

知识图谱问答领域综述^①

郑泳智¹, 朱定局¹, 吴惠麟², 彭小荣³

¹(华南师范大学 计算机学院, 广州 510631)

²(广州国家现代农业产业科技创新中心, 广州 510520)

³(广州市增城区文化馆, 佛山 511300)

通信作者: 朱定局, E-mail: zhudingju@m.scnu.edu.cn



摘要: 近年来, 随着知识图谱的发展, 利用给定的知识图谱数据自动得出人类自然语言问题的答案成为了时下的研究热点, 诸如 Siri 和小爱同学的问答系统已经广泛投入使用。得益于深度学习的引入, 该领域的各子课题虽然有所突破, 但依然存在需要攻克的难点, 例如多跳推理和策略组合等。本文从主流的构建方法为切入点, 归纳总结该领域研究现状以及所面临的挑战, 不仅有助于研究者高效展开对该领域的研究工作, 更有利于不同行业的研究者研发行业相关的问答系统, 提高行业生产力。

关键词: 知识图谱; 智能问答; 语义解析; 信息检索; 问答系统; 分析工具

引用格式: 郑泳智, 朱定局, 吴惠麟, 彭小荣. 知识图谱问答领域综述. 计算机系统应用, 2022, 31(4):1-13. <http://www.c-s-a.org.cn/1003-3254/8418.html>

Overview on Knowledge Graph Question Answering

ZHENG Yong-Zhi¹, ZHU Ding-Ju¹, WU Hui-Lin², PENG Xiao-Rong³

¹(School of Computer Science, South China Normal University, Guangzhou 510631, China)

²(Guangzhou National Modern Agricultural Industry Science and Technology Innovation Center, Guangzhou 510520, China)

³(Zengcheng District Cultural Center of Guangzhou, Foshan 511300, China)

Abstract: With the development of knowledge graphs, utilizing given knowledge graph data to automatically obtain answers to human natural language questions has become popular in recent years. QA (question answering) systems such as Siri and Xiao Ai have been widely used. Thanks to the introduction of deep learning, breakthroughs have been made in various sub-projects in this field, while there are still difficulties that need to be overcome, such as multi-hop reasoning and strategy combination. Therefore, starting from the mainstream construction method, this study summarizes the current research status and challenges in this field, which can not only help researchers to efficiently carry out research in this field but also help researchers in different industries to develop industry-related QA systems to improve productivity.

Key words: knowledge graph; intelligent question answering; semantic analysis; information retrieval; question answering system; analysis tools

1 知识图谱

1.1 知识图谱的发展及定义

知识图谱 (knowledge graph, KG) 源自于 1960 年提出的语义网络, 有着源自于 NLP、Web、AI 等方面

的基因, 它通过结合数学与信息科学等学科理论与方法, 以可视化形式描述其资源与载体, 应用于问答、推荐等领域, 其概念演化如图 1 所示。

语义网络是用图表示知识的方式, 图 2 是一个语

① 基金项目: 中国高等教育学会专项课题 (2020JXD01); 广东省普通高校“人工智能”重点领域专项 (2019KZDZX1027); 广东高校省级重点平台和重大科研项目 (2017KTSCX048); 广东省公益研究与能力建设 (2018B070714018); 广东省中医药局科研项目 (20191411); 广东省高等学校产业学院建设项目 (人工智能机器人教育产业学院)

收稿时间: 2021-06-10; 修改时间: 2021-07-14; 采用时间: 2021-07-30; csa 在线出版时间: 2022-03-22

义网络示例,信息被表达为一组节点,节点间以有向直线相连表示关系,其优点在于表达直接且清晰明确,可用于检索与推理,但不适用于定量动态的知识.

本体(ontology)一词起源于希腊语,是一个哲学术语,在哲学的角度,它关注的是“存在”,而本体论则是对世界任意领域内的存在作客观描述.例如,世界是什么?太阳是什么?星星是什么?1980年,McCarthy^[1]提出以逻辑概念为基础的智能系统需列出所有存在的事物并构建一个本体描述我们的世界.至此,人工智能领域开始引入哲学本体论思想内涵用于刻画知识.1989年,Berners-Lee发明了万维网(World Wide Web, WWW),它作为视频、图片等媒体信息的最深远、最广泛媒介,标志着信息共享进入了新时代.1998年,依托万维网的语义网(semantic web)诞生,这一概念旨在将万维网上的文档添加为可被理解的语义元数据,即文档组织形式转变为以URI标识的更小的数据碎片,同时建立本体库表征数据,使互联网成为通用信息交换媒介.2006年,Berners-Lee提出链接数据(linked data),鼓励各信息源从文档组织形式向这种最小数据碎片形式迁移并发布这些数据作为开放数据,且尽量参考已知本体进行建模并赋予其唯一URI用以标识,较有名的项目有DBpedia、Freebase等.2012年,谷歌为了优化其搜索引擎提出知识图谱的概念,知识图谱由一些相互连接的实体以及它们的属性构成^[2],其基础是语义网和本体论,其本质是表示实体联系的语义网络.其中,每个实体或概念用一个全局唯一ID标识,每个属性值用于刻画实体内在特性,而关系(relation)用来连接两个实体,刻画它们之间的关联.通俗而言,知

识图谱是一张巨大的图,图中的节点表示实体或概念,而图中的边则由属性或关系构成,这种图模型可用W3C提出的资源描述框架(resource description framework,RDF)^[3]表示.

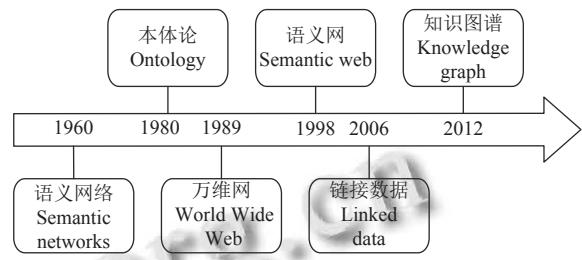


图1 知识图谱概念演化

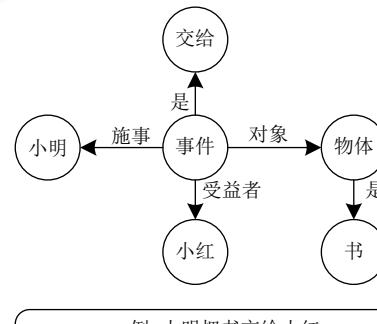


图2 语义网络示例

知识图谱按问题领域划分,可分为通用领域和垂直领域,垂直领域知识图谱是基于特定行业数据构建的,规模虽小,但知识质量高,精度高.而通用领域知识图谱覆盖更广,规模更大,自动化程度更高.本文归纳整理了近些年通用领域知识图谱的项目,如表1所示.

表1 开放领域知识图谱项目

项目名称	年份	当前数据规模	特点
ConceptNet ^[4]	2002	2100万边和800万个节点	融合Open Mind Common Sense、Verbosity、Nadya.jp、WordNet、JMDict等资源
DBpedia ^[5]	2007	119种语言,45亿RDF三元组	最早的维基类知识图谱
Freebase ^[6]	2007	—	谷歌知识图谱的核心,2010年被谷歌收购,数据已迁至维基
YAGO ^[7]	2007	6085万事实	融合维基百科、WordNet和GeoNames等资源
NELL ^[8]	2010	300万RDF三元组	通过网络进行自学习
BabelNet ^[9]	2011	500种语言2000万个同义词集	融合BabelNet live、Wikipedia、Wiktionary、Wikidata和GeoNames等资源
Zhishi.me ^[10]	2013	1728.3万个实体	融合百度百科、互动百科、中文维基等资源
Xlore ^[11]	2019	1628.4万个实体 246万个概念	融合百度百科、中英文维基、法语维基等资源

1.2 知识图谱的构建

通用知识图谱为了融合规模更庞大的实体,通常采用自底向上方式构建,而垂直领域知识图谱的构建对领域知识的深度和精度有很高的要求,需要有完善

的本体模式层.如图3所示,知识图谱的构建,首先需要不断的采集数据、包括结构化、半结构化、非结构化数据,知识是日新月异的,通用领域的知识图谱需要不断的扩充其实体库就需要不断的采集数据.采集得

到的数据通常需要进行数据清洗、缺失值处理、异常值处理等,然后使用自然语言处理的手段提取数据中的实体、关系、属性。目前主流的实体识别方法通常使用结合BERT和BiLSTM+CRF的变式模型提取实体,使用基于卷积神经网络模型(CNN)来抽取关系。得到的实体词通常需要进行对齐操作,包括实体消歧和共指消歧。例如“我的手机是苹果”和“我喜欢吃苹果”中都有“苹果”一词,但所指意思不一致,这就需要进行实体消歧处理,消歧方法包括基于规则的方法、机器学习的方法、全局最优方法、基于知识库的方法、深度学习算法。抽取得到的可靠三元组数据将导入存储知识的数据库,目前主流的图数据库有Neo4j^[12]、Jena^[13]等。

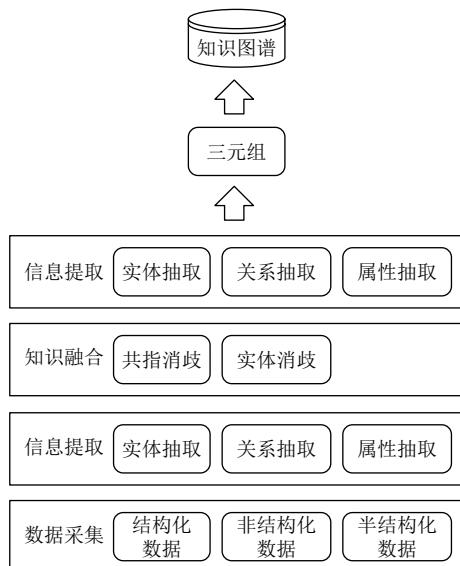


图3 知识图谱的构建过程

2 智能问答

2.1 智能问答的发展

智能问答是自然语言处理中的重要分支,通常以一问一答的人机交互形式定位用户所需知识并提供个性化信息服务。它能让计算机自动并以精准自然语言形式回答用户所提出的问题且不同于搜索引擎。

如表2所示,智能问答的历史可以追溯至1950年,计算机科学之父阿兰·图灵为了检验计算机是否具备精准应答问题的能力,提出机器能否思考的判断方案——图灵测试,自此翻开了自然语言人机交互的篇章。20世纪60年代前后,首批问答系统问世,Green等人^[14]设计的Baseball程序可用普通英语回答有关棒球比赛的问题,1971年月球科学大会上,LUNAR系统^[15]首次

亮相,它可以回答月岩样本分析的相关问题,但这一时期的QA系统只停留在处理领域结构化数据层面上。20世纪70年代前后,语言学的兴起、马尔科夫假设等理论的提出、数据库构建成本降低,使得问答系统构建难度也因此而降低。该时期的问答系统集成自然语言处理、知识表示等方法分析用户问题,耶鲁大学开发的SAM系统^[16]便是这一时期的产物,它引入计划的概念并使用脚本来理解问题,但是其缺点在于脚本未就绪则系统将无法工作。20世纪90年代,计算机运算能力提升,基于机器学习的自然语言处理诞生,智能问答进入了开放领域、自由文本时期。智能问答研究热点转向基于大规模文档集的问答、研究领域从限定领域延展至开放领域,研究对象从固定语料库延伸至互联网。2002年,密歇根大学开发了一个支持多语言的WQA系统^[17],用户可以使用多语言提问。同时期有影响力的问答系统还有Webclopedia^[18]、LAMP^[19]等。2009年,Wolfram Research公司推出的Wolfram Alpha在线自动问答系统能给出答案与答案相关的所有信息,这一时期的系统越渐成熟,涵盖多领域多语言的知识数据,配有相应的可视化界面。当2011年IBM公司研发的“沃森”在美国知识竞赛节目《危险边缘》中战胜两位顶尖人类选手后,基于深度学习的智能问答再次成为研究热点。

表2 智能问答项目

时间	项目	描述
1950	图灵测试	为检验计算机是否具备精准应答问题的能力
1960s	Baseball程序	用普通英语回答有关棒球比赛的问题
1973	LUNAR系统	回答月岩样本分析的相关问题
1970s	SAM系统	引入计划的概念并使用脚本来理解问题
2002	WQA系统	用户可以自由使用多语言提问
2009	Wolfram Alpha	能给出答案与答案相关的所有信息
2011	沃森	知识竞赛中战胜人类

2.2 基于知识图谱的问答系统

近年来,随着知识图谱概念渗透到各领域,基于知识图谱的智能问答逐渐成为焦点之一,在金融、医疗、旅游、农业、电商等垂直领域,都不乏相关研究,例如李贺等人^[20]构建的基于疾病知识图谱的问题系统,杜泽宇等人^[21]的电商知识图谱的问答系统,由于医疗和电商等领域对该类系统的需求较大,因此完善程度也较好。这些基于知识图谱的问答系统,或利用当中的知识数据结合深度学习构建问答系统;或利用图谱

的推理能力理解问题; 或融合问题与三元组的信息编码至向量空间, 在向量空间内完成问题相关的相似度计算任务, 得出用户所需近似答案。归结基于知识图谱问答系统的构建方法有3种, 即语义解析 (semantic parsing, SP)、信息检索 (information retrieval, IR)、向量建模 (vector modeling, VM)。学术界有一种说法称主流方法只分为语义解析和信息检索, 只是近年来将深度学习应用于两种传统的方法, 更将VM归结一种类似IR的方法。在该领域, 一些研究者旨在深入研究KBQA的子任务, 例如问题实体检测、关系抽取、多跳推理等, 一些研究者则研究整体的通用框架, 如Pei等人^[22]设计基于TransE的中文领域知识图谱问答通用框架, 涉及多模型融合。本文以这些任务中使用到的关键技术为侧重点对该领域技术现状以及展开阐述。

2.3 问答数据集

研究KBQA离不开数据集, 而不同数据集通常针对不同QA任务, 包括简单问题和复杂问题。一些研究者为达成研究目的还需要扩充公共数据集或独自构建数据集, 如Miller等人^[23]为了验证其网络功能而提出

MovieQA数据集。但大多数研究者会选择使用公共基准数据集, 既省去构建时间而专注于算法模型的设计, 又便于对比同类模型。而人工标注数据集往往需要高成本人力物力, 因此数据集的构建者会使用模版构建问答数据集, 但仅使用模版生成问题的数据集缺乏多样性, 而缺乏多样性的数据集作为训练数据时通常会降低模型对复杂问题的泛化能力, 因此近年来数据集的构建者会以构建高质量数据集为目标。本文归纳整理了近年来具有代表性数据集, 如表3所示。从体量上看, 数据集的规模已从千级别扩展至百万级别, 其中含有复杂问题的数据集体量往往较小。从基于的知识库看, 早期数据集一般基于Freebase构建, 2016年Freebase被收购后, KGQA数据集大多基于Wikidata和DBpedia。近3年, 数据集的问题焦点放在了多样性、SPARQL以及推理过程上。考虑到以往的数据集很少有推理过程, 2021年, Shi等人^[24]基于Wikidata数据加入推理过程构建KQA Pro, 它包含了多样的简单问题与复杂问题, 且保证了其规模与质量, 无疑是近年来高质量的数据集之一。

表3 基于知识图谱的问答数据集

名称	提出年份	KG	规模	简单问题	复杂问题	特点描述
WebQuestions ^[25]	2013	Freebase	5810	√	√	复杂的多跳和推理问题相对较少
Free917 ^[26]	2013	Freebase	917	√	√	首次尝试了构建成规模KGQA数据集
SimpleQuestions ^[27]	2015	Freebase	108442	√	×	根据知识生成问句, 弥补CSQA规模小的问题
WikiQA ^[28]	2015	Wikidata	3000	√	×	包括没有正确句子的问题, 能够进行答案触发
SQuAD1.1 ^[29]	2016	Wikidata	100000	√	√	众包方式产生阅读理解数据问题与答案, 多样性较好
WebQuestionsSP ^[30]	2016	Freebase	4737	√	√	是WebQuestions含SPARQL标注的升级版
ComplexQuestions ^[31]	2016	Freebase	2100	√	√	通过搜索引擎获取, 针对复杂问题而构建的数据集
GraphQuestions ^[32]	2016	Freebase	5166	√	√	涉及较多复杂逻辑
30M Factoid Questions ^[33]	2016	Freebase	30000000	√	×	由模型自动构建的
NLPCC ICCPOL 2016 KBQA ^[34]	2016	Wikidata	24479	√	×	开放领域的中文数据集, 答案是三元组对象
LC-QuAD ^[35]	2017	DBpedia	5000	√	√	一个针对DBpedia的复杂问题数据集
SQuAD2.0 ^[36]	2018	Wikidata	约150000	√	√	较1.1版本增加5万多个问题
DBNQA ^[37]	2018	DBpedia	约890000	√	×	通过模板构造, 缺乏多样性
QALD-8 ^[38]	2018	DBpedia	50~500	√	√	规模虽小, 但表达更复杂、口语化
CSQA ^[39]	2018	Wikidata	1600000	√	√	复杂序列问答
ComplexWebQuestions ^[40]	2018	Freebase	34689	√	√	部分问题蕴含了复杂的推理
LC-QuAD2 ^[41]	2019	DBpedia Wikidata	30000	√	√	在1.0版本上扩充的数据集
GRAILQA ^[42]	2020	Freebase	64331	√	√	一个针对复杂问题的数据集, 但缺乏多样性
KQA pro ^[24]	2021	Wikidata	117970	√	√	提供上述数据集都不具备的推理过程

3 构建方法

本节对目前主流的基于模板的语义解析方法、基于语义查询图的方法、基于编码解码的方法、基于检索的方法进行介绍, 并对其进行归纳总结如表4

所示。基于模板的语义解析方法其核心在于模板于规则的制定、语义查询图的核心在于如何用语义图来表示自然语言的句子结构、编解码的方法的核心在于构建编码模型捕获句子特征、基于检索的方法其

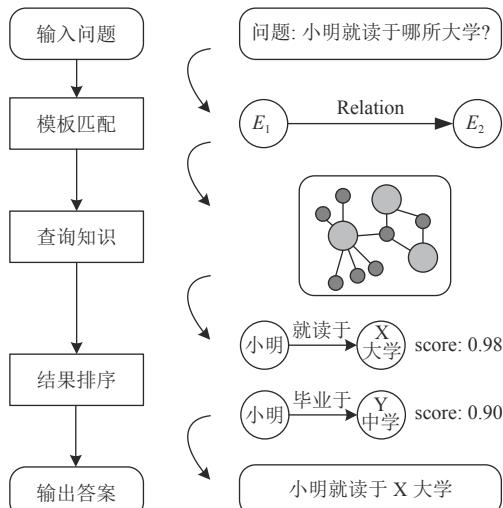
核心在于句法的信息如何映射为特征图或句子特征转为空间向量。

表4 构建方法对比分析

方法	核心	优点	缺点
基于模板的语义解析方法	预定义模板	过程清晰, 可解释性强	可扩展性有限、需要语言学知识
基于语义查询图的方法	语义图表示	有类似于自然语言句子的结构能充分利用知识库	通用性不高语义图的构建需要依赖特定手段
基于编码解码的方法	注意力机制句法图编码	可以捕获一些容易忽略的句法信息	可解释性稍差
门控图神经网络	端到端模型	增强语义, 解决复杂问题有更佳效果	需要大量训练材料
依存句法分析	依存句法分析	可将问句转换为特征图	对复杂问题支持度较差, 计算效率低
基于检索的方法	记忆网络	可将问句和答案转换为同一语义空间向量	在处理复杂问题上仍有进步空间

3.1 基于模板的语义解析方法

语义解析方法是一种语言学方法, 其思想是将非结构化的自然语言问题映射为一系列结构化逻辑形式, 例如语义图和高级查询语言(如 SPARQL, Cypher 等)。而基于模板的语义解析方法其思想在于将问题先转换为人为预定义的规则或模板, 再转换为可执行的查询。如图 4 所示, 输入的问题首先被映射为逻辑形式, 该过程通过预定义模版规则进行映射, 得到实体与关系 $\langle E_1, \text{Relation}, E_2 \rangle$, 再进一步转化为图数据库的可执行查询得到知识图谱中的相应的答案。本文归纳整理了近年来在这方面的研究如表 5 所示。



依赖于人工标注的逻辑形式对于大规模 KBQA 任务而言成本很高, Berant 等人^[27]实现了一个标准的自底向上解析器。首先利用知识库和大型文本语料库建立从问题短语到知识库实体或关系的粗映射; 然后使用桥接操作基于相邻谓词生成其他谓词, 将问题短语映射到知识库实体和关系。该解析器依赖于一个对数线性模型来覆盖手工构建的特性, 减少了搜索的空间, 并在 Cai 等人^[43]的数据集上得到了验证。Bast 等人^[44]提出了一个基于模板的模型 Aqqu, 该模型将问题映射到 3 个模板, 先从知识库中识别出与该问题的一部分匹配的所有实体, 匹配可以是文字匹配, 也可以是实体名称的别名。然后, Aqqu 实例化 3 个模板, 其中知识图谱子图以匹配的实体为中心, 根据基于手工特征的排序模型, 输出最佳实例以查询知识库并获得答案。然而, Aqqu 中的 3 个模板对复杂问题的覆盖范围有限。为处理更多问题, 研究人员尝试从数据集中自动或半自动地学习模板。Abujabal 等人^[45]提出了一种名为 QUINT 的自动模板生成模型, 自动模板分为查询模板和问题模板。其中查询模板负责从知识库中提取规则, 问题模板则依靠解析给定问题中的依赖关系产生。在运行过程中, 首先将问题查询映射到一些问题模板, 然后将相应的查询模板实例化为候选结果, 最后在排序后输出得分最高的查询即为最终答案。为保证自动创建的问题模板的质量并得以商用, Spiegel 等人^[46]提出一个模块化的 MK-SQuIT 框架, 通过生成和优化问题模板和查询模板自动合成数据集。Abujabal 等人^[47]提出的 NEQA 类似于 TeBaQA^[48], 同样是基于模板的 KBQA 系统, 均使用连续学习范式回答未知领域问题。但除了使用基于相似度的模板匹配方法之外, 它还依赖于用户反馈并随着时间推移而改进。另外, TeBaQA 还可以仅使用基准数据集就能轻松地应用到新的领域, 在可扩展性上与之前的方案相比更有优势。

表5 基于模板的语义解析方法的研究

提出的内容	特点
Berant等人 ^[27]	利用对数线性模型覆盖手工构建模板的特性, 减少搜索空间
提出的语义解析器 Aqqu ^[44]	基于手工特征的排序模型输出最佳实例对复杂问题支持有限
QUINT ^[45]	自动模板, 可处理更多问题, 但质量有限
MK-SQuIT ^[46]	类似 QUINT, 但较 QUINT 质量更高
TeBaQA ^[48]	可扩展性较强
NEQA ^[47]	可依赖于用户反馈并随着时间推移而改进

基于模板的语义解析方法其核心在于模板的构建, 其优点在于过程清晰, 可解释性强, 但此类方法需要结合语言学的知识, 无论是自动或半自动的构建方案都需要一定的工作量.

3.2 基于语义查询图的方法

依赖于预定义模版的方法可扩展性有限, 而且需要较专业的语言学知识, 无疑带来大量的工作量, 因此出现了基于神经语义分析的方法 (neural semantic parsing, NSP). 它以增强解析能力和可扩展性为目的, 将非结构化问题映射为语义图这种中间逻辑形式, 然后再将其转换为 SPARQL 查询.

图 5 展示了问题“小明去过广州最高的建筑物是什么?”的一个简单的查询图结构, 此类查询图通常由 4 种类型的节点组成、用圆角矩形表示的主题实体、用圆表示的已存在变量、用阴影圆表示变量, 用菱形表示聚合函数. 其中主题实体是知识图谱中的现有实体, 阴影圆节点 x 也称为答案节点, 用于映射请求检索得到的实体, 菱形节点限制了答案必须是最高的建筑物. 得到如下逻辑形式:

$$\lambda x. \exists y. \text{LocateIn}(GZ, y) \wedge \text{Names}(y, x) \wedge \text{BeenTo}(XiaoMing, y) \quad (1)$$

执行该查询 (不包含聚合函数) 将会匹配到“国际金融中心”“广州塔”等实体, 再结合聚合函数可得到最终答案为“广州塔”.

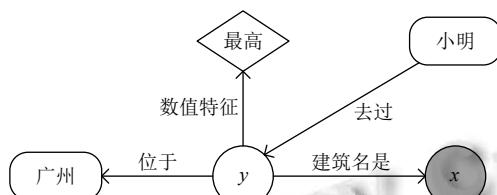


图 5 语义查询图示例

本文归纳整理了近年来此类研究的内容及特点^[49-60], 如表 6 所示.

Reddy 等人^[49] 提出了一种基于图的语义解析器 GraphParser, 使用组合范畴语法 (combinatory categorial grammar, CCG) 将句子转换为语义查询图, 通过语义查询图表示自然语言时可将图的边映射为知识图谱的关系, 图的节点映射到知识图谱实体或类型等, 并采用集束搜索方法得出最佳语义查询图.

2013 年 Kwiatkowski 等人^[50] 曾经指出当逻辑形式使用与知识图谱中定义的谓词不相同时, 可能会存

在本体匹配问题. 因此他构建的解析器是从问题-答案对中学习的, 使用 CCG 构建语言动机的逻辑形式, 改进本体匹配的准确性. 后来, Zou 等人^[51] 提出以结构化的方式对自然语言问题的查询意图进行建模, 在此基础上, 将 QA 任务简化为子图匹配问题, 他们考虑到在线 QA 系统的查询对系统成本较高, 考虑改进消歧方法, 便采用一种惰性方法, 将歧义消除推到了查询评估阶段以提升整体性能.

表 6 基于语义查询图方法的研究

研究侧重点	文献	特点
图的构建与匹配	[51]	提出模型GraphParser, 用CCG将句子转换为语义查询图映射至知识图谱
	[52]	改进本体匹配准确性
	[53]	对查询意图建模, 简化子图匹配
分阶段查询	[54]	提出分阶段查询模型STAGG, 提高知识利用率 在STAGG基础上提出MultiCG模型, 涵盖了更多复杂问题
	[55]	
	[56]	在STAGG基础上加入BiLSTM, 增强实体链接和关系路径分量以提高精度
引入编码	[60]	结合GraphParse和STAGG提出STF模型, 以更灵活的策略来回答复杂问题
	[57]	首次从局部和全局角度, 对语义图和问题进行编码
	[58]	引入自注意力机制
	[59]	考虑了实体和关系的顺序

为使得知识图谱的知识利用率更高, 而且受到文献 [49] 的启发, Yih 等人^[52] 在 Kwiatkowski 研究的基础上提出了一个名为分阶段查询图生成框架 (staged query graph generation, STAGG). 框架将其分解为 3 个阶段的搜索问题, 第 1 阶段, 利用实体链接工具获取候选实体及其得分; 第 2 阶段, STAGG 找到主题实体和答案节点之间的所有关系路径, 但为了限制搜索空间, 仅当中间存在变量可被固定到复合值类型节点 (compound value type, CVT) 时才探索长度 2 的路径, 否则探索长度 1 的路径; 第 3 阶段, 根据启发式规则将约束节点附加到关系路径上. 每一个阶段均利用对数线性模型对当前部分查询图进行评分, 并输出最佳的最终查询图来查询知识库. STAGG 在 WebQuestion 基准数据集上进行实验并验证了其语义空间裁剪的有效性, 不仅简化了任务难度, 更提高了查询效率. 但是为了限制搜索空间, STAGG 只探索有限长度关系路径, 因此难以处理多跳等复杂问题. 考虑到文献 [52] 提出的 STAGG 暂不能覆盖某些复杂的约束, Bao 等人^[53] 在 2016 年提出在 STAGG 的基础上扩展了约束类型和算子, 包括类型约束和显式

与隐式时间约束,并提出了多约束的语义查询图(multiple constraint query graph, MultiCG)来解决这些复杂问题.但MultiCG仍然在整体上继承了STAGG框架,只是提供了更多的规则来涵盖复杂问题.为了得到更高的精度,Yu等人^[53]在STAGG框架基础上,提出使用深度残差双向LSTM模型(hierarchical residual-BiLSTM)来编码问题和关系路径,并计算所有问题的相似性得分,使得实体链接和关系路径两个分量相互增强以提高精度.其中关系路径是指在单词级别和短语级别与候选主题实体关联的所有关系路径,最后只保留候选主题实体中得分较高的.

只将关注点放在实体链接或约束而忽视组合语义通常不利于解决复杂问题.Luo等人^[54]认为语义图中的各语义成分只传递部分信息,即现有方法无法捕获组合语义,这是由于对不同的组件进行单独编码造成的.因此,文献[54]首次从局部和全局的角度对语义图和问题进行编码,生成全局统一的表示向量.文献[54]指出统一的矢量表示形式可以顺利地捕获了复杂问题中各语义成分信息,他们的实验在ComplexQuestion等数据集上便验证了这一点.后来,有不少研究者在此基础上做出了改进,其中Maheshwariet等人^[55]除了对该类模型的排序方法进行了实证研究以外,还提出了一种基于自注意力机制的模型;Zhu等人^[56]提出了一种树到序列算法,考虑了实体和关系的顺序,并使用基于树的LSTM对语义图进行编码;为了适应更多类型的复杂问题,例如具有更多隐含关系的问题,Hu等人^[57]提出了一个结合了GraphParse和STAGG的状态转换框架(STF),以更灵活的策略来回答复杂问题,虽优于STAGG,但仍缺乏处理复杂聚合问题的能力.

基于语义查询图的方法其核心在于如何将自然语言问句用语义图来表示并映射至知识图谱的查询,优点在于能充分利用知识,但这些方法都依赖特定构建手段,在通用性上还有待提高.

3.3 基于编码解码的方法

除了使用基于语义图的方法,还有一种常用的语义解析方法,即基于编解码的方法.如图6所示,自然语言问题输入编码器和解码器后,得到适用于数据库处理的逻辑表示作为输出.

近年来,基于递归神经网络的编解码模型已成功应用于各种NLP任务,如语法解析^[58],因此研究者开始尝试将编解码模型也运用于KBQA中的语义解析

方法.本文整理近年来的相关研究对比如表7所示.

Dong等人^[59]在2016年提出的一种基于注意力机制的增强型编解码模型,学习自然语言和逻辑形式之间的对齐方式,将问题转换为逻辑形式.但其中存在一些问题,例如解码过程中可能会忽略较长的疑问词,而这是编解码模型的常见问题,可以通过Tu等人^[60]提出的显式建模解决.Xu等人^[61]指出了使用普通的序列编码器提取词序通常会忽略一些有价值的句法信息.因此,他们采用图序模型来编码句法图,而句法图表示了词序、依存关系等特征,用于捕获一些通常被忽略的句法信息.但是这种方法需要大量训练材料,不适用于多数KBQA场景.

为了增强问题的语义,一些研究人员会把关注点放在义素上.义素是词义的最小意义单位,他们希望以更细的粒度来捕获信息以增强语义.例如,Wu等人^[62]提出一种基于义素的语义解析方法,对问题中的义素级别的信息进行编码以减少噪声,并引入了一种层次表示法对关系进行编码,尽可能的消除词语歧义.为了更高效的消除歧义并丰富问题的信息,Wu等人^[63]利用外部知识,将义素级别的信息和注释都集成到词语中,增强了模型对问题的理解.

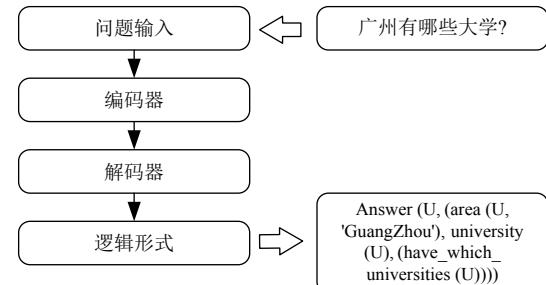


图6 基于编解码模型的方法

近年来,神经机器翻译模型NMT也被考虑应用到KBQA的任务中,Ji等人^[64]提出结合语义相似度模型和神经机器翻译模型,将复杂问题转化为子查询,将并行执行子查询的结果组装成完整SPARQL查询.类似的,Wang等人^[65]构建了4种基于神经机器翻译的模型将问题转换为SPARQL查询.

KBQA任务往往分为多个子任务,但是为每个任务的样本做标注不仅是高成本的做法,而且存在上游任务到下游任务的传播误差问题,因此端到端的模型成为了研究的热点之一.与Lukovnikov等人^[66]和Huang等人^[67]提出仅解决单跳推理的模型不同的是,Srivastava

等人^[68]提出一种基于BERT模型的多任务神经网络机器翻译模型(CQA-NMT),可以应对实体链接、多跳推理等多个子任务的挑战。他们以扩展的BERT模型作为编码器,以Transformer作为解码器,更好的解决了多跳问题。而且在MetaQA数据集上进行的实验均优于PullNet^[69]、EmbedKGQA^[70]。

当研究者将关注点放在为问题选择正确语义关系的时候往往会忽略语义解析的结构,即实体之间的连接和关系的方向。这些信息通常是解决复杂问题的关键,Sorokin等人^[71]提出GGNN架构,使用门控图神经网络对语义解析的结构进行编码,利用Bi-GRUs提取问题中的语义特征,匹配得出相关语义部分,再利用CNN模型学习问题与关系之间的相似度,这种使用门控图神经网络的新颖方法有效提升了回答复杂问题的效果。

3.4 基于检索的方法

基于检索的方法旨在将自然语言问题和知识库中的实体和关系映射为同一低维空间中的特征向量,将任务转化为问题向量与知识图谱中对应关系向量之间的相似度匹配任务。根据其特征表示技术的不同,又分为基于特征工程的方法和基于表示学习的方法。本文整理近年来的相关研究对比如表8所示。

基于特征工程的方法特点是从依存句法分析结果提取问题词等特征并转化为问句特征图后,组合主题实体子图的候选特征图,将权重偏向于关联度较高的特征。例如Yao等人^[72]提出的模型则是基于此类方法。但该方法除了对复杂问题的支持度较差以外,还需要自行定义并抽取特征,而且容易造成维度太高,计算效率低等问题。而基于表示学习方法为了解决该类问题,将问句和候选答案转换为同一语义空间的向量,将该问题转换为问句与答案的向量匹配计算问题。

Bordes等人^[73]首次提出将问句和图谱中候选实体映射至同一向量空间,但该模型忽略了词序对句子的影响,Dong等人^[74]提出的MCCNNs模型则考虑到词序、答案类型等特征,但也存在问句向量转换为定长向量的问题,容易忽略了隐含的问句信息。因此Hao等人^[75]和Qu等人^[76]利用带有注意力机制的模型来捕获隐含信息,尽管效果有所提升,但在处理复杂问题上仍有进步的空间。Bordes等人^[75]采用记忆网络(memory network)模型将问题和图谱的知识等信息存于记忆网络中,在记忆槽中选取一些相关度高的信息通过响应模块来得到答案,实验证明该方案比大多数的检索方法好。

表7 基于编解码的方法研究

文献	目标	方法特点	待改进之处
[62]	构建编解码模型 对齐自然语言与逻辑形式	结合LSTM Encoder和Tree-LSTM Decoder并引入注意力机制。	可能会忽略较长疑问词
[64]	对句法图进行编码	引入句法图表示词序、依存关系、成分句法等特征。	需要大量训练材料,不适用多数场景
[65,66]	更细粒度捕获信息增强语义	基于义素的解析方法,对问题中的义素级别的信息进行编码以减少噪声,利用外部知识,义素级别信息和注释集成到词语中。	在复杂问题的支持上有待提高
[67,68]	复杂问题转化为子查询 子查询组装为SPARQL查询	结合语义相似度模型和神经机器翻译模型实现。	模型训练成本高
[71]	应对实体链接、多跳推理任务	提出CQA-NMT,以扩展的BERT模型作为编码器,以Transformer作为解码器。	同上,工作量大,成本高
[74]	对语义结构进行编码 提升回答复杂问题的效果	提出GGNN架构,使用门控图神经网络对语义解析的结构进行编码,利用Bi-GRUs提取问题中的语义特征,匹配得出相关语义部分,再利用CNN模型学习问题与关系之间的相似度。	存在噪声连接和过平滑问题

而基于检索的方法离不开实体识别与检索。近年来,越来越多的实体检索模型比传统方法有显著改进。Naseri等人^[77]提出利用相关实体信息丰富实体的表示。Kadilierakis等人^[78]在ElasticSearch的基础上支持了对RDF数据集的关键字搜索。Gerritse等人^[79]利用Wikipedia2Vec^[80]展开实体排名的研究。Nikolaev等人^[81]

实现了名为Kewer的系统,可以通过使用联合词和实体嵌入来对实体进行排序,并且不需要大量的文本语料库。后来,Esmeir等人^[82]基于Kewer系统提出了SERAG,其任务是从阿拉伯知识图谱中检索语义实体。由于具有多跳推理功能,SERAG明显优于经典的BM25模型^[83]。

表8 基于检索的方法研究

分类	文献	目标	方法特点	待改进之处
基于特征工程	[75]	将任务转化为问题向量与知识图谱中对应关系向量之间的相似度匹配任务	基于特征工程的方法,从依存句法分析结果提取问题词等特征并转化为问句特征图后,将权重偏向于关联度较高的特征。	对复杂问题的支持度较差,计算效率低
	[76]	将问句和图谱中候选实体映射至同一向量空间	利用训练数据中的问题答案对以及知识库进行向量建模。	忽略了词序对句子的影响
	[77]	捕获词序、答案类型等特征	提出MCCNNs模型,使用多列卷积神经网络来学习问题的表示,这些列可以描述问题的答案路径、答案类型、答案上下文,且模型共享相同词向量。	问句向量转换为定长向量时,容易忽略了隐含的问句信息
基于表示学习	[78,79]	捕获隐含的问句信息	引入注意力机制,根据不同的答案的类型给予问题中不同单词的权重。	处理复杂问题上仍有进步空间
	[80]	捕获更多的问句信息	采用记忆网络,将问题和图谱的知识等信息存于记忆网络中,在记忆槽中选取一些相关度高的信息通过响应模块来得到答案。	对数据的要求高

4 发展趋势与挑战

当前KBQA的发展向着结合深度学习模型的方法靠拢,以解决多跳推理问题、提高模型的解释性为主要目标。

4.1 多跳推理

KBQA中的多跳推理问题一直都是亟待解决的问题,解决方法往往是结合多元的信息来增强模型的理解力,例如Shi等人^[84]提出了TransferNet,在统一的框架中解决两种不同形式的多跳问题,且在MetaQA数据集中实现了2跳3跳问题的100%准确性;Qin等人^[85]提出利用多个推理路径信息来解决多跳问题;Wu等人^[86]结合知识图谱中的数据作为上下文信息,结合注意力机制构建REN模型。但面对不同的问题数据集时,解决多跳问题的模型在数据集上的扩展性仍是需要考虑的问题。

4.2 策略组合

随着近年来深度学习的发展,基于语义解析的方法和基于检索的方法正逐渐走向组合化,以STAGG为例,近年来出现的许多KBQA算法都试图将这两种范式进行组合,从而使它们能够兼具两者的优点。信息抽取方式中提出的主题子图的概念与人类思维方式相似,语义解析方式可以更好地把握问题中的约束信息。因此,如何设计一个可以更好地整合这两种范式的优秀神经网络是未来的趋势。

4.3 数据质量

KBQA的性能在很大程度上取决于知识图谱的质量和问题数据集的质量,但是现有开放式知识图谱的大小和完整性依然需要与时俱进。因此,知识图谱高效

自动化建设将是KBQA领域重要的研究方向之一。具备自动挖掘隐藏关系的能力将有助于系统及时准确地更新内容。另外,近年来流行的记忆网络,也证明了充分利用知识图谱先验知识也是重点研究方向之一。

4.4 可靠性与可解释性

尽管端到端模型的引入降低了人工成本,但是在端到端模型中,许多方法通常会忽略模型预测的不确定性,因为基于端到端的方法将所有决策留给模型本身,其中的不可解释性可能会使高性能KBQA系统也变得不可靠,Zhang等人^[87]提出了一种基于贝叶斯神经网络(BNN)的端到端KBQA模型,实体及其上下文和候选谓词均由Bayesian-BiLSTM编码,其实验取得的成效说明在未来提高模型的鲁棒性,增强模型的可解释性也是该领域的一个必不可少的研究方向。

5 结束语

知识图谱囊括的知识数据与日俱增,自动问答需求充斥着社会各个领域,然而基于知识图谱的问答系统仍有许多技术难点亟待攻破。未来,基于知识图谱的问答系统应以构建回答准确率高、可解释性强、稳定可靠的模型为目标,不断迭代更新KBQA领域的技术。

参考文献

- 1 McCarthy J. Circumscription—A form of non-monotonic reasoning. Artificial Intelligence, 1980, 13(1–2): 27–39.
- 2 Pan JZ, Vetere G, Gomez-Perez JM, et al. Exploiting Linked Data and Knowledge Graphs in Large Organisations. Berlin, Heidelberg: Springer, 2017.
- 3 Beckett D, McBride B. RDF/XML syntax specification

- (revised). W3C Recommendation, 2004, 10(2,3).
- 4 Liu H, Singh P. ConceptNet—A practical commonsense reasoning tool-kit. *BT Technology Journal*, 2004, 22(4): 211–226.
- 5 Auer S, Bizer C, Kobilarov G, et al. Dbpedia: A nucleus for a web of open data. In: Aberer K, Choi KS, Noy N, et al., eds. *The Semantic Web*. Berlin, Heidelberg: Springer, 2007. 722–735.
- 6 Bollacker K, Evans C, Paritosh P, et al. Freebase: A collaboratively created graph database for structuring human knowledge. *Proceedings of the 2008 ACM SIGMOD International Conference on Management of Data*. New York: ACM, 2008. 1247–1250.
- 7 Suchanek FM, Kasneci G, Weikum G. Yago: A large ontology from Wikipedia and WordNet. *Journal of Web Semantics*, 2008, 6(3): 203–217.
- 8 Carlson A, Betteridge J, Kisiel B, et al. Toward an architecture for never-ending language learning. *Proceedings of the 24th AAAI Conference on Artificial Intelligence*. Atlanta: AAAI Press, 2010. 1306–1313.
- 9 Navigli R, Ponzetto SP. BabelNet: Building a very large multilingual semantic network. *Proceedings of the 48th Annual Meeting of the Association for Computational Linguistics*. Uppsala: Association for Computational Linguistics, 2010. 216–225.
- 10 Niu X, Sun XR, Wang HF, et al. Zhishi.me—Weaving Chinese linking open data. *International Semantic Web Conference*. Bonn: Springer, 2011. 205–220.
- 11 Wang ZG, Li JZ, Wang ZC, et al. XLore: A large-scale English-Chinese bilingual knowledge graph. *Proceedings of the 12th International Semantic Web Conference (Posters & Demos)*. Aachen: CEUR-WS.org, 2013. 121–124.
- 12 Webber J. A programmatic introduction to Neo4j. *Proceedings of the 3rd Annual Conference on Systems, Programming, and Applications: Software for Humanity*. New York: ACM, 2012. 217–218.
- 13 McBride B. Jena: A semantic web toolkit. *IEEE Internet Computing*, 2002, 6(6): 55–59.
- 14 Green BF, Wolf AK, Chomsky C, et al. Baseball: An automatic question-answerer. *Western Joint IRE-AIEE-ACM Computer Conference*. New York: ACM, 1961. 219–224.
- 15 Woods WA. Progress in natural language understanding: An application to lunar geology. *Proceedings of the National Computer Conference and Exposition*. New York: ACM, 1973. 441–450.
- 16 Schank RC, Abelson RP. Scripts, plans, and knowledge. *Proceedings of the 4th International Joint Conference on Artificial Intelligence*. San Francisco: Morgan Kaufmann Publishers Inc., 1975. 151–157.
- 17 Radev DR, Qi H, Wu H, et al. Evaluating web-based question answering systems. *Proceedings of the 3rd International Conference on Language Resources and Evaluation*. Las Palmas: European Language Resources Association, 2002.
- 18 Hovy E, Gerber L, Hermjakob U, et al. Question answering in webclopedia. *Proceedings of the 9th Text Retrieval Conference*. Gaithersburg: National Institute of Standards and Technology, 2000. 53–56.
- 19 Zhang D, Lee W S. Web based pattern mining and matching approach to question answering. *Proceedings of the 11th Text Retrieval Conference*. Gaithersburg: National Institute of Standards and Technology, 2002. 497.
- 20 李贺, 刘嘉宇, 李世钰, 等. 基于疾病知识图谱的自动问答系统优化研究. *数据分析与知识发现*, 2021, 5(5): 115–126.
- 21 杜泽宇, 杨燕, 贺樑. 基于中文知识图谱的电商领域问答系统. *计算机应用与软件*, 2017, 34(5): 153–159.
- 22 Pei ZM, Zhang J, Xiong W, et al. A general framework for Chinese domain knowledge graph question answering based on TransE. *Journal of Physics: Conference Series*, 2020, 1693(1): 012136.
- 23 Miller A, Fisch A, Dodge J, et al. Key-value memory networks for directly reading documents. *Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing*. Austin: ACL, 2016. 1400–1409.
- 24 Shi JX, Cao SL, Pan LM, et al. KQA Pro: A large diagnostic dataset for complex question answering over knowledge base. *arXiv: 2007.03875v1*, 2020.
- 25 Bordes A, Usunier N, Chopra S, et al. Large-scale simple question answering with memory networks. *arXiv: 1506.02075*, 2015.
- 26 Cai QQ, Yates A. Semantic parsing freebase: Towards open-domain semantic parsing. *Proceedings of the Second Joint Conference on Lexical and Computational Semantics*. Atlanta: ACL, 2013. 328–338.
- 27 Berant J, Chou A, Frostig R, et al. Semantic parsing on freebase from question-answer pairs. *Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing*. Seattle: ACL, 2013. 1533–1544.
- 28 Yang Y, Yih WT, Meek C. Wikiqa: A challenge dataset for open-domain question answering. *Proceedings of the 2015 Conference on Empirical Methods in Natural Language Processing*. Lisbon: ACL, 2015. 2013–2018.

- 29 Rajpurkar P, Zhang J, Lopyrev K, et al. Squad: 100,000+ questions for machine comprehension of text. arXiv: 1606.05250, 2016.
- 30 Yih WT, Richardson M, Meek C, et al. The value of semantic parse labeling for knowledge base question answering. Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers). Berlin: ACL, 2016. 201–206.
- 31 Bao JW, Duan N, Yan Z, et al. Constraint-based question answering with knowledge graph. Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics: Technical Papers. Osaka: The COLING 2016 Organizing Committee, 2016. 2503–2514.
- 32 Su Y, Sun H, Sadler B, et al. On generating characteristic-rich question sets for QA evaluation. Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. Austin: ACL, 2016. 562–572.
- 33 Serban IV, García-Durán A, Gulcehre C, et al. Generating factoid questions with recurrent neural networks: The 30m factoid question-answer corpus. Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Berlin: ACL, 2016. 588–598.
- 34 Duan N. Overview of the NLPCC-ICCPOL 2016 shared task: Open domain Chinese question answering. In: Lin CY, Xue NW, Zhao DY, et al., eds. Natural Language Understanding and Intelligent Applications. Cham: Springer, 2016. 942–948.
- 35 Trivedi P, Maheshwari G, Dubey M, et al. LC-QuAD: A corpus for complex question answering over knowledge graphs. International Semantic Web Conference. Vienna: Springer, 2017. 210–218.
- 36 Rajpurkar P, Jia R, Liang P. Know what you don't know: Unanswerable questions for SQuAD. Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers). Melbourne: ACL, 2018. 784–789.
- 37 Hartmann AK, Tommaso ME, Moussallem D, et al. Generating a large dataset for neural question answering over the DBpedia knowledge base. Workshop on Linked Data Management, co-located with the W3C WEBBR. 2018, 2018.
- 38 Usbeck R, Ngomo ACN, Conrads F, et al. 8th challenge on question answering over linked data (QALD-8). Language, 2018, 7: 1.
- 39 Saha A, Pahuja V, Khapra M, et al. Complex sequential question answering: Towards learning to converse over linked question answer pairs with a knowledge graph. Proceedings of the 32nd AAAI Conference on Artificial Intelligence. New Orleans: AAAI Press, 2018. 705–713.
- 40 Talmor A, Berant J. The Web as a knowledge-base for answering complex questions. arXiv: 1803.06643, 2018.
- 41 Dubey M, Banerjee D, Chaudhuri D, et al. EARL: Joint entity and relation linking for question answering over knowledge graphs. International Semantic Web Conference. Monterey: Springer, 2018. 108–126.
- 42 Gu Y, Kase S, Vanni M, et al. Beyond I.I.D.: Three levels of generalization for question answering on knowledge bases. Proceedings of the Web Conference 2021. New York: ACM, 2020. 3477–3488.
- 43 Cai QQ, Yates A. Large-scale semantic parsing via schema matching and lexicon extension. Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Sofia: ACL, 2013. 423–433.
- 44 Bast H, Haussmann E. More accurate question answering on freebase. Proceedings of the 24th ACM International Conference on Information and Knowledge Management. New York: ACM, 2015. 1431–1440.
- 45 Abujabal A, Yahya M, Riedewald M, et al. Automated template generation for question answering over knowledge graphs. Proceedings of the 26th International Conference on World Wide Web. Republic and Canton of Geneva: International World Wide Web Conferences Steering Committee, 2017. 1191–1200.
- 46 Spiegel BA, Cheong V, Kaplan JE, et al. MK-SQuIT: Synthesizing questions using iterative template-filling. arXiv: 2011.02566v1, 2020.
- 47 Abujabal A, Roy RS, Yahya M, et al. Never-ending learning for open-domain question answering over knowledge bases. Proceedings of the 2018 World Wide Web Conference. Republic and Canton of Geneva: International World Wide Web Conferences Steering Committee, 2018. 1053–1062.
- 48 Vollmers D, Jalota R, Moussallem D, et al. Knowledge graph question answering using graph-pattern isomorphism. arXiv: 2103.06752, 2021.
- 49 Reddy S, Lapata M, Steedman M. Large-scale semantic parsing without question-answer pairs. Transactions of the Association for Computational Linguistics, 2014, 2: 377–392.
- 50 Kwiatkowski T, Choi E, Artzi Y, et al. Scaling semantic parsers with on-the-fly ontology matching. Proceedings of

- the 2013 Conference on Empirical Methods in Natural Language Processing. Seattle: ACL, 2013. 1545–1556.
- 51 Zou L, Huang RZ, Wang HX, et al. Natural language question answering over RDF: A graph data driven approach. Proceedings of the 2014 ACM SIGMOD International Conference on Management of Data. New York: ACM, 2014. 313–324.
- 52 Yih SW, Chang MW, He X, et al. Semantic parsing via staged query graph generation: Question answering with knowledge base. Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). Beijing: ACL, 2015. 1321–1331.
- 53 Yu M, Yin WO, Hasan KS, et al. Improved neural relation detection for knowledge base question answering. Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Vancouver: ACL, 2017. 571–581.
- 54 Luo KQ, Lin FL, Luo XS, et al. Knowledge base question answering via encoding of complex query graphs. Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Brussels: ACL, 2018. 2185–2194.
- 55 Maheshwari G, Trivedi P, Lukovnikov D, et al. Learning to rank query graphs for complex question answering over knowledge graphs. International Semantic Web Conference. Auckland: Springer, 2019. 487–504.
- 56 Zhu SG, Cheng X, Su S. Knowledge-based question answering by tree-to-sequence learning. Neurocomputing, 2020, 372: 64–72.
- 57 Hu S, Zou L, Zhang XB. A state-transition framework to answer complex questions over knowledge base. Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing. Brussels: ACL, 2018. 2098–2108.
- 58 Vinyals O, Kaiser Ł, Koo T, et al. Grammar as a foreign language. Proceedings of the 28th International Conference on Neural Information Processing Systems. Montreal, 2015. 2773–2781.
- 59 Dong L, Lapata M. Language to logical form with neural attention. arXiv: 1601.01280, 2016.
- 60 Tu ZP, Lu ZD, Liu Y, et al. Modeling coverage for neural machine translation. Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Berlin: ACL, 2016. 76–85.
- 61 Xu K, Wu LF, Wang ZG, et al. Exploiting rich syntactic information for semantic parsing with graph-to-sequence model. arXiv: 1808.07624, 2018.
- 62 Wu PY, Zhang XW. A sememe-based approach for knowledge base question answering. Proceedings of the ISWC 2020 Demos and Industry Tracks: From Novel Ideas to Industrial Practice co-located with 19th International Semantic Web Conference (ISWC 2020). CEUR-WS.org, 2020. 175–179.
- 63 Wu PY, Zhang XW. Improving knowledge base question answering with question understanding augment. Proceedings of the ISWC 2020 Demos and Industry Tracks: From Novel Ideas to Industrial Practice co-located with 19th International Semantic Web Conference (ISWC 2020). CEUR-WS.org, 2020. 167–171.
- 64 Ji G, Wang S, Zhang X, et al. A fine-grained complex question translation for KBQA. Proceedings of the ISWC 2020 Demos and Industry Tracks: From Novel Ideas to Industrial Practice Co-located with 19th International Semantic Web Conference (ISWC 2020). CEUR-WS.org, 2020. 194–199.
- 65 Wang SJ, Jiao J, Li YH, et al. Answering questions over RDF by neural machine translating. Proceedings of the ISWC 2020 Demos and Industry Tracks: From Novel Ideas to Industrial Practice Co-located with 19th International Semantic Web Conference (ISWC 2020). CEUR-WS.org, 2020. 189–194.
- 66 Lukovnikov D, Fischer A, Lehmann J. Pretrained transformers for simple question answering over knowledge graphs. International Semantic Web Conference. Auckland: Springer, 2019. 470–486.
- 67 Huang X, Zhang JY, Li DC, et al. Knowledge graph embedding based question answering. Proceedings of the 12th ACM International Conference on Web Search and Data Mining. New York: ACM, 2019. 105–113.
- 68 Srivastava S, Patidar M, Chowdhury S, et al. Complex question answering on knowledge graphs using machine translation and multi-task learning. Proceedings of the 16th Conference of the European Chapter of the Association for Computational Linguistics: Main Volume. ACL, 2021. 3428–3439.
- 69 Sun HT, Bedrax-Weiss T, Cohen W. Pullnet: Open domain question answering with iterative retrieval on knowledge bases and text. Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP). Hong Kong: ACL, 2019.

- 2380–2390.
- 70 Saxena A, Tripathi A, Talukdar P. Improving multi-hop question answering over knowledge graphs using knowledge base embeddings. Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. ACL, 2020. 4498–4507.
- 71 Sorokin D, Gurevych I. Modeling semantics with gated graph neural networks for knowledge base question answering. arXiv: 1808.04126, 2018.
- 72 Yao XC, Van Durme B. Information extraction over structured data: Question answering with freebase. Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Baltimore: ACL, 2014. 956–966.
- 73 Bordes A, Chopra S, Weston J. Question answering with subgraph embeddings. Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Doha: ACL, 2014. 615–620.
- 74 Dong L, Wei FR, Zhou M, et al. Question answering over freebase with multi-column convolutional neural networks. Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing (Volume 1: Long Papers). Beijing: ACL, 2015. 260–269.
- 75 Hao YC, Zhang YZ, Liu K, et al. An end-to-end model for question answering over knowledge base with cross-attention combining global knowledge. Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Vancouver: ACL, 2017. 221–231.
- 76 Qu YQ, Liu J, Kang LY, et al. Question answering over freebase via attentive RNN with similarity matrix based CNN. arXiv: 1804.03317, 2018.
- 77 Naseri S, Foley J, Allan J, et al. Exploring summary-expanded entity embeddings for entity retrieval. Proceedings of the CIKM 2018 Workshops Co-located with 27th ACM International Conference on Information and Knowledge Management (CIKM 2018). Torino: CEUR-WS.org, 2018.
- 78 Kadilierakis G, Fafalios P, Papadakos P, et al. Keyword search over RDF using document-centric information retrieval systems. European Semantic Web Conference. Heraklion: Springer, 2020. 121–137.
- 79 Gerritse EJ, Hasibi F, De Vries AP. Graph-embedding empowered entity retrieval. European Conference on Information Retrieval. Lisbon: Springer, 2020. 97–110.
- 80 Yamada I, Asai A, Sakuma J, et al. Wikipedia2Vec: An efficient toolkit for learning and visualizing the embeddings of words and entities from wikipedia. Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing: System Demonstrations. ACL, 2018. 23–30.
- 81 Nikolaev F, Kotov A. Joint word and entity embeddings for entity retrieval from a knowledge graph. European Conference on Information Retrieval. Lisbon: Springer, 2020. 141–155.
- 82 Esmeir S. SERAG: Semantic entity retrieval from arabic knowledge graphs. Proceedings of the 6th Arabic Natural Language Processing Workshop. Kyiv: ACL, 2021. 219–225.
- 83 Pérez-Iglesias J, Pérez-Agüera JR, Fresno V, et al. Integrating the probabilistic models BM25/BM25F into Lucene. arXiv: 0911.5046, 2009.
- 84 Shi JX, Cao SL, Hou L, et al. TransferNet: An effective and transparent framework for multi-hop question answering over relation graph. arXiv: 2104.07302, 2021.
- 85 Qin KC, Wang Y, Li C, et al. A complex KBQA system using multiple reasoning paths. arXiv: 2005.10970, 2020.
- 86 Wu WQ, Zhu ZF, Zhang GY, et al. A reasoning enhance network for muti-relation question answering. Applied Intelligence, 2021, 51(7): 4515–4524.
- 87 Zhang LH, Lin C, Zhou DY, et al. A Bayesian end-to-end model with estimated uncertainties for simple question answering over knowledge bases. Computer Speech & Language, 2021, 66: 101167.