知识图谱补全技术一般应用

- 知识图谱构建^[128]

KG 的构建通常包括自上而下或自下而上的方式.KG 的构建是一个动态的过程,需要不断地补充缺失的实体和关系,以改善 KG 的结构.借助 KGC 技术,可以对构建的 KG 进行迭代更新和扩展,以辅助 KG 的构建.

- 新知识发现

KGC 是对实体关系等信息的预测,如对多跳关系路径连接实体对间直接关系推理,是发现新知识的重要手段,KGC 技术已被广泛应用于基于 KG 的许多上游任务中,如辅助 QA 系统,实现信息的快速准确检索和获取.

- 股市趋势预测

KGC 技术在金融领域越来越显示出巨大的价值,例如预测金融市场状况^[129].由于金融市场具有较强的实时性,即在金融市场中,市场信息随时间动态变化,通过基于金融事件和因素的金融 KG 来实现对金融市场的动态预测.将长短期记忆神经网络等时间序列神经网络结构与注意力机制相融合,构建预测模型.该模型整合市场的整体宏观动态序列和每个子市场的动态序列,将发展预测应用于金融事件中,实现金融 KG 的动态补全.

- 辅助医疗诊断

KG 具有组织和挖掘信息的能力,在医学领域也展现出巨大的应用潜力.许多研究者致力于医学 KG 的研究.利用基于电子病历构建的医学 KG 来辅助疾病的智能诊断时,可以将患者的基本信息与现有的医学地图进行链接,然后应用 KGC 技术来挖掘与患者实体相关的疾病实体信息链接在一起,从而为患者的疾病诊断提供准确的辅助参考.

- 自动推荐系统

自动推荐问题在少样本链接预测中具有挑战性的现实任务.例如,用户评论已经成为像 Yelp 这样的 Web 服务的重要组成部分.收集用户评论等相关信息有助于形成基于位置的社交网络,这种系统面临的一个挑战是当新用户加入时,平台中几乎没有现有的知识.因此,少样本链接预测模型,如 SEATTLE^[130]通过 KGC 技术为更新信息的用户建模等方法来解决推荐问题.

7.2 知识图谱补全技术在华谱系统中应用

在大数据知识工程 BigKE 的技术框架下,吴信东团队推出了一套囊括所有华人姓氏的家谱系统,即华谱系统^[131-133],网址: <https://www.zhonghuapu.com/> (如图 2 所示).华谱系统通过对家谱数据进行碎片化知识融合,为用户提供了寻根问祖、家族姓氏分布、人物之间关联等信息.华谱系统中 KGC 技术的应用包括以下 3 个方面.




图 2 华谱系统首页展示

● 人物关联补全

华谱系统人物关联模块 (如图 3 所示), 用于寻找任意两人物之间的关系. 系统构建的 KG 有些人物之间缺少直接关系, 该模块通过 KGC 技术中的推理规则、Jena 推理等对人物关系补全. 如亲属关系中, 基于已有的关系三元组 (<吴根长, 儿子, 吴信东> 和 <吴信东, 儿子, 吴超>), 加入推理规则, Jena 推理机制推出 <吴根长, 孙子, 吴超>, 即吴根长和吴超之间的关系为祖孙关系. 而该关系三元组在原始知识图中并没有, 通过 KGC 技术中的规则推理机制, 沿着关系路径进行推理, 得到多跳路径连接的实体对间的直接关系.




图 3 华谱系统人物关联逻辑规则推理关系展示

有些人物之间基于已有的 KG 难以推测出其直接关系, 如: 吴信东和杨善林 (如图 4 所示), 人物关联模块通过爬取两个人物实体的简介信息, 提取相应实体描述三元组给大模型, 如讯飞星火大模型等, 预测吴信东和杨善林之间的关系为同事 (社会关系), 对现有 KG 进行补全.




图 4 华谱系统人物关联大模型预测关系展示

● 人物分布地址补全

华谱系统中特色模块下的家谱人物分布功能,旨在寻找任意家谱人物在地图板块的位置分布情况 (<https://www.zhonghuapu.com/index.php/datamgr/tozhuigensuyuan>),根据家谱名称、家谱 ID 以及祖先姓名搜索家谱信息,包括字辈、住址等. 有些人物的地址、来源不详. 该模块使用知识图谱中邻居节点信息之间语义相似性特征,对缺失的人物分布地址进行补全,如父亲地址和孩子地址或配偶地址具有一定的相似性,用父亲地址补全孩子地址或配偶地址,或者配偶地址补全丈夫/妻子地址、爷爷地址补全孙子/孙女地址. 同时,通过字辈信息溯源对应家谱,对个体人物和家谱之间建立联系,帮助个体人物认祖归宗.

● 超点融合^[134]补全

华谱系统中碎片化人物信息的来源不同,可能存在错误或信息不全. 超点模块使用 KGC 技术中的智能融合技术对稀疏碎片化的人物信息补全. 对人物属性向量化,通过向量间的相似度对不同来源的同名人物信息进行融合(如图 5 所示管理员权限进入华谱可查看融合效果),对缺失属性的人物进行补全,从而得到信息更加完备、内容更加精确的人物信息.



图 5 华谱系统超点碎片化信息融合展示

8 知识图谱补全技术未来可能的研究方向

- 复杂关系处理研究: 已有的模型对实体和关系的处理多数是单一的向量化, 仅依赖嵌入式向量的简单运算去表示实体对象之间各种语义关系, 虽然降低了模型训练的复杂度, 但复杂关系处理不够充分, 导致现有模型在复杂关系处理方面能力受限.
- 语义信息有效获取: 传统多数 KGC 模型是线性变换的, 表现力不强, 同时也难以保证有效获取不同元素之间的交互信息, 因此需要非线性的处理方式, 神经网络弥补了该缺憾. ConvE 使用传统的卷积模型, 仅对三元组向量化拼接成新的张量, 因而对 KG 的实体关系特征语义信息获取不够充分连贯, 进而影响表现力.
- 可扩展性通用性: 现实世界中数据是纷繁复杂的, KG 中各种问题挑战可能同时出现. 经典的 KGC 模型或多或少都存在着一一定的不足, 单一的模型只能在某个方面表现较强, 将多种单一的基模型通过一定的集成策略有效集成在一起, 形成功能强大的集成模型, 可以弥补单一模型的不足, 以提高 KGC 模型的可扩展性通用性.
- 可解释性问题: 大模型在零样本和少样本 KGC 中表现出较好的性能, 但大模型类似于黑匣子, 对捕获和获取事实知识缺乏一定的可解释性. 虽然用思维链来解释 LLM 的预测, 也时常存在幻觉问题.
- 大模型和传统 KGC 技术结合: LLM 因其涌现能力和泛化能力, 在自然语言处理和人工智能领域取得了很

大成功.但也因易产生幻觉和对捕获的事实知识缺乏可解释性而限制了其在医疗诊断等高风险场景中的应用.传统的 KGC 技术基于结构化知识表示和推理能够增强 LLM 获取知识的可解释性,但是对新事实表示缺乏丰富的语义,而 LLM 能够提供丰富的语义表示.因此,大语言模型时代, KGC 技术研究仍然具有重要意义.两者,相辅相成,相互增强是当下及未来值得研究的课题.

9 结 论

本文根据模型构建过程所需样本的数量对已有的 KGC 模型进行了分类,即零样本 KGC 模型、少样本 KGC 模型和多样本 KGC 模型,并对每类模型进行了全面的分析和讨论,指出了它们的优点和不足,并通过实验加以验证.同时例举 KGC 技术的一般应用和华谱系统中的具体实现.基于以上调研,本文总结了当下 KGC 模型的不足和展望了 KGC 未来可能的研究方向,以期对未来 KGC 研究提供一些基本的借鉴和参考.

References:

- [1] Steiner T, Verborgh R, Troncy R, Gabarró J, van de Walle R. Adding realtime coverage to the Google knowledge graph. In: Proc. of the 2012 Int'l Conf. on Posters & Demonstrations Track. Boston: CEUR-WS.org, 2012. 65–68.
- [2] Liu K, Zhao J, He SZ, Zhang YZ. Question answering over knowledge bases. IEEE Intelligent Systems, 2015, 30(5): 26–35. [doi: 10.1109/MIS.2015.70]
- [3] Guo QM, Wang X, Zhu ZF, Liu PY, Xu LC. A knowledge inference model for question answering on an incomplete knowledge graph. Applied Intelligence, 2023, 53(7): 7634–7646. [doi: 10.1007/s10489-022-03927-0]
- [4] Bi X, Nie HJ, Zhao XG, Yuan Y, Wang GR. Reinforcement learning inference techniques for knowledge graph constrained question answering. Ruan Jian Xue Bao/Journal of Software, 2023, 34(10): 4565–4583 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6889.htm> [doi: 10.13328/j.cnki.jos.006889]
- [5] Qiao SJ, Yang GP, Yu Y, Han N, Tan X, Qu LL, Ran LQ, Li H. QA-KGNet: Language model-driven knowledge graph question-answering model. Ruan Jian Xue Bao/Journal of Software, 2023, 34(10): 4584–4600 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6882.htm> [doi: 10.13328/j.cnki.jos.006882]
- [6] Jannach D, Manzoor A, Cai WL, Chen L. A survey on conversational recommender systems. ACM Computing Surveys (CSUR), 2022, 54(5): 105. [doi: 10.1145/3453154]
- [7] Wang HW, Zhao M, Xie X, Li WJ, Guo MY. Knowledge graph convolutional networks for recommender systems. In: Proc. of the 2019 World Wide Web Conf. San Francisco: ACM, 2019. 3307–3313. [doi: 10.1145/3308558.3313417]
- [8] Li LS, Dong JY, Qin XY. Dual-view graph neural network with gating mechanism for entity alignment. Applied Intelligence, 2023, 53(15): 18189–18204. [doi: 10.1007/s10489-022-04393-4]
- [9] Ji SX, Pan SR, Cambria E, Marttinen 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]
- [10] Zhang X, Zhang CX, Guo JT, Peng C, Niu ZD, Wu XD. Graph attention network with dynamic representation of relations for knowledge graph completion. Expert Systems with Applications, 2023, 219: 119616. [doi: 10.1016/j.eswa.2023.119616]
- [11] Li WD, Peng R, Li Z. Knowledge graph completion by jointly learning structural features and soft logical rules. IEEE Trans. on Knowledge and Data Engineering, 2023, 35(3): 2724–2735. [doi: 10.1109/TKDE.2021.3108224]
- [12] Zhang NY, Xie X, Chen X, Deng SM, Ye HB, Chen HJ. Knowledge collaborative fine-tuning for low-resource knowledge graph completion. Ruan Jian Xue Bao/Journal of Software, 2022, 33(10): 3531–3545 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6628.htm> [doi: 10.13328/j.cnki.jos.006628]
- [13] Wang Q, Wang B, Guo L. Knowledge base completion using embeddings and rules. In: Proc. of the 24th Int'l Conf. on Artificial Intelligence. Buenos Aires: AAAI Press, 2015. 1859–1865.
- [14] 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]
- [15] Rossi A, Barbosa D, Firmani D, Matinata A, Merialdo P. Knowledge graph embedding for link prediction: A comparative analysis. ACM Trans. on Knowledge Discovery from Data (TKDD), 2021, 15(2): 14. [doi: 10.1145/3424672]
- [16] Shen T, Zhang F, Cheng JW. A comprehensive overview of knowledge graph completion. Knowledge-based Systems, 2022, 255: 109597. [doi: 10.1016/j.knosys.2022.109597]

- [17] 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]
- [18] Wu GD, Liu HW, He ZW, Li JX, Wang XN. Review of knowledge graph completion technology. *Journal of Chinese Computer Systems*, 2023, 44(3): 471–482 (in Chinese with English abstract). [doi: 10.20009/j.cnki.21-1106/TP.2022-0423]
- [19] Wu TX, Qi GL, Li C, Wang M. A survey of techniques for constructing Chinese knowledge graphs and their applications. *Sustainability*, 2018, 10(9): 3245. [doi: 10.3390/su10093245]
- [20] Lin YK, Han X, Xie RB, Liu ZY, Sun MS. Knowledge representation learning: A quantitative review. arXiv:1812.10901, 2018.
- [21] Socher R, Chen DQ, Manning CD, Ng AY. Reasoning with neural tensor networks for knowledge base completion. In: *Proc. of the 27th Int'l Conf. on Neural Information Processing Systems*. Lake Tahoe: Curran Associates Inc., 2013. 926–934.
- [22] Gesese GA, Biswas R, Alam M, Sack H. A survey on knowledge graph embeddings with literals: Which model links better literal-ly? *Semantic Web*, 2021, 12(4): 617–647. [doi: 10.3233/SW-200404]
- [23] Chen Z, Wang YH, Zhao B, Cheng J, Zhao X, Duan ZT. Knowledge graph completion: A review. *IEEE Access*, 2020, 8: 192435–192456. [doi: 10.1109/ACCESS.2020.3030076]
- [24] Zamini M, Reza H, Rabiei M. A review of knowledge graph completion. *Information*, 2022, 13(8): 396. [doi: 10.3390/info13080396]
- [25] 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]
- [26] 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.
- [27] 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: IJCAI, 2023. 6545–6553.
- [28] Kejriwal M. Advanced topic: Knowledge graph completion. In: Kejriwal M, ed. *Domain-specific Knowledge Graph Construction*. Cham: Springer, 2019. 59–74. [doi: 10.1007/978-3-030-12375-8_4]
- [29] Cai HY, Zheng VW, Chang KCC. A comprehensive survey of graph embedding: Problems, techniques, and applications. *IEEE Trans. on Knowledge and Data Engineering*, 2018, 30(9): 1616–1637. [doi: 10.1109/TKDE.2018.2807452]
- [30] 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*, 2019. 3044–3051. [doi: 10.1609/aaai.v33i01.33013044]
- [31] 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]
- [32] Zhou YY, Shi S, Huang HY. Weighted aggregator for the open-world knowledge graph completion. In: *Proc. of the 6th Int'l Conf. of Pioneering Computer Scientists, Engineers and Educators on Data Science*. Taiyuan: Springer, 2020. 283–291. [doi: 10.1007/978-981-15-7981-3_19]
- [33] 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]
- [34] Shi BX, Weninger T. Open-world knowledge graph completion. In: *Proc. of the 32nd AAAI Conf. on Artificial Intelligence*. New Orleans: AAAI, 2018. 1957–1964. [doi: 10.1609/aaai.v32i1.11535]
- [35] 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]
- [36] Yao L, Mao CS, Luo Y. KG-BERT: BERT for knowledge graph completion. arXiv:1909.03193, 2019.
- [37] Kim B, Hong T, Ko Y, Seo J. Multi-task learning for knowledge graph completion with pre-trained language models. In: *Proc. of the 28th Int'l Conf. on Computational Linguistics*. Barcelona: Int'l Committee on Computational Linguistics, 2020. 1737–1743. [doi: 10.18653/v1/2020.coling-main.153]
- [38] Choi B, Jang D, Ko Y. MEM-KGC: Masked entity model for knowledge graph completion with pre-trained language model. *IEEE Access*, 2021, 9: 132025–132032. [doi: 10.1109/ACCESS.2021.3113329]
- [39] Yao L, Peng JZ, Mao CS, Luo Y. Exploring large language models for knowledge graph completion. arXiv:2308.13916, 2023.
- [40] Zhang YC, Chen Z, Guo LB, Xu YJ, Zhang W, Chen HJ. Making large language models perform better in knowledge graph completion. In: *Proc. of the 32nd ACM Int'l Conf. on Multimedia*. Melbourne: ACM, 2024. 233–242. [doi: 10.1145/3664647.3681327]
- [41] 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, ICCL, 2024. 11956–11968.
- [42] Shu D, Chen TL, Jin MY, Zhang C, Du MN, Zhang YF. Knowledge graph large language model (KG-LLM) for link prediction. In: Proc. of the 16th Asian Conf. on Machine Learning. Hanoi: ACML, 2024. 143–158.
- [43] 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: Association for Computational Linguistics, 2018. 1980–1990. [doi: [10.18653/v1/D18-1223](https://doi.org/10.18653/v1/D18-1223)]
- [44] 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)]
- [45] 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. Association for Computational Linguistics, 2020. 1681–1691. [doi: [10.18653/v1/2020.emnlp-main.131](https://doi.org/10.18653/v1/2020.emnlp-main.131)]
- [46] 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)]
- [47] Huisman M, van Rijn JN, Plaat A. A survey of deep meta-learning. Artificial Intelligence Review, 2021, 54(6): 4483–4541. [doi: [10.1007/s10462-021-10004-4](https://doi.org/10.1007/s10462-021-10004-4)]
- [48] Sun QR, Liu YY, Chua TS, Schiele B. Meta-transfer learning for few-shot learning. In: Proc. of the 2019 IEEE/CVF Conf. on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019. 403–412. [doi: [10.1109/CVPR.2019.00049](https://doi.org/10.1109/CVPR.2019.00049)]
- [49] 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. Hong Kong: Association for Computational Linguistics, 2019. 4216–4225. [doi: [10.18653/v1/D19-1431](https://doi.org/10.18653/v1/D19-1431)]
- [50] 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)]
- [51] 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.
- [52] 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)]
- [53] Lv X, Gu YX, Han X, Hou L, Li JZ, 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: Association for Computational Linguistics, 2019. 3374–3379. [doi: [10.18653/v1/D19-1334](https://doi.org/10.18653/v1/D19-1334)]
- [54] Zhang CX, Yu L, Saebi M, Jiang M, Chawla N. Few-shot multi-hop relation reasoning over knowledge bases. In: Proc. of the 2020 Association for Computational Linguistics: EMNLP 2020. Association for Computational Linguistics, 2020. 580–585. [doi: [10.18653/v1/2020.findings-emnlp.51](https://doi.org/10.18653/v1/2020.findings-emnlp.51)]
- [55] 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. Alexandria: Society for Industrial and Applied Mathematics, 2022. 666–674. [doi: [10.1137/1.9781611977172.75](https://doi.org/10.1137/1.9781611977172.75)]
- [56] 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)]
- [57] Qin PD, Wang X, Chen WH, Zhang CY, Xu WR. 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)]
- [58] Du ZX, Zhou C, Ding M, Yang HX, Tang J. Cognitive knowledge graph reasoning for one-shot relational learning. arXiv:1906.05489, 2019.
- [59] Zhang NY, Deng SM, Sun ZL, Chen JY, Zhang W, Chen HJ. Relation adversarial network for low resource knowledge graph completion. In: Proc. of the 2020 Web Conf. Taipei: ACM, 2020. 1–12. [doi: [10.1145/3366423.3380089](https://doi.org/10.1145/3366423.3380089)]
- [60] Xie HC, Li AP, Jia Y. Few-shot knowledge reasoning method based on attention mechanism. In: Proc. of the 8th Int'l Conf. on Computing and Pattern Recognition. Beijing: ACM, 2019. 46–51. [doi: [10.1145/3373509.3373574](https://doi.org/10.1145/3373509.3373574)]

- [61] Li JL, Tang TY, Zhao WX, Wei ZC, Yuan NJ, Wen JR. Few-shot knowledge graph-to-text generation with pretrained language models. In: Proc. of the 2021 Association for Computational Linguistics: ACL-IJCNLP 2021. Association for Computational Linguistics, 2021. 1558–1568. [doi: [10.18653/v1/2021.findings-acl.136](https://doi.org/10.18653/v1/2021.findings-acl.136)]
- [62] Zhao ZH, Wallace E, Feng S, Klein D, Singh S. Calibrate before use: Improving few-shot performance of language models. In: Proc. of the 38th Int'l Conf. on Machine Learning. JMLR.org, 2021. 12697–12706.
- [63] Li Q, Chen Z, Ji C, Jiang SQ, Li JX. LLM-based multi-level knowledge generation for few-shot knowledge graph completion. In: Proc. of the 33rd Int'l Joint Conf. on Artificial Intelligence. Jeju: IJCAI, 2024. 2135–2143.
- [64] Nickel M, Tresp V, Kriegel HP. A three-way model for collective learning on multi-relational data. In: Proc. of the 28th Int'l Conf. on Machine Learning. Bellevue: Omnipress, 2011. 809–816.
- [65] 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.
- [66] 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.org, 2016. 2071–2080.
- [67] Zhang S, Tay Y, Yao Y, Li Q. Quaternion knowledge graph embeddings. In: Proc. of the 33rd Int'l Conf. on Neural Information Processing Systems. Curran Associates Inc., 2019. 2731–2741.
- [68] Balazevic I, Allen C, Hospedales T. TuckER: Tensor factorization for 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: Association for Computational Linguistics, 2019. 5184–5193. [doi: [10.18653/v1/D19-1522](https://doi.org/10.18653/v1/D19-1522)]
- [69] Liu HX, Wu YX, Yang YM. Analogical inference for multi-relational embeddings. In: Proc. of the 34th Int'l Conf. on Machine Learning. Sydney: JMLR.org, 2017. 2168–2178.
- [70] 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)]
- [71] Vashishth S, Sanyal S, Nitin V, Agrawal N, Talukdar P. InteractE: Improving convolution-based knowledge graph embeddings by increasing feature interactions. In: Proc. of the 34th AAAI Conf. on Artificial Intelligence. New York: AAAI, 2020. 3009–3016. [doi: [10.1609/aaai.v34i03.5694](https://doi.org/10.1609/aaai.v34i03.5694)]
- [72] Nguyen DQ, Nguyen TD, Nguyen DQ, Phung D. A novel embedding model for knowledge base completion based on convolutional neural network. In: Proc. of the 2018 Conf. of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. New Orleans: Association for Computational Linguistics, 2018. 327–333. [doi: [10.18653/v1/N18-2053](https://doi.org/10.18653/v1/N18-2053)]
- [73] Jiang XT, Wang Q, Wang B. Adaptive convolution for multi-relational learning. In: Proc. of the 2019 Conf. of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Minneapolis: Association for Computational Linguistics, 2019. 978–987. [doi: [10.18653/v1/N19-1103](https://doi.org/10.18653/v1/N19-1103)]
- [74] 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)]
- [75] Cai L, Yan B, Mai GC, Janowicz K, Zhu R. TransGCN: Coupling transformation assumptions with graph convolutional networks for link prediction. In: Proc. of the 10th Int'l Conf. on Knowledge Capture. Marina: ACM, 2019. 131–138. [doi: [10.1145/3360901.3364441](https://doi.org/10.1145/3360901.3364441)]
- [76] Shang C, Tang Y, Huang J, Bi JB, He XD, Zhou BW. End-to-end structure-aware convolutional networks for knowledge base completion. In: Proc. of the 33rd AAAI Conf. on Artificial Intelligence. Honolulu: AAAI, 2019. 3060–3067. [doi: [10.1609/aaai.v33i01.33013060](https://doi.org/10.1609/aaai.v33i01.33013060)]
- [77] Vashishth S, Sanyal S, Nitin V, Talukdar P. Composition-based multi-relational graph convolutional networks. In: Proc. of the 8th Int'l Conf. on Learning Representations. Addis Ababa: OpenReview.net, 2020.
- [78] 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)]
- [79] Bordes A, Usunier N, García-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. Lake Tahoe: Curran Associates Inc., 2013. 2787–2795.
- [80] 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, 2014. 1112–1119. [doi: [10.1609/aaai.v28i1.8870](https://doi.org/10.1609/aaai.v28i1.8870)]
- [81] 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)]
- [82] 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 and the 7th Int'l Joint Conf. on Natural Language Processing. Beijing: Association for Computational Linguistics, 2015. 687–696. [doi: [10.3115/v1/P15-1067](https://doi.org/10.3115/v1/P15-1067)]
- [83] Yoon HG, Song HJ, Park SB, Park SY. A translation-based knowledge graph embedding preserving logical property of relations. In: Proc. of the 2016 Conf. of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. San Diego: Association for Computational Linguistics, 2016. 907–916. [doi: [10.18653/v1/n16-1105](https://doi.org/10.18653/v1/n16-1105)]
- [84] Do K, Tran T, Venkatesh S. Knowledge graph embedding with multiple relation projections. In: Proc. of the 24th Int'l Conf. on Pattern Recognition. Beijing: IEEE, 2018. 332–337.
- [85] Fan M, Zhou Q, Chang E, Zheng TF. Transition-based knowledge graph embedding with relational mapping properties. In: Proc. of the 28th Pacific Asia Conf. on Language, Information and Computing. Phuket: Department of Linguistics, Chulalongkorn University, 2014. 328–337.
- [86] Xie QZ, Ma XZ, Dai ZH, Hovy E. An interpretable knowledge transfer model for knowledge base completion. In: Proc. of the 55th Annual Meeting of the Association for Computational Linguistics. Vancouver: Association for Computational Linguistics, 2017. 950–962. [doi: [10.18653/v1/P17-1088](https://doi.org/10.18653/v1/P17-1088)]
- [87] Nguyen DQ, Sirts K, Qu LZ, Johnson M. Neighborhood mixture model for knowledge base completion. In: Proc. of the 20th SIGNLL Conf. on Computational Natural Language Learning. Berlin: Association for Computational Linguistics, 2016. 40–50. [doi: [10.18653/v1/K16-1005](https://doi.org/10.18653/v1/K16-1005)]
- [88] 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, 2019. 7152–7159. [doi: [10.1609/aaai.v33i01.33017152](https://doi.org/10.1609/aaai.v33i01.33017152)]
- [89] Li WD, Zhang XY, Wang YQ, Yan ZH, Peng R. Graph2Seq: Fusion embedding learning for knowledge graph completion. IEEE Access, 2019, 7: 157960–157971. [doi: [10.1109/ACCESS.2019.2950230](https://doi.org/10.1109/ACCESS.2019.2950230)]
- [90] Zhang Z, Zhuang FZ, Zhu HS, Shi ZP, Xiong H, He Q. Relational graph neural network with hierarchical attention for knowledge graph completion. In: Proc. of the 34th AAAI Conf. on Artificial Intelligence. New York: AAAI, 2020. 9612–9619. [doi: [10.1609/aaai.v34i05.6508](https://doi.org/10.1609/aaai.v34i05.6508)]
- [91] Oh B, Seo S, Lee KH. Knowledge graph completion by context-aware convolutional learning with multi-hop neighborhoods. In: Proc. of the 27th ACM Int'l Conf. on Information and Knowledge Management. Torino: ACM, 2018. 257–266. [doi: [10.1145/3269206.3271769](https://doi.org/10.1145/3269206.3271769)]
- [92] Ferré S. Link prediction in knowledge graphs with concepts of nearest neighbours. In: Proc. of the 16th Int'l Conf. on the Semantic Web. Portorož: Springer, 2019. 84–100. [doi: [10.1007/978-3-030-21348-0_6](https://doi.org/10.1007/978-3-030-21348-0_6)]
- [93] Borrego A, Ayala D, Hernández I, Rivero CR, Ruiz D. CAFE: Knowledge graph completion using neighborhood-aware features. Engineering Applications of Artificial Intelligence, 2021, 103: 104302. [doi: [10.1016/j.engappai.2021.104302](https://doi.org/10.1016/j.engappai.2021.104302)]
- [94] Yin WP, Yaghoobzadeh Y, Schütze H. Recurrent one-hop predictions for reasoning over knowledge graphs. In: Proc. of the 27th Int'l Conf. on Computational Linguistics. Santa Fe: Association for Computational Linguistics, 2018. 2369–2378.
- [95] 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: Association for Computational Linguistics, 2011. 529–539.
- [96] Gardner M, Talukdar P, Krishnamurthy J, Mitchell T. Incorporating vector space similarity in random walk inference over knowledge bases. In: Proc. of the 2014 Conf. on Empirical Methods in Natural Language Processing (EMNLP). Doha: Association for Computational Linguistics, 2014. 397–406. [doi: [10.3115/v1/D14-1044](https://doi.org/10.3115/v1/D14-1044)]
- [97] Neelakantan A, Roth B, McCallum A. Compositional vector space models for knowledge base completion. In: Proc. of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th Int'l Joint Conf. on Natural Language Processing. Beijing: Association for Computational Linguistics, 2015. 156–166. [doi: [10.3115/v1/P15-1016](https://doi.org/10.3115/v1/P15-1016)]
- [98] Lin YK, Liu ZY, Luan HB, Sun MS, Rao SW, Liu S. Modeling relation paths for representation learning of knowledge bases. In: Proc. of the 2015 Conf. on Empirical Methods in Natural Language Processing (EMNLP). Lisbon: Association for Computational Linguistics, 2015. 705–714.
- [99] Garcia-Durán A, Bordes A, Usunier N, Grandvalet Y. Combining two and three-way embeddings models for link prediction in knowledge bases. arXiv:1506.00999, 2015.
- [100] Xiong SW, Huang WT, Duan PF. Knowledge graph embedding via relation paths and dynamic mapping matrix. In: Proc. of the 2018 Int'l Conf. on Conceptual Modeling. Xi'an: Springer, 2018. 106–118. [doi: [10.1007/978-3-030-01391-2_18](https://doi.org/10.1007/978-3-030-01391-2_18)]
- [101] Kuželka O, Davis J. Markov logic networks for knowledge base completion: A theoretical analysis under the MCAR assumption. In: Proc. of the 35th Uncertainty in Artificial Intelligence Conf. Tel Aviv: AUAI Press, 2019. 1138–1148.
- [102] 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. 2319–2328.
- [103] Cohen WW. Tensorlog: A differentiable deductive database. arXiv:1605.06523, 2016.
 - [104] Ghiasnezhad Omran P, Wang KW, Wang Z. Scalable rule learning via learning representation. In: Proc. of the 27th Int'l Joint Conf. on Artificial Intelligence. Stockholm: AAAI, 2018. 2149–2155.
 - [105] Rocktäschel T. Deep prolog: End-to-end differentiable proving in knowledge bases. In: Proc. of the 2nd Conf. on Artificial Intelligence and Theorem Proving. Obergurgl: AITP, 2017. 37.
 - [106] Meilicke C, Wudage Chekol M, Ruffinelli D, Stuckenschmidt H. Anytime bottom-up rule learning for knowledge graph completion. In: Proc. of the 28th Int'l Joint Conf. on Artificial Intelligence. Macao: AAAI, 2019. 3137–3143.
 - [107] Ma JT, Qiao YQ, Hu GW, Wang YJ, Zhang CQ, Huang YZ, Kumar Sangaiah A, Wu HG, Zhang HP, Ren K. ELPKG: A high-accuracy link prediction approach for knowledge graph completion. Symmetry, 2019, 11(9): 1096. [doi: 10.3390/sym11091096]
 - [108] Niu GL, Zhang YF, Li B, Cui P, Liu S, Li JY, Zhang XW. Rule-guided compositional representation learning on knowledge graphs. In: Proc. of the 34th AAAI Conf. on Artificial Intelligence. New York: AAAI, 2020. 2950–2958. [doi: 10.1609/aaai.v34i03.5687]
 - [109] Jiang TS, Liu TY, Ge T, Sha L, Li SJ, Chang BB, Sui ZF. Encoding temporal information for time-aware link prediction. In: Proc. of the 2016 Conf. on Empirical Methods in Natural Language Processing. Austin: Association for Computational Linguistics, 2016. 2350–2354. [doi: 10.18653/v1/D16-1260]
 - [110] Ni RY, Ma ZG, Yu KH, Xu XH. Specific time embedding for temporal knowledge graph completion. In: Proc. of the 19th IEEE Int'l Conf. on Cognitive Informatics & Cognitive Computing. Beijing: IEEE, 2020. 105–110. [doi: 10.1109/ICCICC50026.2020.9450214]
 - [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: Association for Computational Linguistics, 2018. 2001–2011. [doi: 10.18653/v1/D18-1225]
 - [112] Tang XL, Yuan R, Li QY, Wang TY, Yang HZ, Cai YD, Song HJ. Timespan-aware dynamic knowledge graph embedding by incorporating temporal evolution. IEEE Access, 2020, 8: 6849–6860. [doi: 10.1109/ACCESS.2020.2964028]
 - [113] Wang XZ, Gao TY, Zhu ZC, Zhang ZY, Liu ZY, Li JZ, Tang J. KEPLER: A unified model for knowledge embedding and pre-trained language representation. Trans. of the Association for Computational Linguistics, 2021, 9: 176–194. [doi: 10.1162/tacl_a_00360]
 - [114] Liu S, Qin YF, Xu M, Kolmanič S. Knowledge graph completion with triple structure and text representation. Int'l Journal of Computational Intelligence Systems, 2023, 16(1): 95. [doi: 10.1007/s44196-023-00271-0]
 - [115] 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]
 - [116] 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]
 - [117] Zhang X, Liang X, Zheng XP, Wu B, Guo YH. MULTIFORM: Few-shot knowledge graph completion via multi-modal contexts. In: Proc. of 2022 the European Conf. on Machine Learning and Knowledge Discovery in Databases. Grenoble: Springer, 2022. 172–187. [doi: 10.1007/978-3-031-26390-3_11]
 - [118] Wei YY, Chen W, Zhang XF, Zhao PP, Qu JF, Zhao L. Multi-modal siamese network for few-shot knowledge graph completion. In: Proc. of the 40th Int'l Conf. on Data Engineering. Utrecht: IEEE, 2024. 719–732. [doi: 10.1109/ICDE60146.2024.00061]
 - [119] 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]
 - [120] Zhang YC, Chen Z, Zhang W. MACO: A modality adversarial and contrastive framework for modality-missing multi-modal knowledge graph completion. In: Proc. of the 12th National CCF Conf. on Natural Language Processing and Chinese Computing. Foshan: Springer, 2023. 123–134. [doi: 10.1007/978-3-031-44693-1_10]
 - [121] 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, ICCL, 2024. 17120–17130.
 - [122] Zhang YC, Chen Z, Guo LB, Xu YJ, Hu BB, Liu ZQ, Zhang W, Chen HJ. Native: Multi-modal knowledge graph completion in the wild. In: Proc. of the 47th Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. Washington: ACM, 2024. 91–101. [doi: 10.1145/3626772.3657800]
 - [123] 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: Association for Computational Linguistics, 2022. 10527–10536. [doi: 10.18653/v1/2022.emnlp-main.719]
 - [124] Wang YP, Ning B, Wang X, Li GY. Multi-hop neighbor fusion enhanced hierarchical Transformer for multi-modal knowledge graph completion. World Wide Web (WWW), 2024, 27(1). [doi: 10.1007/s11280-024-01289-w]

- [125] Zhang YC, Chen Z, Guo LB, Xu YJ, Hu BB, Liu ZQ, Chen HJ, Zhang W. MyGO: Discrete modality information as fine-grained tokens for multi-modal knowledge graph completion. arXiv:2404.09468, 2024.
- [126] Zhang YC, Chen Z, Guo LB, Xu YJ, Hu BB, Liu ZQ, Zhang W, Chen HJ. Multiple heads are better than one: Mixture of modality knowledge experts for entity representation learning. In: Proc. of the 13th Int'l Conf. on Learning Representations. Singapor: OpenReview.net, 2025. 172–188.
- [127] Chen Q, Zhang D, Li SS, Zhou GD. Task knowledge fusion for multimodal knowledge graph completion. Ruan Jian Xue Bao/Journal of Software, 2025, 36(4): 1590–1603 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/7213.htm> [doi: 10.13328/j.cnki.jos.007213]
- [128] Li ZJ, Shen LW, Li G, Peng X. Text-oriented construction for CPS resource capability knowledge graph. Ruan Jian Xue Bao/Journal of Software, 2023, 34(5): 2268–2285 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6410.htm> [doi: 10.13328/j.cnki.jos.006410]
- [129] Zhang ZQ, Cai JY, Zhang YD, Wang J. Learning hierarchy-aware knowledge graph embeddings for link prediction. In: Proc. of the 34th AAAI Conf. on Artificial Intelligence. New York: AAAI, 2020. 3065–3072. [doi: 10.1609/aaai.v34i03.5701]
- [130] Li RR, Wu X, Wu X, Wang W. Few-shot learning for new user recommendation in location-based social networks. In: Proc. of the 2020 Web Conf. 2020. Taipei: ACM, 2020. 2472–2478. [doi: 10.1145/3366423.3379994]
- [131] Wu XD, Li J, Zhou P, Bu CY. Fusion technique for fragmented genealogy data. Ruan Jian Xue Bao/Journal of Software, 2021, 32(9): 2816–2836 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6010.htm> [doi: 10.13328/j.cnki.jos.006010]
- [132] Wu XD, Sheng SJ, Jiang TT, Bu CY, Wu MH. Huapu-CP: From knowledge graphs to a data central-platform. Acta Automatica Sinica, 2020, 46(10): 2045–2059 (in Chinese with English abstract). [doi: 10.16383/j.aas.c200502]
- [133] Wu XD, He J, Lu RL, Zheng NN. From big data to big knowledge: HACE+BigKE. Acta Automatica Sinica, 2016, 42(7): 965–982 (in Chinese with English abstract). [doi: 10.16383/j.aas.2016.c160239]
- [134] Dong BB, Zhang Z, Li J, Zhu Y, Bu CY, Wu XD. Hypernode: Entity fusion for data traceability and link prediction. In: Proc. of the 2022 IEEE Int'l Conf. on Data Mining. Orlando: IEEE, 2022. 111–120. [doi: 10.1109/ICDM54844.2022.00021]

附中文参考文献:

- [4] 毕鑫, 聂豪杰, 赵相国, 袁野, 王国仁. 面向知识图谱约束问答的强化学习推理技术. 软件学报, 2023, 34(10): 4565–4583. <http://www.jos.org.cn/1000-9825/6889.htm> [doi: 10.13328/j.cnki.jos.006889]
- [5] 乔少杰, 杨国平, 于泳, 韩楠, 覃晓, 屈露露, 冉黎琼, 李贺. QA-KGNet: 一种语言模型驱动的知识图谱问答模型. 软件学报, 2023, 34(10): 4584–4600. <http://www.jos.org.cn/1000-9825/6882.htm> [doi: 10.13328/j.cnki.jos.006882]
- [12] 张宁豫, 谢辛, 陈想, 邓淑敏, 叶宏彬, 陈华钧. 基于知识协同微调的低资源知识图谱补全方法. 软件学报, 2022, 33(10): 3531–3545. <http://www.jos.org.cn/1000-9825/6628.htm> [doi: 10.13328/j.cnki.jos.006628]
- [17] 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]
- [18] 吴国栋, 刘涵伟, 何章伟, 李景霞, 王雪妮. 知识图谱补全技术研究综述. 小型微型计算机系统, 2023, 44(3): 471–482. [doi: 10.20009/j.cnki.21-1106/TP.2022-0423]
- [25] 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]
- [78] 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]
- [127] 陈强, 张栋, 李寿山, 周国栋. 融合任务知识的多模态知识图谱补全. 软件学报, 2025, 36(4): 1590–1603. <http://www.jos.org.cn/1000-9825/7213.htm> [doi: 10.13328/j.cnki.jos.007213]
- [128] 李正洁, 沈立炜, 李弋, 彭鑫. 面向文本描述的 CPS 资源能力知识图谱构建. 软件学报, 2023, 34(5): 2268–2285. <http://www.jos.org.cn/1000-9825/6410.htm> [doi: 10.13328/j.cnki.jos.006410]
- [131] 吴信东, 李娇, 周鹏, 卜晨阳. 碎片化家谱数据的融合技术. 软件学报, 2021, 32(9): 2816–2836. <http://www.jos.org.cn/1000-9825/6010.htm> [doi: 10.13328/j.cnki.jos.006010]
- [132] 吴信东, 盛绍静, 蒋婷婷, 卜晨阳, 吴明辉. 从知识图谱到数据中台: 华谱系统. 自动化学报, 2020, 46(10): 2045–2059. [doi: 10.16383/j.aas.c200502]
- [133] 吴信东, 何进, 陆汝钤, 郑南宁. 从大数据到大知识: HACE+BigKE. 自动化学报, 2016, 42(7): 965–982. [doi: 10.16383/j.aas.2016.c160239]



郑修林(1995—), 男, 博士生, 主要研究领域为数据挖掘, 知识图谱补全, 大模型技术, 知识工程.



张赞(1987—), 男, 博士, 副教授, 主要研究领域为因果学习, 弱监督学习.



周鹏(1987—), 男, 博士, 副教授, CCF 专业会员, 主要研究领域为数据挖掘, 机器学习, 知识工程.



黄艳香(1990—), 女, 博士, 主要研究领域为数据挖掘, 大数据分析, 推荐系统.



李培培(1982—), 女, 博士, 教授, 博士生导师, CCF 专业会员, 主要研究领域为短文本/多标签数据流挖掘, 概念漂移检测方法及应用.



吴信东(1963—), 男, 博士, 教授, 博士生导师, 主要研究领域为数据挖掘, 大数据分析, 知识工程.