

开放领域知识图谱问答研究综述

陈子睿¹, 王 鑫^{1,2+}, 王 林³, 徐大为³, 贾勇哲^{1,3}

1. 天津大学 智能与计算学部, 天津 300350
2. 天津市认知计算与应用重点实验室, 天津 300350
3. 天津泰凡科技有限公司, 天津 300457
+ 通信作者 E-mail: wangx@tju.edu.cn

摘要: 知识图谱问答是通过处理用户提出的自然语言问题, 基于知识图谱的某种形式, 从中获取相关答案的过程。由于知识规模、计算能力及自然语言处理能力的制约, 早期知识库问答系统被应用于限定领域。近年来, 随着知识图谱的发展, 以及开放领域问答数据集的陆续提出, 知识图谱已用于开放领域问答研究与实践。以技术发展为主线, 对开放领域知识图谱问答进行综述。首先, 介绍五种基于规则模板的开放领域知识图谱问答方法: 传统语义解析、传统信息检索、三元组匹配、话语模板和查询模板, 这类方法主要依赖人工定义的规则模板完成问答工作。其次, 描述五种基于深度学习的方法, 这类方法采用神经网络模型完成问答过程的各类型任务, 包括知识图谱嵌入、记忆网络、基于神经网络的语义解析、基于神经网络的查询图、基于神经网络的信息检索。接着, 介绍开放领域知识图谱问答常用的4个通用领域知识图谱和11个开放领域问答数据集。随后, 按照问题的难易程度选择3个经典问答数据集比较各问答系统的性能指标, 对比不同方法间的性能差异并进行分析。最后, 展望开放领域知识图谱问答的未来研究方向。

关键词: 知识图谱问答(KGQA); 开放领域; 深度学习; 语义解析; 信息检索

文献标志码:A **中图分类号:**TP311

Survey of Open-Domain Knowledge Graph Question Answering

CHEN Zirui¹, WANG Xin^{1,2+}, WANG Lin³, XU Dawei³, JIA Yongzhe^{1,3}

1. College of Intelligence and Computing, Tianjin University, Tianjin 300350, China
2. Tianjin Key Laboratory of Cognitive Computing and Application, Tianjin 300350, China
3. Tianjin TechFantasy Co., Ltd., Tianjin 300457, China

Abstract: Knowledge graph question answering (KGQA) is the procedure of processing natural language questions posed by users to obtain relevant answers from knowledge graph (KG) based on some form of KG. Due to the limitation of knowledge scale, computing power and natural language processing capability, the early knowledge base question answering systems were limited to closed-domain questions. In recent years, with the development of KG and the construction of open-domain question answering (QA) datasets, KG has been used for open-domain QA research and practice. In this paper, in accordance with the development of technology, the open-domain KGQA is summarized. Firstly, five rule and template based KGQA methods are reviewed, including traditional semantic

基金项目:国家重点研发计划(2019YFE0198600);国家自然科学基金面上项目(61972275)。

This work was supported by the National Key Research and Development Program of China (2019YFE0198600) and the General Project of National Natural Science Foundation of China (61972275).

收稿日期:2021-06-25 **修回日期:**2021-08-24

parsing, traditional information retrieval, triplet matching, utterance template, and query template. This type of methods mainly relies on manually defined rules and templates to complete QA task. Secondly, five deep learning based KGQA methods are introduced, which use neural network models to complete the subtasks of QA process, including knowledge graph embedding, memory network, neural network-based semantic parsing, neural network-based query graph, and neural network-based information retrieval method. Thirdly, four general domain KG and eleven open-domain QA datasets, which KGQA commonly used are described. Fourthly, three classic KGQA datasets are selected according to the difficulty of questions to compare and analyze the performance metric of each KGQA system, and the effect between above methods. Finally, this paper looks forward to the future research directions on this topic.

Key words: knowledge graph question answering (KGQA); open-domain; deep learning; semantic parsing; information retrieval

问答系统(question answering, QA)能够自动回答用户提出的自然语言问题,是信息检索和自然语言处理的交叉研究方向^[1]。知识库(knowledge base, KB)是用于存储计算机所使用的结构化及非结构化知识的数据管理系统。早期知识库问答多以限定领域知识库为信息源的专家系统为主,允许非专业用户使用自然语言检索由专家构建的限定领域知识库并获得所需领域问题的答案,而无需使用数据库查询语言(如SQL)来构建查询。代表性系统包括BASEBALL^[2]和LUNAR^[3]。

近年来,随着语义网(semantic web)^[4-5]、知识图谱(knowledge graph, KG)^[6]、信息检索及深度学习等技术的发展,Freebase^[7]、DBpedia^[8]、YAGO^[9]等通用领域知识图谱及开放领域问答数据集被提出,使用限定领域知识库回答单一领域问题已不能满足用户对多领域问题解答的需求。知识图谱问答(knowledge graph question answering, KGQA)作为限定领域知识库问答的发展,如何通过使用诸如Freebase等通用领域知识图谱的知识作为KGQA系统的信息源,以回答开放领域的问题,即开放领域知识图谱问答,开始受到学术界和工业界的广泛关注。

开放领域知识图谱问答的实际应用十分广泛:可作为搜索引擎的组成部分,将问答系统所得答案与搜索引擎所得结果同时进行展示;还可用于智能对话、智能客服、智能助理^[10]等系统,帮助人们获取知识^[11]、执行任务,或利用多轮对话补全用户意图^[12]。

为了实现开放领域知识图谱问答,问答系统需要利用问题的语义信息深入理解自然语言问题,并从通用领域知识图谱中获取答案。然而,随着知识图谱数据规模的增长以及人们对直接获得问题答案

的需求不断增加,现有的开放领域知识图谱问答研究常常面临如下挑战:

(1)提取问题的语义信息。无论对于语义解析还是信息检索方法而言,都需要系统充分理解并利用用户所提问题的语义信息,定位KG中与问题高度相关的子知识图谱以避免庞大的搜索空间,但如何在自然语言问题中充分获取语义信息是KGQA面临的一大挑战。

(2)充分利用知识图谱信息。通用领域KG的规模通常较为庞大,其中不乏大量长尾关系及同名不同义实体。如何训练系统,使得系统对KG信息进行充分的掌握与利用是KGQA面临的又一挑战。

(3)答案可解释性。对于整个KGQA系统而言,通过将自然语言作为输入,用户可以直接得到答案输出。而对于答案具体如何产生,系统应如何为用户解释答案的来源也是KGQA要解决的重要问题。

目前,已有大量开放领域知识图谱问答的方法被提出,但尚无同时涵盖开放领域知识图谱问答全部方法,并用相同基线评测分析不同方法运行效果的综述工作。文献[13]针对2016年以前的方法进行综述,选择2个经典问答数据集作为基线,对比不同方法的运行效果,进而衡量不同方法的有效性,但该综述认为开放领域知识图谱问答的所有方法皆由流程相同的5个子任务组成,忽略了流程多样性。文献[14]将基于神经网络的方法作为综述内容,缺少基于规则模板方法的综述。文献[15]的方法内容相对完善,但仍缺少对传统语义解析方法的论述。文献[16]更侧重于对方法的简要论述,对开放领域知识图谱问答相关资源及方法实现原理缺乏详细描述。文献[14-16]皆未在相同基线上统一评测不同方法的运行

效果。本文详细介绍了开放领域知识问答的各类方法及实现原理,并在3个经典问答数据集上分别评测不同方法的运行效果,整体框架如图1所示。

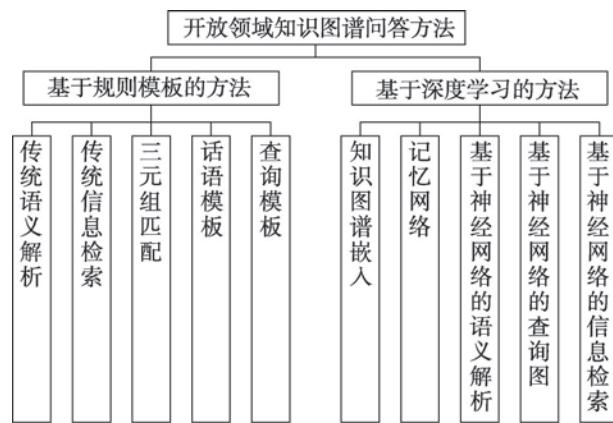


Fig.1 Framework of knowledge graph question answering methods

图1 开放领域知识图谱问答方法框架

图2按照时间顺序列出本文进行综述的主要方法,方法间的箭头表示方法的演变方向。从图中可以看出,在深度学习技术得到广泛应用之前,开放领域知识图谱问答以人工因素占主导的规则模板方法为主。最初通过词汇表、依存分析等方法构建查询

语句,进而检索KG获得问题答案的传统语义解析方法较多;基于语义解析方法,传统信息检索形成了以查询图为中间结构的话语(utterance)模板方法。在此期间,三元组匹配方法和查询模板方法同样有所发展。随着深度学习技术的不断发展,传统基于规则模板的方法由于系统的人工因素占比较高、通用性与迁移能力较低、准确率等性能指标提升瓶颈等原因,导致该类方法的研究热度逐渐减低;而同期,基于深度学习方法在人为因素占比、通用性、迁移能力、准确率方面具有较好潜力及表现,导致目前KGQA的研究全面转向基于深度学习的方法。在基于深度学习方法的部分,基于低维向量空间的知识图谱嵌入方法率先产生;随后以知识图谱嵌入为基础的记忆网络方法被提出;接着是利用诸如卷积神经网络(convolutional neural networks, CNN)、注意力机制(attention mechanism)、图神经网络(graph neural networks, GNN)等神经网络模型,对传统基于规则模板方法流程各环节的性能提升工作,诸如实体关系抽取、候选排序等工作,包括基于神经网络的语义解析、查询图和信息检索方法,其中基于神经网络的信息检索方法近几年得到了广泛关注。

本文的目标在于对开放领域知识图谱问答的最新研究进展提供全面深入的文献综述,以便人们对

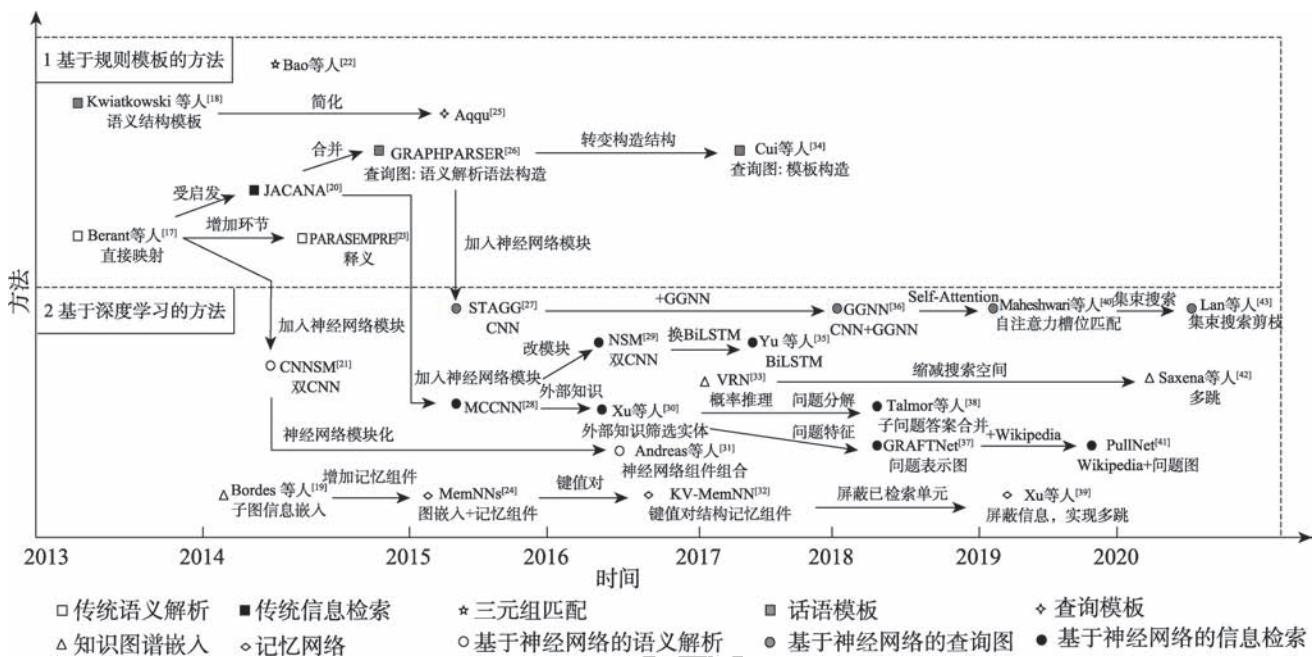


Fig.2 Timeline of knowledge graph question answering methods

图2 开放领域知识图谱问答方法时间轴

该研究领域有快速深刻的理解。具体来说,本文的贡献在于:

(1)从开放领域知识图谱问答的技术角度出发,基于方法使用的核心技术,以规则模板与深度学习技术为分类依据,对现有各类开放领域知识图谱问答方法进行全面而深入的综述。

(2)概述用于开放领域知识图谱问答的主要资源,包括通用领域知识图谱及开放领域问答数据集。

(3)以3个经典问答数据集为基线,评测不同方法的实验效果并进行分析。

(4)总结开放领域知识图谱问答的多种挑战,指出未来的研究方向。

1 预备知识

知识图谱:目前没有一个统一的严格定义。知识图谱主要有以下4种类型:资源描述框架(resource description framework, RDF)图、属性图、异构信息网络和有向标签图^[44]。这里以KGQA最常用的知识图谱Freebase为例(RDF图)进行定义,如图3所示,给出一个KG实例,其中圆角矩形表示实体e,有向边表示谓语p。

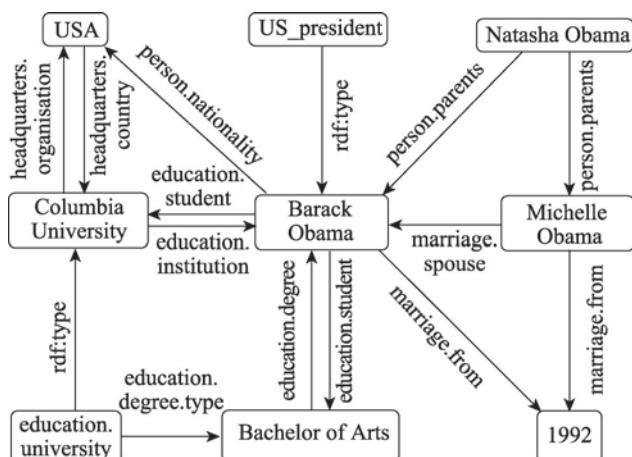


Fig.3 Example of knowledge graph
图3 知识图谱示例

定义1(知识图谱) 令 E 为实体集合, P 为谓词集合。知识图谱 G 是事实三元组 $(s, p, o) \in E \times P \times E$ 的有限集合,其中 s 是主语, p 是谓语, o 是宾语。

知识图谱问答:由于不同方法使用的训练数据、元素定义及实现的功能不同,知识图谱问答没有统一的严格定义。根据知识图谱问答系统获得答案的

不同方式,知识图谱问答主要有语义解析和信息检索两种解决方法,两者对应不同的知识图谱问答定义,与知识图谱问答的关系如图4所示。可以看出,语义解析与信息检索细化了知识图谱问答的流程,在获得正确答案集 A 前分别增加了查询语句及候选答案部分,这也是两类方法的区别所在。开放领域知识图谱问答,则是知识图谱 G 为通用领域知识图谱,问题 q 为开放领域问题的知识图谱问答情况。

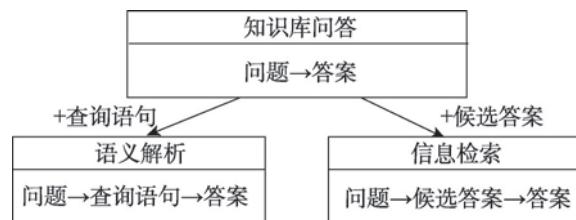


Fig.4 Two methods of knowledge graph question answering

图4 知识图谱问答的两种方法

定义2(知识图谱问答) 给定知识图谱 G ,自然语言问题 q ,返回正确答案集 A ,其中 A 为 E 的子集。

语义解析(semantic parsing, SP):得到查询语句或查询语句的逻辑形式,在KG上执行所得结果间接获得正确答案集。查询语句常用SPARQL查询语言,表达逻辑形式的逻辑语言常用 λ -DCS(λ dependency-based compositional semantic)^[45]和 λ -calculus^[46]。

定义3(语义解析) 给定知识图谱 G ,自然语言问题 q ,将 q 映射为可在 G 上执行并返回正确答案集 A 的查询语句 y 或查询语句的逻辑形式 z 。

信息检索(information retrieval, IR):获得问题相关的候选答案集,通过排序获得正确答案集。

定义4(信息检索) 给定知识图谱 G ,自然语言问题 q ,在 G 中检索与问题 q 所含主题实体(topic entity) e 的在数跳(hop)关系内的实体集作为候选答案集 A' ,通过排序获得最终正确答案集 A 。

图5给出两种方法的示例,对于相同的问题“Who is Obama’s wife?”,图中的上下两部分,分别对应语义解析和信息检索两种方法的回答流程,语义解析将问题映射为SPARQL查询语句并检索KG获得最终答案;信息检索将问题所含主题实体Barack Obama在KG中的邻近实体作为候选答案集,并根据特征或相似度排序获得最终答案集。

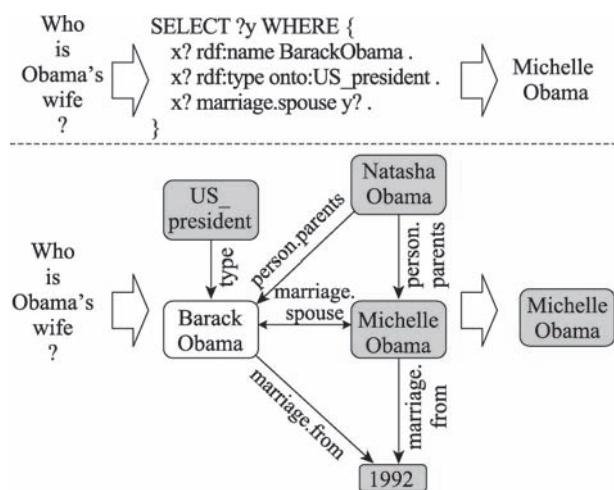


Fig.5 Example of comparison between semantic parsing and information retrieval methods

图5 语义解析与信息检索两种方法对比示例

表1给出KGQA方法中的一些常用符号。

Table 1 Notation used in this paper

表1 常用符号

符号	描述
G	知识图谱
(s, p, o)	一个事实三元组,即(主语,谓语,宾语)
E	实体集合
P	谓词集合
e	E 的一个实体
q	自然语言问题
L	词汇表
w	自然语言短语
y	查询语句
z	逻辑形式
A'	候选答案集合
A	正确答案集合

2 基于规则模板的方法

无需人工定义特征的深度学习方法在KGQA领域得到广泛应用之前,KGQA主要依赖各类人工定义的规则、特征和模板回答问题。这些方法实现性能提升主要依靠传统语言学及人工经验,而非深度学习模型自行抽取的高维特征。

开放领域问题集从技术角度出发,可分别根据解答问题所需跳数与模型训练监督方法的不同,将数据集分为简单问题数据集(答案仅涉及单个三元组)与复杂问题数据集(答案涉及多个三元组,即复

杂多跳问题;涉及多个限制条件,即复杂多限制问题),逻辑形式数据集(监督学习方法)与问答对形式数据集(远程监督学习方法)。基于模板规则的工作主要集中在简单问题数据集的处理上。

2.1 传统语义解析

传统语义解析是一种将NLP领域的语义解析应用于KGQA问题翻译的方法,主要基于词汇表映射完成对KG信息的利用,可通过系统生成的查询语句或逻辑形式解释系统的答案来源,可解释性较高。传统语义解析共有直接映射和复述(paraphrase)两种方法。直接映射方法由结构表示、词汇映射和消歧排序3个步骤组成,将问题直接映射为逻辑形式;复述方法使用人工定义的规则,将自然语言问题改写为中间形式,然后基于中间形式的各类特征进行打分排序,将最佳中间形式对应的逻辑形式作为输出。

2.1.1 直接映射

直接映射方法采用语义解析常用的语法工具完成结构表示,如组合范畴语法(combinatory categorial grammar,CCG),并使用语法工具附带的词汇表完成短语—实体/关系的映射,产生多种逻辑形式,通过排序选出最佳逻辑形式作为结果。

最初,直接映射的传统语义解析^[47-48]作为NLP领域的传统方法,用于将自然语言转换为某种逻辑语言的表达形式。Berant等人^[17]将直接映射的传统语义解析融入KGQA作为解决方法,解决了两个主要问题:训练语义解析器需要人工标记的逻辑形式数据作为监督和词汇表覆盖面窄的问题,并提出了著名的WebQuestions^[17]数据集基线。

该KGQA系统分为两个阶段:构造逻辑形式和打分。

(1)构造逻辑形式阶段。生成问题可能构成的所有逻辑形式。构造逻辑形式阶段可细分为谓词产生与谓词组合两个子任务。

①谓词产生子任务。将问题短语通过词汇表或桥接组合规则转换为对应Freebase谓词。词汇表 L 的形式如图6所示,其中 w 为自然语言短语,通过词汇表 $L(w)$ 映射得到一组条目 (z, s) , z 为短语对应谓词, s 为谓词 z 的一组特征值,用于模型排序使用。

②谓词组合子任务。使用人工定义的4类组合规则——连接、交集、聚合与桥接,将谓词随机组合,生成所有可能的逻辑形式。使用交集+连接组合规则、桥接组合规则所得的逻辑形式如图7所示。

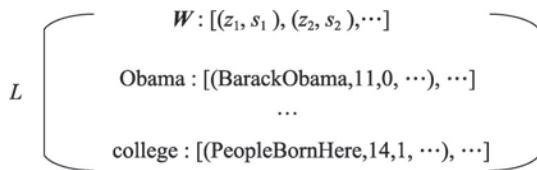


Fig.6 Lexicon

图6 词汇表

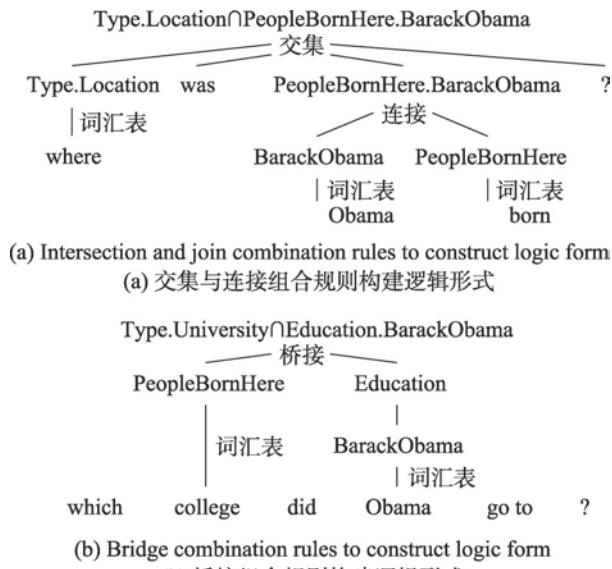


Fig.7 Logic form

图7 逻辑形式

(2) 打分阶段。根据逻辑形式各类人工特征,诸如规则应用总数、连接与桥接过程中的跳过词(skipped work)POS(part-of-speech)标记、逻辑形式的长度等,使用对数线性模型对逻辑形式进行打分排序,得到正确的逻辑形式用于检索Freebase获得答案。特征权重通过模型训练学习得到,训练数据使用问答对数据集,目标是最大化正确答案的对数概率。

后来对直接映射方法的研究可细分至直接映射流水线的不同环节。

词汇映射+消歧排序环节。DEANNA系统^[49]与Yahya等人^[50]着重研究短语映射环节的消歧工作。前者采用整数线性规划(integer linear programming, ILP)模型,提升效果不明显;后者为三元组增加文本描述内容 X 形成四元组 (S, P, O, X) ,并利用 X 信息进行短语消歧。该方法修改元组结构,采用此思路的方法较少。

仅词汇表映射环节。AGENDAIL系统^[51]将模仿学习结合进语义解析器的训练过程中,使得所生成逻辑形式减少一个数量级,在保持精度的同时提高

运行速度;Reddy等人^[52]将结构表示的依存解析树先转换为其二值表示形式s-expression,后转换为 λ -calculus表达式;UDepLambda系统^[53]以Reddy等人的系统为基础,将s-expression替换为通用依赖树库(universal dependencies, UD),实现跨语言解析性能。

2.1.2 复述

复述方法采用各类人工模板或规则,将问题改写为中间形式打分得到最优改写。

PARASEMPRE系统流程图如图8所示,其中粗线和细线分别表示正确与错误的答案生成路线。PARASEMPRE系统^[23]使用5个人工定义模板将问题转换为逻辑形式 z ,后使用预先定义好的规则和词汇表将每个逻辑形式 z 转换为一组自然语言 c ,后使用联合模型与向量空间模型作为复述模型对自然语言-逻辑形式元组 (c, z) 打分,使用得分最高元组的逻辑形式 z 检索KG获得答案。



Fig.8 Workflow of PARASEMPRE system

图8 PARASEMPRE系统流程图

OQA系统^[54]使用预先定义的操作符与模板,将用户问题提炼为语法正确、用词准确的标准问题,并将该标准问题转换为相应结构的SPARQL查询,后将该查询语句中的词语重新改写为KG中存在的相似实体关系名并进行打分排序。该系统可使得问题更标准,SPARQL查询更贴近KG内容,但该方法使用的操作符与模板需线下构建,如KG或问题集变动,则无法实现在线动态更新。

2.2 传统信息检索

传统信息检索以信息抽取的视角重新构思解决KGQA的方案,通过提取问题主题实体的KG子图,从中抽取出与主题实体数跳内的相关节点作为候选答案集,通过提取问题和答案等信息的人工特征,作

为答案排序依据以获得最优答案。该方法与传统语义解析方法无直接关联,但传统语义解析受到该方法的启发,对技术演变方向产生重大影响。通过指定的查询语句模板完成自然语言到查询语句的转换,对KG信息的利用主要基于词汇表映射,但可解释性较低,答案节点主要通过结合权重的人工特征进行提取。

该方法最初通过JACANA系统^[20]实现,依次得到问题特征与答案特征来获得答案。

(1)问题特征。对问题执行依存分析,将分析结果转化为问题图(question graph)。问题图共有问题词(qword)、问题焦点(qfocus)、问题动词(qverb)和问题主题(qtopic)4个特征^[20],其中问题主题即主题实体,用于寻找相关Freebase网页页面以构成该系统主题图(topic graph)。以问题“What is the name of Justin Bieber brother?”为例,该问题对应的问题图如图9所示,每个圆角矩形代表一个单词,单词特征通过等号对应标记,其中justin和bieber为问题主题。

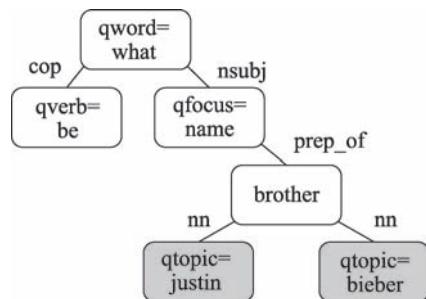


Fig.9 Question graph generated by Freebase

图9 Freebase生成的问题图

(2)答案特征。在Freebase内检索问题图中主题实体数跳内的所有节点,包括实体、属性两类节点,形成主题图。其中,一个重要的特征是关系与问题的相关度,该特征值通过检索人工收集Reverb谓词与Freebase关系的映射所得的关系表ReverbMapping获得;其次,将属性和带方向的关系也作为各节点的特征类型。(1)中举例的问题所得主题图如图10所示,主题实体为Justin Bieber,圆角矩形代表实体,矩形代表属性,有向边代表关系。

获得问题图、主题图特征后,将问题图所有特征与主题图中每个节点的特征成对连接形成特征集,捕获问题与答案节点的关联信息。使用L1正则化逻辑回归模型对主题图中的每个节点进行二分类,提

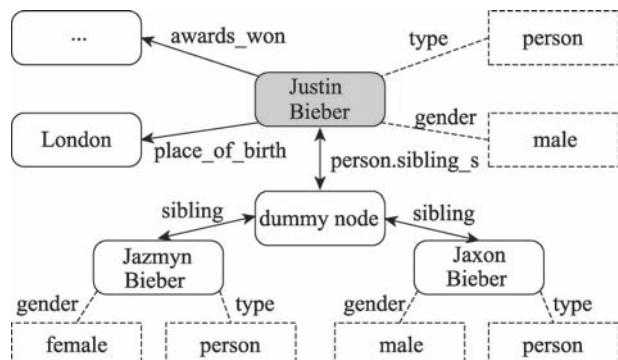


Fig.10 Topic graph generated by dependency parsing

图10 依存分析生成的主题图

取答案节点。

因KG为KGQA的信息源,该方法通过聚焦在可能性较高的节点,减小搜索空间,提高问答效果。该思想对KGQA方法的发展具有深远影响。

2.3 三元组匹配

三元组匹配方法最初由AquaLog^[55-56]、FREyA^[57]为代表的早期RDF问答系统^[58-59]提出,将自然语言问题映射为三元组表示,后通过相似性度量从RDF数据检索相似三元组得到答案。现经过转变,分别形成以问题拆分和问题复述为首要环节的两类流水线方法,并应用于开放领域知识图谱问答。但三元组匹配方法在简单问题上的效果并不理想,在Web-Questions基线上的最高精确度指标没有超过37.5%,通过人工指定的多个查询语句模板完成自然语言问题到查询语句的转换,而对KG信息的利用仅通过人为定义的模板及表达式进行实体关系匹配。三元组匹配方法可通过三元组形式解释系统的答案来源,采用该方法的系统较少,未形成大规模应用。

2.3.1 问题拆分+翻译+三元组排序流水线

Bao等人^[22]以问题拆分为首要环节,将三元组匹配方法细化为3个步骤:问题拆分、翻译和三元组排序。

(1)问题拆分环节。使用图11的4类依存解析树模板完成问题拆分,通过子问题答案取交集作为最终答案。

(2)翻译环节。将步骤(1)所得子问题或原问题使用图12所示的CYK(Cocke-Younger-Kasami)算法^[60],结合人工给定的4 764个问题模式模板与133 445个关系字符串表达式,按照跨度(span)由小至大的顺序,将自然语言问题翻译为对应跨度对应的答案三元组。

(3)三元组排序环节。根据特征,将步骤(2)所

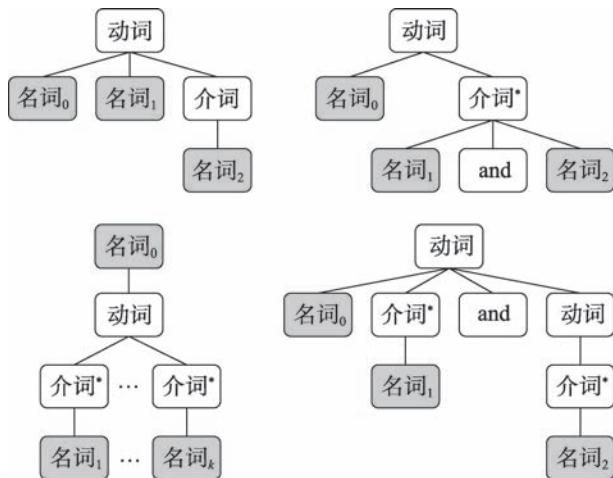


Fig.11 Dependency parsing tree template

图 11 依存解析树模板

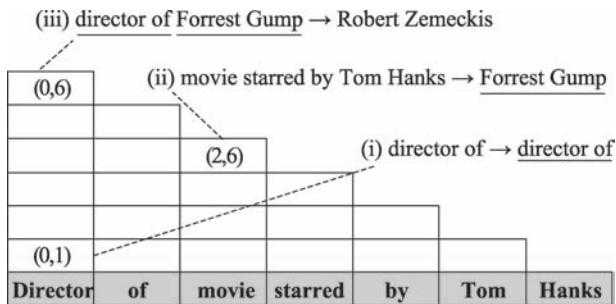


Fig.12 CYK translation process

图 12 CYK 翻译过程

得的 KG 三元组进行排序。使用的特征包括:答案包含原问题的单词个数、问题包含的疑问词数量、三元组转换成功的跨度个数、翻译所得的三元组总个数等。将上述特征结合最小错误率训练算法(minimum error rate training, MERT)^[61]调节特征权重训练模型。

2.3.2 问题复述+翻译+三元组排序流水线

TAQA 系统^[62]以问题复述为首要环节,将第一类方法的环节(1)改为问题复述环节。使用人工预定义模板对自然语言问题进行改写,表述为与 KG 三元组具有相似词汇、语法结构的多个新问题。目的是解决用户的口语词汇及表达方式给系统带来的解析匹配困难。

2.4 话语模板

传统语义解析方法同时考虑词汇、结构信息,并完成词汇映射工作,而本节话语模板则先构造语义结构的中间形式,后将词汇形式映射结果嵌入语义结构中。

该方法核心思想在于问题与逻辑形式间建立一个如图 13 所示的表示问题语义结构的中间形式,之后使用 KG 数据实例化该中间形式,得到对应的逻辑查询。中间形式可分为语义结构模板与查询图两种。传统语义解析复述方法的中间形式为同时包含语义结构与词汇映射的完整结构,而本节的中间形式则单纯为语义结构。

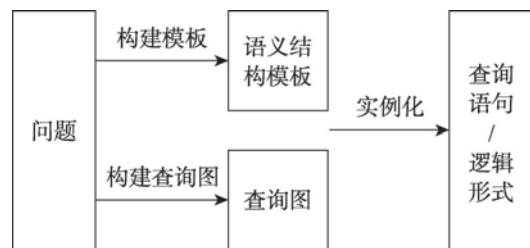


Fig.13 Two forms of utterance-query template

图 13 话语模板的两种形式

2.4.1 语义结构模板

语义结构模板使用包含占位符的 SPARQL 模板或包含变量的领域独立逻辑形式,表示问题语义结构,并分别使用 KG 数据实例化占位符或变量直接得到检索答案的查询语句或逻辑形式。

Kwiatkowski 等人^[18]实现领域独立逻辑形式的语义结构模板,如图 14 所示。自然语言问题首先使用 CCG 与 Wiktionary 的词信息构建包含变量的领域独立逻辑形式,以密切反映句子结构,之后使用本体常量将变量映射到最终的逻辑形式,最后使用手工指定的算法计算线性模型参数,排序生成最终逻辑形

自然语言问题

What works did Mozart dedicate to Joseph Haydn?

领域独立逻辑形式

$\lambda x.eq(x, count(\lambda y.people(y) \wedge \exists e.visit(y, z.public(z) \wedge library(z) \wedge of(z, new_{york}), e) \wedge annually(e)))$

最终逻辑形式

$\lambda x.library.public_library_system.annual_visit(x, new_york_public_library)$

答案

13 554 002

Fig.14 Transformation process of domain-independent logical form

图 14 领域独立逻辑形式转换流程

式并检索 KG 获得答案。

2.4.2 查询图

语义结构模板方法受传统信息检索方法的启发,转向以查询图为中间形式,系统性能得到提升。

查询图使用无根据图(ungrounded graph)表示问题语义结构,实例化后的图结构称为有根据图(grounded graph)或语义查询图(semantic query graph),将语义查询图转换为逻辑形式。

GRAPHPARSER 系统^[26]率先引入查询图方法,如图 15 所示。以问题“What is the capital of Texas?”为例,系统获得问题后使用CCG 解析工具中的 C&C 解析器^[63]获得问题结构;根据解析结果,各词汇的 POS 标签及词间关系,依据人工规则转换为表示问题结构的无根据图,该图与 Freebase 不产生直接映射关系;之后再将无根据图的边与节点映射至所有可能的 Freebase 关系与实体,得到语义查询图,此类多为一对多映射,故将产生多种语义查询图;最后利用模型从问题、无根据图、语义查询图和 KG 中抽取特征进行排序,将得分最高的语义查询图转换为逻辑查询表达式,检索 KG 获得答案,由此将语义解析问题变为图匹配问题。

之后,Zou 等人^[64]通过依存树而非 CCG 创建查询图,获得更优的结构表示;SINA^[65]通过问题关键字与 KG 节点标签的字符串匹配获得资源并构建查询图完成消歧任务,性能相对于 GRAPHPARSER 系统没有显著提升;Zheng 等人^[66]通过计算查询图与 SPARQL 查询的图编辑距离计算相似性,自动生成话语模板,但 KG 与问题数据集变动时系统无法动态更新的问题依旧没有得到解决。

2.5 查询模板

查询模板方法是话语模板工作的简化,模板的选择不由问题的话语结构决定,而是所有模板都尝试进行匹配,对 KG 信息的利用主要基于词汇表映射,所得结果即为查询语句,可解释性较高。使用预先定义的高通用性查询模板,填充实体、关系占位符以获得查询语句,检索 KG 获得答案。模板匹配流水线由实体链接、模板匹配和关系匹配 3 个环节组成。

2.5.1 模板匹配流水线+候选排序

Aqqu 系统^[25]率先使用模板匹配流水线+候选排序完成 KGQA。

(1) 实体链接环节。获得问题词语可匹配的所有 KG 实体及其置信度(在判断是否匹配的二分类任

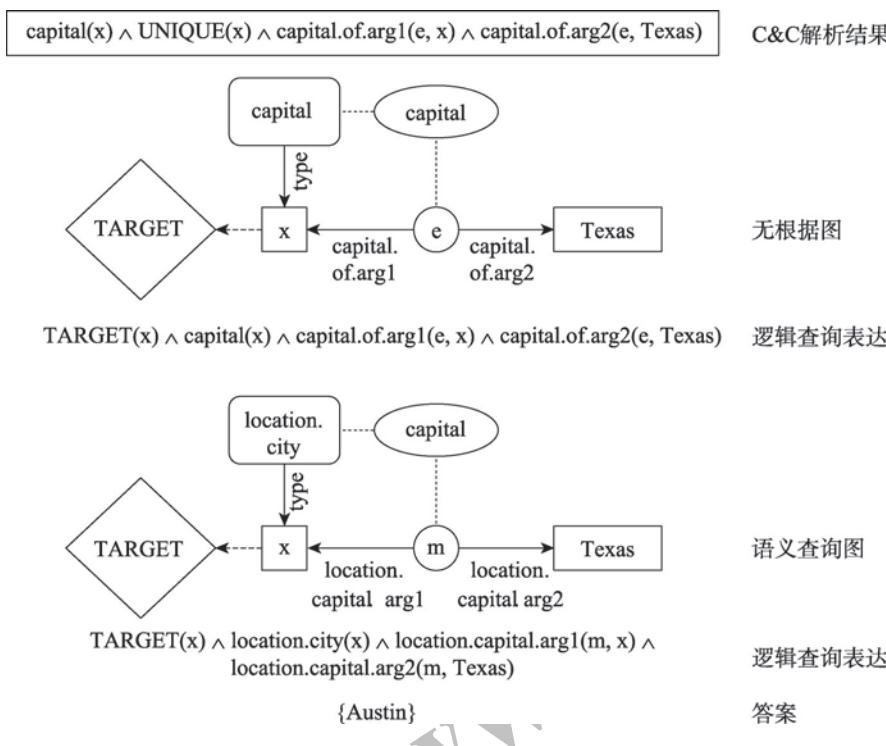


Fig.15 Question answering process of query graph method

图 15 查询图方法问答流程

务中类别为 true 的概率值)打分, 打分通过 CrossWikis 数据集提供的实体别名概率分布值获得。

(2) 模板匹配环节。令所得候选实体集充分填充图 16 中 3 类模板的实体占位符 e_i 。模板涵盖单实体一跳、单实体二跳和二实体二跳三种情况。

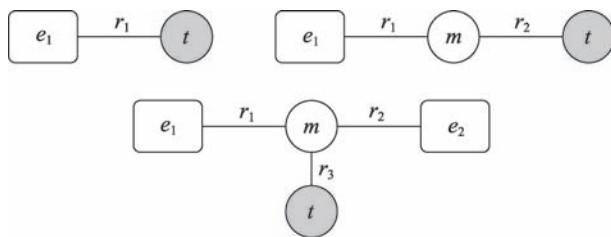


Fig.16 Query statement template

图 16 查询语句模板

(3) 关系匹配环节。根据模板的关系数, 检索 KG 对应实体的所有关系, 以填充模板关系占位符 r_i 。

(4) 候选排序环节。对环节(3)得到的候选查询集进一步提取字面匹配值、派生匹配值、同义词匹配

值和上下文匹配值 4 类模板特征值, 结合环节(1)的实体置信度等特征, 一并输入随机森林, 选出最优模板进行检索。

2.5.2 模板匹配流水线+候选排序+外部知识

Text2KB 系统^[67]受 Aqqu 及结合外部知识思想的启发, 将 Aqqu 各步骤改写为结合外部文本信息的方法以提升性能, 即利用搜索引擎所得结果增强实体链接环节的性能; 通过挖掘 CQA (community question answering) 数据来改进关系匹配环节的性能表现; 通过加入文本语料库统计值来优化候选查询的排名效果。

由于一跳、二跳查询基本可覆盖简单问题和部分复杂问题, 使得该方法评测效果处于规则模板所有方法前列, 但对于含有丰富语义限制的复杂问题效果依旧不佳^[67]。

表 2 给出了基于规则模板方法的小结。3 类语义解析方法皆具有良好的可解释性。前 3 类方法仅对简单问题具有较好的处理能力, 涉及复杂多跳问题,

Table 2 Summary of rule template based methods

表 2 基于规则模板的方法小结

类型	优点	缺点	方法	文献	描述
传统语义解析	所得的逻辑形式可执行于 KG, 对所得答案具有充分的可解释性	词汇表基于简单的统计方式构建, 对训练数据具有较大的依赖性	直接映射	[17,49-53,68-70]	使用语法规则及词汇表完成谓词映射, 以高召回率生成逻辑形式用于排序
	聚焦与问题相关的 KG 内容, 大幅减小搜索空间	对复杂多关系问题缺乏表示能力	复述	[23,54]	使用模板或规则将问题改写为中间形式, 提取特征作为评判依据
传统信息检索	简单问题的语义匹配度较好	语义复杂的问题无法使用三元组如实捕获原始语义	问题特征+答案特征	[20,71]	问题转换为问题图获得特征, 主题实体提取主题图获得答案特征, 两者特征依次结合作为答案选择依据
三元组匹配	反映问题语义结构, 紧密结合 KG 信息	对复杂多限制问题的表示能力有限	问题拆分+翻译+三元组排序流水线	[22]	依赖树模板拆分子问题, 结合问题模式模板和关系表达式字典构造三元组, 使用人工特征排序
			问题复述+翻译+三元组排序流水线	[62]	复述模板改写问题, 依赖树规则构造三元组, 使用人工特征排序
话语模板	模板充分对应简单问题与多关系复杂问题查询模式	对复杂多限制问题的语义捕获能力较差	语义结构模板	[18,34,72-74]	以 SPARQL 或领域独立逻辑形式为模板形式表示语义结构, 利用 KG 数据实例化模板
			查询图	[26,64-66]	以无根据图为语义结构表示形式, 利用 KG 数据实例化得到语义查询图, 转换得到逻辑形式
查询模板			模板匹配流水线+候选排序	[25]	使用流水线提高生成的候选查询召回率, 通过实体、关系、查询特征筛选查
			模板匹配流水线+候选排序+外部知识	[67]	实体、关系流水线结合外部知识提升性能

后2类方法效果较好。传统语义解析依赖人工指定的词汇表,短语映射结果的好坏与数据的质量密切相关;话语模板方法受到传统信息检索方法的启发而产生,确立缩小搜索空间的重要性;三元组匹配方法对复杂问题的处理能力由问题分解的好坏决定;话语模板综合能力最强,对于复杂问题同样具有解决能力;查询模板则对人工设定的模板通用性要求较高。

基于规则模板方法所含的人工干预较多,导致系统通用性差,无法方便扩展至其他本体或拥有更广泛词汇的新KG上。但基于规则模板的方法有较强的可解释性,部分方法的评测结果同样优于其他基于深度学习方法的基线指标。

3 基于深度学习的方法

随着深度学习不断发展,各类基于深度学习的KGQA方法逐渐被提出和发展。初期阶段,在排序环节会采用基于规则或模板的方法进行实现,之后则由深度学习方法所取代。基于深度学习的方法通过神经网络模型抽取问题特征完成问答任务,对KG信息的利用率较高,主要通过监督和远程监督的方式完成对KG的学习。知识图谱嵌入及记忆网络的可解释性较差,基于神经网络的语义解析、查询图、信息检索方法可通过问答流程子环节所得的中间结果推断答案的来由,具有一定的可解释性,可获得比知识图谱嵌入和记忆网络方法更高的性能表现。

3.1 知识图谱嵌入

知识图谱嵌入方法作为最基础的深度学习方法,无需使用规则、词汇表、语法工具等额外内容,直接将问题映射为向量特征表示,将候选答案映射到相同向量空间进行相似度比较,获得最终答案。知识图谱嵌入方法常作为其他神经网络模型组成环节的一部分。

最基本的知识图谱嵌入方法TransE由Bordes等人^[75]首次提出。TransE的改进版本^[19]将问题答案路径及周围子图编码为嵌入向量。如图17所示,问题与答案皆用 $\mathbf{R}^{k \times N}$ 的矩阵 \mathbf{W} 表示,其中 k 为预先指定的嵌入空间维度。

候选答案的得分通过问题表示 $f(q)$ 与候选答案表示 $g(a)$ 的点积获得,训练目标是使正确答案的得分最高。

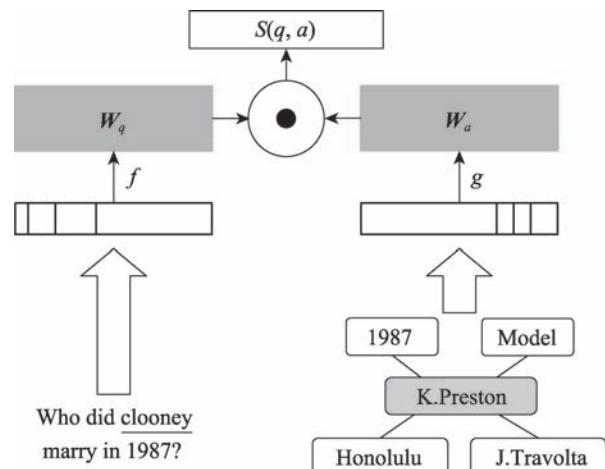


Fig.17 Working process of improved TransE

图17 TransE改进版本工作流程

由于KG信息量巨大,EmbedKGQA系统^[42]借鉴PullNet算法^[41],针对文献[75]候选答案集合进行缩减的需求,提出一种简单的缩减方法,并实现利用知识图谱嵌入解决复杂多跳问题的功能,效果提升明显。

VRN^[33]、IRN^[76]与EmQL^[77]系统将知识图谱嵌入完成知识图谱补全的方法应用至KGQA。其中,EmQL首次将KG实体与查询语句同时嵌入相同空间,提高系统在不完整KG中的推理问答能力。

3.2 记忆网络

本节方法基于知识图谱嵌入方法叠加记忆组件来实现。

为了让模型能够具有像人类一样的记忆机制,人们创造了诸如记忆网络(memory network)和循环神经网络(recurrent neural networks, RNN)特殊变体的长短时记忆模型(long short-term memory, LSTM),其中记忆网络模型类似于计算机外存,能够长期存取大量信息。该框架率先由Weston等人^[78]提出并命名为MemNN——以可读写记忆组件为核心的学习系统,通过将KG的所有内容嵌入至向量空间来确定系统输入输出的自然语言与KG查询语言间的关系。

MemNNs系统^[24]则将MemNN记忆网络框架应用于开放领域知识图谱问答,并提出了重要的简单问题数据集SimpleQuestions^[24]。

MemNNs系统通过图18中的记忆(M)、输入(I)、输出(O)、响应(R)、泛化(G)共5个模块的组合完成架构。记忆模块M用于存储KG三元组,并被剩

余4个模块读写;输入模块I用于预处理外部输入,包括KG三元组及自然语言问题的预处理;输出模块O用于在M中选择与I的输出最相关的记忆,并对所得候选记忆进行打分排序;响应模块R用于将O提供的记忆以对应格式输出最终结果;泛化模块G用于导入外部知识更新记忆模块M的内容。整体工作流程如图18所示。

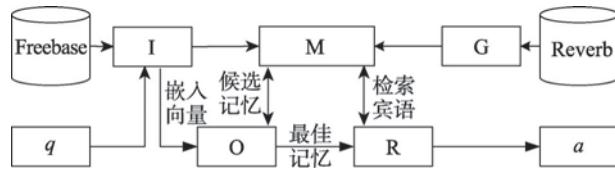


Fig.18 Workflow of MemNNs framework

图18 MemNNs框架流程图

Jain等人^[79]以MemNNs为基础,在KG预处理环节舍去合并相同主谓三元组的过程,但使用词袋结合位置编码的方法表示问题 q ,在WebQuestions数据集上获得了更优的效果;Xu等人^[39]以KV-MemNN为基础,通过引入STOP策略,设计一种新式查询更新策略,屏蔽已寻址的内存信息,使得KV-MemNN能够处理复杂问题。

3.3 基于神经网络的语义解析

本节方法使用神经网络模块对传统语义解析、话语模板的查询图、传统信息检索方法的各环节进行提升。除本节程序归纳子方法用于处理复杂问题外,其他子方法皆用于简单问题的处理。

3.3.1 神经网络+知识图谱嵌入

对于简单问题的词汇映射部分,主要通过使用神经网络模块替换传统方法的词汇表完成性能升级。Golub等人^[80]的方法如图19所示,根据实体提及召回的候选实体结果,将流行度最高的10个候选实体作为候选实体集 E ,接着检索候选实体集 E 在KG中的所有一跳关系作为候选关系集 P 。将问题 q 的独热向量输入LSTM获得问题编码,候选实体集 E 、候选关系集 P 作为输入,系统分别从 E 、 P 集合选取最优实体、关系作为输出,并分别使用一个CNN网络以字符为单位进行编码,获得固定长度的向量表示;然后使用注意力机制解码与问题最相关的实体与关系,通过语义相似度函数计算解码器所得实体向量与候选实体对应向量的余弦相似度,选出相似度乘积最大的 e 、 p 作为输出,用于填充逻辑查询语句的

实体关系占位符。ISS-NR系统^[81]则通过神经推理预训练模型和GCN分别获得事实三元组和问题对应KG子图的嵌入,同时判断事实三元组的实体关系与问题对应KG子图的相似度。

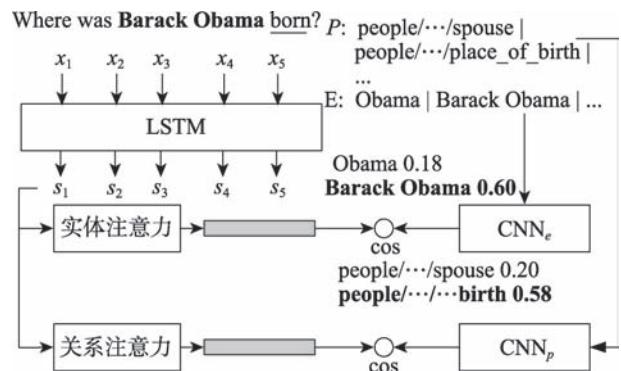


Fig.19 Neural network models to complete lexical mapping

图19 神经网络模型完成词汇映射工作

3.3.2 神经网络+候选排序

提升简单问题的排序打分工作,主要通过神经网络模型替换传统方法的统计学习模型来完成。Yavuz等人^[82]对传统语义解析系统AGENDAIL进行改进,使用BiLSTM(bi-directional long short-term memory)模型对实体前后内容进行向量表示并用于预测实体的正确类型,排序部分则以实体类型相似度打分作为重要特征。

3.3.3 神经网络+复述+候选排序

对于简单问题的排序部分,复述方法同样有所涉及。Dong等人^[83]先对问题生成多个改写 q' ,对所得改写使用BiLSTM模型得到向量表示,获得改写问题与原问题的相似度打分 $P(q'|q)$,后使用另一个BiLSTM模型编码答案 a ,获得答案与改写问题的相似度打分 $P(a|q')$,最终答案的打分 $P(a|q)$ 通过 $P(a|q') \cdot P(q'|q)$ 计算。

3.3.4 程序归纳

对于复杂多关系问题部分,诸如SSRP^[84]、CIPITR^[85]、MRL-CQA^[86]、NS-CQA^[87]等系统,将问题转换为可在KG上执行并获得答案的程序序列,而非语义解析的逻辑形式。

3.3.5 神经网络模块组合

本类方法也有诸如Andreas等人^[31]的特殊实现。该工作针对不同的问题,组合神经网络子模块,对应

形成特定的神经网络模型, 用于获得问题的答案, 常规对多个候选逻辑形式的排序, 转换为对多种不同组合模型的排序。

3.4 基于神经网络的查询图

回顾查询图方法, 其关键步骤在于无根据图到语义查询图的实例化转换, 排序多个语义查询图并转换最优语义查询图为逻辑形式得到结果。基于神经网络的方法在上述实例化转换和排序环节均有涉及。

3.4.1 神经网络+答案特征

针对无根据图到语义查询图的映射环节, 最先由 STAGG 系统^[27]使用 CNN 模型完成关系映射; STF 系统^[88]与 STAGG 系统的不同在于使用 MCCNN 完成关系映射, 实验证明 MCCNN 比 CNN 更适合关系的特征抽取。

3.4.2 神经网络+问题特征+图特征

针对语义查询图的排序环节, Bao 等人^[89]使用 CNN 对问题和语义查询图进行编码并完成相似度分析; Luo 等人^[90]使用 BiGRU(bi-directional gate recurrent unit)完成上述工作; Maheshwari 等人^[40]使用自注意力的槽位匹配方法进行排序。

GGNN(gate graph neural networks)系统^[36]使用与 STAGG 完全相同的图生成框架, 但在 STAGG 基础上使用 CNN 与 GGNN 分别对问题和语义查询图进行向量化, 使用所得两向量乘积代表的相似度打分作为排序依据。

以问题“What was the first Taylor Swift album?”为例, 如图 20 所示, CNN 将问题映射到长度固定为 d_w 的向量表示。在问题序列首尾加入特殊开始和结尾标记 $< s >$ 和 $< f >$, 使用 $|L_w| \times d_w$ 矩阵 W 将问题序列转换为嵌入向量, 其中 L_w 为词汇表, 以后各词嵌入向量输入双层 CNN+Pooling 层, 连接全连接层 H 得到最终表示向量 v_q 。

GGNN 如图 21 所示抽取图中各节点与边的类型标签, 将它们切分为字符序列, 并使用矩阵 W 获得标签的词向量表示 h_l 。

之后使用矩阵 $A \in \mathbb{R}^{|V| \times 2|V|}$ 与 $A' \in \mathbb{R}^{|V| \times 2|R|}$ 表示图信息, 其中 V 为节点集合, R 为关系集合, A 表示节点间的连接信息, A' 表示边的方向类型信息。获得这些信息后, 首先将每个节点和边的向量表示求和, 然

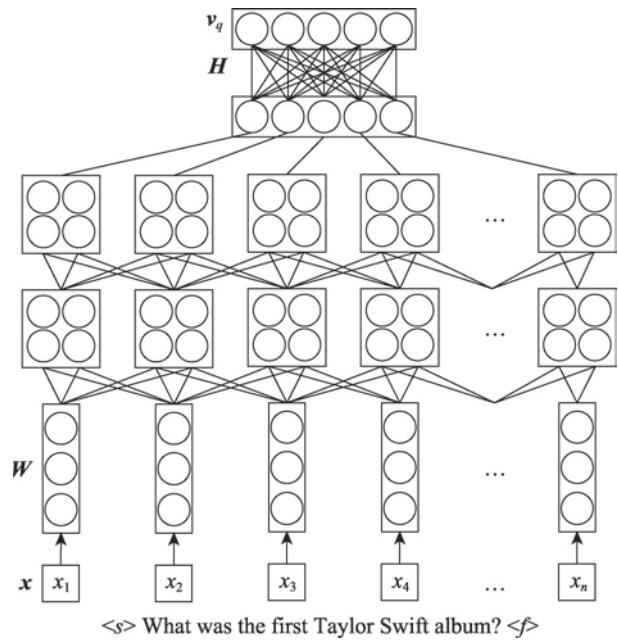


Fig.20 Mapping structure of CNN

图 20 CNN 映射结构

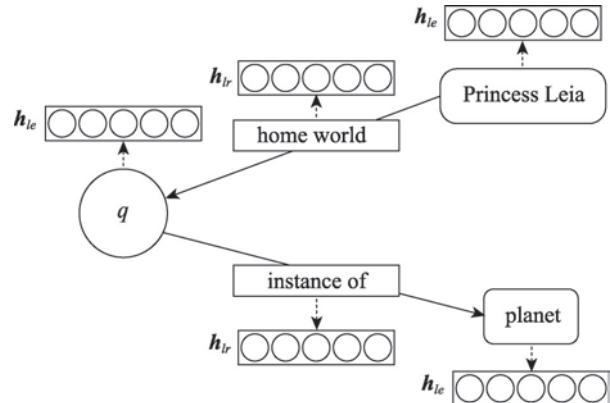


Fig.21 Representation of label vector

图 21 标签词向量表示

后使用非线性变换, 迭代得到图中代表答案的变量节点向量表示, 将结果输入全连接层及线性整流函数(rectified linear unit, ReLU), 获得答案节点的最终向量表示 v_g 。

在获得答案节点向量表示 v_g 与问题向量表示 v_q 后, 通过余弦相似度分析得到最优语义查询图, 并转换为相应的查询语句。

Xu 等人^[91]在编码端进行改进, 同时结合问题的词序、依存句法以及成分句法的分析结果作为输入, 对问题进行编码并获得性能提升。

3.4.3 剪枝+集束搜索

此方法为一类特殊的实现。Lan 等人^[43]通过控制查询图的生成过程处理复杂多约束、多关系问题。对于单关系多约束问题,在查询图生成阶段,每获得一个约束就对应进行图剪枝操作;对于复杂多关系问题,则使用集束搜索在扩展关系时仅考虑最佳关系而非全部关系,进而减少搜索空间。

3.5 基于神经网络的信息检索

该类方法主要使用神经网络模型完成候选答案排序和关系匹配,或使用外部知识完成候选答案排序。

3.5.1 神经网络+候选排序

传统信息检索方法的核心要点是检索主题实体在 KG 上的相邻实体作为候选答案,通过排序获得最终答案。

本小节所述系统使用神经网络模型提升排序环节的性能。其中 MCCNNs 系统^[92]使用 MCCNN 卷积得到问题答案路径、类型、上下文 3 类特征,并学习候选答案的嵌入向量表示,将两者同时作为评分函数的输入获得相似度评分;Hao 等人^[93]使用交叉注意力机制表示问题与候选答案。实验结果显示交叉注意力机制的效果优于 MCCNN。

3.5.2 神经网络+关系匹配

神经网络模型同样可用于传统信息检索中的关系匹配环节。

Yu 等人^[35]将关系名以关系名本身与组成关系的单词两级表示,使用 BiLSTM 进行编码并排序。

本小节模型较为多样,模型呈现出复杂度递增的趋势。Mohammed 等人^[94]评测深度学习与传统方法的效果差异,探寻深度学习对 KGQA 的有效贡献,关注简单问题的回答,将问题处理环节分解为实体检测、实体链接、关系预测与特征组合 4 步。

接着使用 SimpleQuestions 数据集对各子环节及系统整体组合效果进行评测。整体流程如图 22 所示。实体检测环节,BiLSTM 与条件随机场(conditional random fields, CRF) 分别实现 93.1% 与 90.2% 的 F1 值;结合实体链接方法后,两者整体 R@1 分别为 67.8% 与 66.6%;关系预测环节,BiGRU、CNN 与逻辑回归(logical regression, LR) 的 R@1 分别为 82.3%、82.8% 和 74.7%;系统整体的预测准确率中,BiLSTM+BiGRU 的表现最好,为 74.9%,CRF+BiGRU 的表现次之,为 73.7%,而 CRF+LR 的准确率为 69.9%。

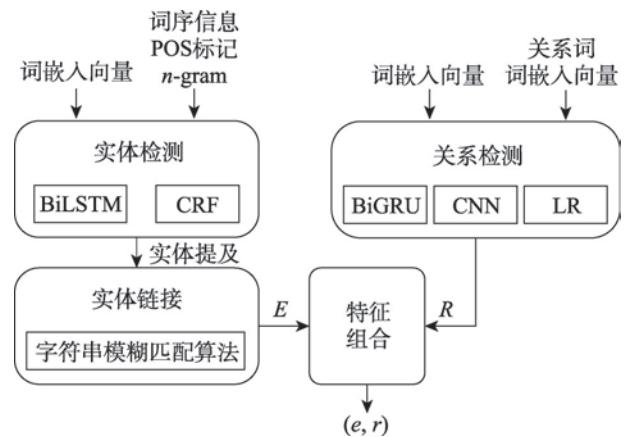


Fig.22 Evaluation flow

图 22 评测流程

由上可知,对于简单问题的 KGQA 而言,传统规则模板方法有能力取得与深度学习方法相近的准确率,深度学习方法的实验结果更优,但没有与传统规则模板方法拉开明显的差距。

3.5.3 神经网络+候选排序+外部信息

本小节介绍使用外部知识回答问题的方法。MCCNN 系统^[28]结合主题实体对应的维基百科(Wikipedia)页面信息,过滤系统返回的不正确答案;Talmor 等人^[38]使用计算树(computation tree)分析问题语义并分解为多个子问题,同时从 KG 和搜索引擎中提取子问题答案,最后将各子问题答案取交集获得最终答案;GRAFTNet 系统^[37]提出问题表示图,用于确定答案在 KG 与文本数据中的存在情况。

表 3 给出了基于深度学习方法的小结。知识图谱嵌入方法作为所有深度学习方法的基础,对简单问题使用问题答案相似度比对的方法获得答案;记忆网络方法通过记忆模块与知识图谱嵌入的结合,实现简单问题问答性能的进一步提升,记忆网络结构具有较大的扩展性;基于神经网络的语义解析与信息检索方法在简单问题处理方面的性能基本接近,区别在于是否可生成查询语句,在复杂问题方面,基于神经网络的语义解析在近几年产生了程序归纳方法,而基于神经网络的信息检索在该方向目前进展较少;基于神经网络的查询图目前为较理想的方法,可同时处理简单问题与复杂问题,但其在搜索空间的缩减方面仍有待提高。

表 4 汇总了本文介绍的所有知识图谱问答方法,包括每种方法的文献和原理描述。

Table 3 Summary of deep learning based methods

表3 基于深度学习的方法小结

类型	优点	缺点	方法	文献	描述
知识图谱嵌入	无需使用任何人工定义的特征参与运算	缺乏对先验知识的应用	知识图谱嵌入相似度	[19,33,41-42,75-77,95]	计算问题与答案的嵌入向量相似度获得最优答案
记忆网络	扩展组合性较强, 可灵活修改各组件功能特性	复杂多跳问题处理能力较低	记忆模块+知识图谱嵌入	[24,32,39,78-79]	以知识图谱嵌入相似度为基础, 设计记忆组件存储 KG, 提升候选答案检索能力
基于神经网络的语义解析	具有良好的简单问题处理能力, 以及一定语义解析的复杂问题处理能力	对复杂多限制问题的处理能力较弱	神经网络+知识图谱嵌入	[21,30,80-81,96]	使用神经网络获得问题与候选答案的向量表示, 计算相似度
			神经网络+候选排序	[82]	使用神经网络获得答案类型打分作为重要排序依据
			神经网络+复杂描述+候选排序	[83]	改写问题, 神经网络分别将“问题-改写”和“改写-答案”评分作为最终打分
基于神经网络的查询图	具有复杂多跳和多限制问题的处理能力	剪枝缩小搜索空间技术欠佳, 待排序的结果冗余	程序归纳	[84-87]	问题转换为可在 KG 上执行的程序序列, 按执行顺序检索问题答案
			神经网络模块组合	[31]	人工预先设计神经网络子模块, 针对不同问题组合出不同结构的神经网络模型用以解析问题语义
			神经网络+答案特征	[27,88]	使用神经网络表示候选关系, 与问题做相似度比较作为关系选择依据, 构建语义查询图
基于神经网络的信息检索	对简单问题的处理效果较优	缺少可解释性	神经网络+问题特征+图特征	[36,40,89-91]	使用神经网络同时表示问题与语义查询图, 评测两者相似度作为语义查询图的选择依据
			剪枝+集束搜索	[43]	单关系多约束问题与多关系问题分别使用剪枝操作和集束搜索减小搜索空间
			神经网络+候选排序	[92-93,97-99]	同神经网络+知识图谱嵌入方法, 但直接返回最佳答案
基于神经网络的语义解析	具有良好的简单问题处理能力, 以及一定语义解析的复杂问题处理能力	对简单问题的处理效果较优	神经网络+关系匹配	[29,35,94,100]	同神经网络+答案特征方法, 但直接返回最佳关系
			神经网络+候选排序+外部信息	[28,37-38,101]	结合外部信息, 对候选答案进行筛选或补充

Table 4 Summary of open-domain knowledge graph question answering methods

表4 开放领域知识图谱问答方法总结

类型	名称	文献	描述
基于规则模板的方法	传统语义解析	[17,23,47-54,68-70]	同时完成结构和词汇到 KG 的映射
	传统信息检索	[20,71]	以实体或关系为单位, 基于特征比较相似度
	三元组匹配	[22,55-62]	以三元组为单位, 基于特征比较相似度
	话语模板	[18,26,34,63-66,72-74]	表述语义结构后填充 KG 实体关系使之实例化
基于深度学习的方法	查询模板	[25,67]	按照实体链接、关系抽取、候选查询排序的流水线顺序执行得到查询语句
	知识图谱嵌入	[19,33,41-42,75-77,95]	通过问题与答案的嵌入表示, 获得答案打分
	记忆网络	[24,32,39,78-79]	以知识图谱嵌入为基础, 引入记忆模块存储 KG
	基于神经网络的语义解析	[21,30-31,80-87,96]	使用神经网络完成传统方法中的映射和排序工作
	基于神经网络的查询图	[27,36,40,43,88-91]	使用神经网络完成查询图中的实例化和打分工作
基于神经网络的信息检索	基于神经网络的语义解析	[28-29,35,37-38,92-94,97-101]	使用神经网络完成信息检索中的答案排序工作

4 知识图谱问答相关资源

本章首先介绍作为 KGQA 信息源的常用通用领域知识图谱,然后介绍基于这些通用领域知识图谱的信息构建而成的开放领域问答数据集。

4.1 通用领域知识图谱

通用领域知识图谱作为问答系统的信息源,是整个系统的核心组件,问答效果与知识图谱的信息质量直接关联。下述 4 个通用领域知识图谱是开放领域知识图谱问答常用的 KG。

Freebase 是一个开放共享、协同构建的大规模数据库,基于 RDF 三元组模型构建并采用图数据库进行底层存储。其知识表示框架主要包含对象、事实、类型和属性 4 个要素,使用复合值类型(compound value types, CVT)来处理多元关系。

DBpedia 是世界上最大的多领域知识本体之一,也是语义网应用的一个典型范例。它从维基百科词条中提取结构化资源,增强维基百科搜寻功能,并将其他数据集联结至维基百科。通过语义技术,使维基百科页面信息获得更多的语义应用。

YAGO 是一个三元组质量高、概念覆盖广的链接数据库,其核心同为维基百科,却以较高的准确率将维基百科与 WordNet^[102]两个数据源进行连接,以三元组的关系类型为单位,计算连接所得的三元组准确率平均达 97%。这使得 YAGO 本体既从维基百科的海量数据获益,又利用了 WordNet 清晰的概念分类。

Wikidata^[103]的目标是构建一个免费开放、多语言、任何人或机器都可以编辑修改的大规模链接知识图谱。Wikidata 起源于维基百科,已作为维基百科

的后台支持知识库使用,同样以页面作为基本组织单元,实体代指最顶层的对象。

4.2 开放领域问答数据集

开放领域问答数据集随着知识图谱问答技术的发展而不断被开发,数据集间的比较如表 5 所示。

Free917^[50]的问题类型没有限制,但以房地产领域为主,数据形式为(问题, λ -calculus 表达式),数据集的问题通过将 Freebase 的某个属性作为答案,人工提出与之相关的自然语言问题获得。

WebQuestions 使用 Google Suggest API 随机获取以 Wh 疑问词开头并仅含单个实体的 10 万个问题,由 AMT(Amazon mechanical turk)工人通过 Freebase 实体页面的内容回答。由于采用先提问后解答的问题构建流程,该数据集的问题完全独立于 Freebase,相比 Free917 更加自然多样化,但仅提供问题答案,不提供检索出答案的查询语句。

SimpleQuestions 以研究系统覆盖面为目的,收集一个纯简单问题的数据集。数据由统一资源标志符(uniform resource identifier, URI)标识,数据形式为(主语 URI, 关系 URI, 宾语 URI),每个问题与知识图谱 Freebase2M^[104]的一个事实三元组匹配。

FactoidQuestions^[104]以 SimpleQuestions 作为训练数据,将 Freebase 中的三元组通过神经网络模型自动转换为自然语言问题,得到问答对数据。该方法所得问题质量优于模板方法所得质量,数据的形式为((主语 URI, 关系 URI, 宾语 URI), 问题)。

ComplexQuestions^[105]的目标是构建一个多层次限制问题数据集,测试 KGQA 系统在复杂多层次限制问题上

Table 5 Comparison of open-domain question answering dataset

表 5 开放领域问答数据集的比较

背景 KG	提供答案	数据集	问题数	查询形式	实体数	关系数	问题结构
Freebase	否	Free917	917	λ -calculus	733	852	简单
		WebQuestions	5 810	无	4 525	未提供	84% 简单 ^[105]
		SimpleQuestions	108 442	三元组	131 684	1 837	简单
		FactoidQuestions	31 021 369	三元组	未提供	未提供	简单
		ComplexQuestions	2 100	无	未提供	未提供	复杂
		WebQuestionsSP	4 737	SPARQL	904 938	695	简单
		ComplexWebQuestions	34 689	SPARQL	未提供	未提供	复杂
	是	GraphQuestions	5 166	SPARQL	未提供	596	复杂
DBpedia+YAGO	是	PathQuestion	7 106	路径	2 215	14	复杂
DBpedia+Wikidata	否	QALD	50~500	SPARQL	383	378	复杂
		LC-QuAD	5 000~30 000	SPARQL	5 042~21 258	615~1 310	复杂

的能力。创建者分别从 WebQuestions 的训练集和测试集选取 596 和 326 个问题, 从搜索引擎得到 878 个问题, 从文献[106]获得 300 个问题组成该数据集。该数据集不提供查询语句。

WebQuestionsSP^[107]重新审视语义解析逻辑形式数据的价值, 证明逻辑形式数据有助于 KGQA 性能提升, 并以 WebQuestions 数据集为基础进行创建。其中共有 1 073 个 WebQuestions 问题无法提供对应答案的完整解析。

ComplexWebQuestions^[108]从 WebQuestionsSP 数据集中检索符合条件的 SPARQL 查询, 据此自动创建更复杂的查询, 生成 AMT 工人可以理解的查询语句, 并由 AMT 工人将查询语句解释为自然语言问题。

GraphQuestions^[109]是首个具有明确特征的问题集, 用于考察不同问题特征对问答过程的影响。问题通过 KG 创建的多个查询模板生成对应查询图, 保留高质量的查询图交由众包转换为问题。

PathQuestion^[110]以 Freebase 为 KG, 提取彼此为 2 至 3 跳关系的实体及对应路径, 利用模板生成问题。为提高生成问题的多样性, 构建者搜索互联网、WebQuestions 和 WikiAnswers^[69]数据集确定 Freebase 内的同义关系词, 改写模板生成的问题, 以丰富所生成问题的词汇丰富度。

QALD^[111-115]是 CLEF(Congference and Labs of the Evaluation Forum)的一项评估子任务, CLEF 从 2011 年开始每年举办一次, 每次提供多个训练集和测试集。所提供的问题中, 复杂多关系和多限制问题约占 38%。

LC-QuAD^[116-117]创建一组 SPARQL 模板和种子实体, 提取种子实体对应的 DBpedia 子图, 每个子图均包含 RDF 图中距离种子实体两跳范围内的所有三元组, 使用这些三元组实例化 SPARQL 模板来创建 SPARQL 查询。

5 知识图谱问答方法评测

本章首先介绍评测 KGQA 系统常用的指标类型, 然后选取 3 个经典的数据集对比不同方法间的性能差异并进行分析。

5.1 评测指标

对知识图谱问答系统进行评测时, 通常使用 4 种指标: 准确率、精度、召回率和 F1。其中除准确率是以问题集整体为单位进行计算外, 其他 3 个指标均以

单个问题为计算单位。

设系统针对单个问题返回的答案集内存在多个正确答案, 令 Q 为问题集, q 为问题集内的单个问题, t 为系统预测正确的问题总数, $rank_i$ 为第 i 个问题对应答案集中第一个正确答案的排名; 对单个问题 q 而言, 令 A 为系统返回答案集, G 为黄金标准答案集(每个问题对应的一组预期正确答案), $prec_j$ 为系统返回的答案列表中, 自顶向下以第 j 个正确答案为下界, 取下界以上部分为子答案集计算所得的精度。

5.1.1 准确率

准确率(accuracy)表示系统回答正确的问题数占问题总数的比例, 若单个问题同时拥有多个正确答案, 则视系统同时返回全部答案为正确。其计算公式如下:

$$accuracy(Q) = \frac{t}{|Q|} \quad (1)$$

$Hits@K$ 是一个基于准确率进行定义的指标。若按某顺序排列答案列表, 前 K 个答案中至少存在一个正确答案则为 1 hit, 反之没有正确答案则为 0 hit, 最终计算整个问题集的 hit 平均值。 K 值大小由任务具体需求人工定义。

5.1.2 精度

精度(precision)表示对于单个问题而言, 系统返回的正确答案数占系统返回的总答案数的比例。其计算公式如下:

$$precision(q) = \frac{|A \cap G|}{|A|} \quad (2)$$

5.1.3 召回率

召回率(recall)表示对于单个问题而言, 系统返回的正确答案数占系统返回的黄金标准答案的比例。其计算公式如下:

$$recall(q) = \frac{|A \cap G|}{|G|} \quad (3)$$

5.1.4 F1

F1 值表示精度与召回率的加权平均值, 是系统性能总体水平的综合体现。其计算公式如下:

$$F1 = 2 \times \frac{precision \times recall}{precision + recall} \quad (4)$$

对于上述 3 种指标, 有分别对应的 $precision@K$ 、 $recall@K$ 和 $F1@K$ 指标, 计算方式同 $Hits@K$, 考察范围 K 由人为指定, 均以系统返回答案列表的前 K 个答案作为考察范围进行计算。

系统的F1有两种计算方法 micro-F1 和 macro-F1, 区别在于计算时是否将问题集中尚未回答的指标考虑在内。micro-F1通过计算已回答问题的精度与召回率的平均值获得; macro-F1则通过同时计算未回答问题的精度和召回率并取平均值获得。本文使用marco-F1值作为评测指标。

除了上述4种指标外,还有两种用于衡量系统返回答案集优劣的评测指标 mAP(mean average precision) 与 MRR(mean reciprocal rank), 答案集的优劣通过正确答案在答案列表中的相对位置评价。

5.1.5 mAP

mAP计算系统返回的答案集内,自顶向下分别以各正确答案所在位置为下界,取下界以上部分为子答案集计算所得精度的平均值。其计算公式如下:

$$mAP(Q) = \frac{1}{|Q|} \sum_{i=1}^{|Q|} \sum_{j \in [A \cap G]} prec_j \quad (5)$$

5.1.6 MRR

MRR计算答案集内第一个正确答案所在位置的倒数平均值。其计算公式如下:

$$MRR(Q) = \frac{1}{|Q|} \sum_{i=1}^{|Q|} \frac{1}{rank_i} \quad (6)$$

假设以“三原色是哪几种?”和“德国三大汽车品牌是什么?”两个问题构成一个问题集,问题的黄金标准答案分别是“绿色”“红色”“蓝色”和“奔驰”“宝马”“大众”。这两个问题与问题集的评测指标值如图23所示。

5.2 指标分析

通过对主流数据集的筛选分析,本文选取3个数据集进行评测。通过4.2节的描述可知,3个数据集各具特点: SimpleQuestions 为简单问题数据集,通过

单个三元组即可解答,系统仅需给定候选实体与候选关系中置信度最高的一个实体和一个关系,即可构成查询语句并获得宾语答案; WebQuestions 含 84% 的简单问题与 16% 的复杂问题,可视为复杂问题与简单问题的折衷; 而 ComplexQuestions 全部为复杂问题,涉及多跳关系与多限制条件,回答难度较大。

5.2.1 SimpleQuestions

在 SimpleQuestions 数据集上进行实验的系统,所得指标如图24所示。

记忆网络早期方法受记忆网络结构的限制,仅能解决简单问题且效果一般。MemNN^[78]的设计初衷并非用于解决开放领域问题; MemNNs^[24]对 MemNN 进行修改使得系统更适配于 Freebase 及 SimpleQuestions 数据集,但提升效果一般; 对于不使用 KG 预处理技术的记忆网络方法^[79],其性能指标甚至低于最初的 MemNN 方法。可见,将 KG 存储于记忆模块整体检索的实际效果并不理想。

如图24所示,剩余方法皆与神经网络模型进行结合且准确率均高于 70.9%。根据编码器分别在问题的词级和字符级构建表示的研究可知^[80,96],令编码器在字符级与词级分别构建问题表示,并分别用于实体链接与关系抽取环节的效果,比单纯在字符级构建问题表示完成上述任务的效果好。

基于神经网络的查询图方法,准确率上限为 72.8%; 单纯使用知识图谱嵌入方法回答问题的准确率上限为 75.4%; 其余基于神经网络的信息检索方法,效果普遍更优。将神经网络模型抽取的特征用于候选排序环节或用于实体/关系抽取环节,对系统准确率的提升效果相近,对于排序环节,使用 MCCNN^[28]抽取特征的效果较好; 对于实体和关系抽

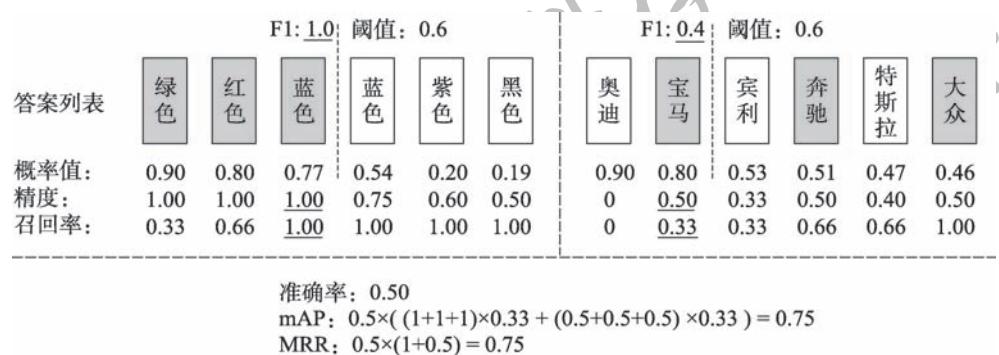


Fig.23 Example of evaluation metric

图23 评测指标示例图

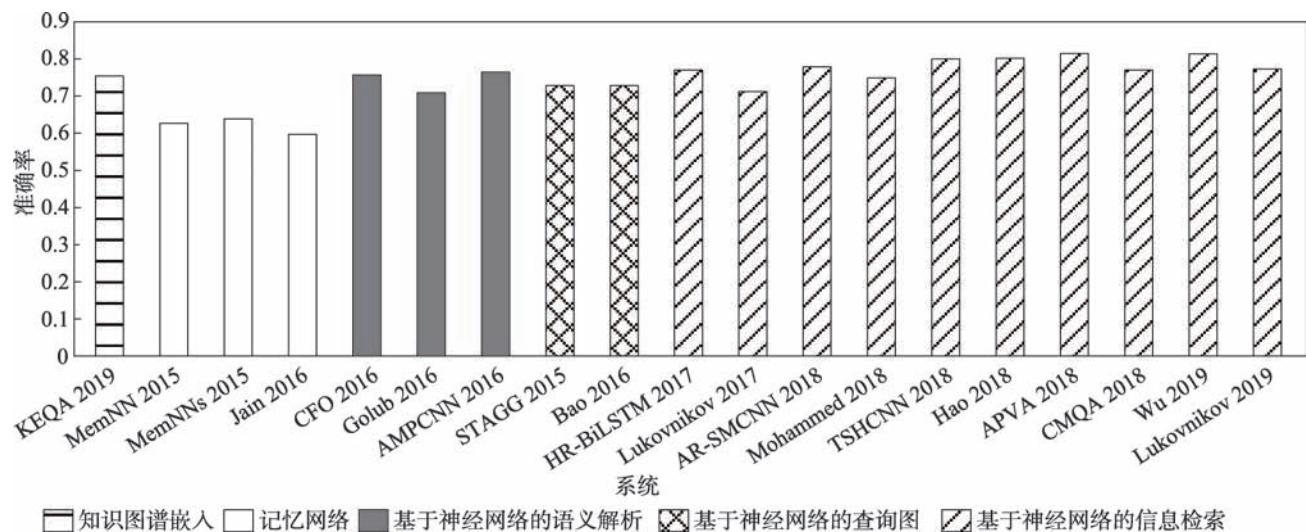


Fig.24 Accuracy of SimpleQuestions related systems

图 24 SimpleQuestions 相关系统精确率

取环节,将实体链接与关系抽取视为两个独立环节的方法^[71]普遍没有联合抽取方法^[98](即同时考虑实体和关系两者与原问句相似度)的效果好。

5.2.2 WebQuestions

在 WebQuestions 数据集上进行实验的系统,所得指标如图 25 所示。

使用直接映射的传统语义解析方法与传统信息检索方法作为系统实现的性能,基本作为 KGQA 在此数据集的最低指标;使用复述方法的传统语义解析可提升一定的效果,但相比深度学习方法对系统

的提升而言,提升幅度较小。

若单独使用知识图谱嵌入作为 KGQA 的核心方法进行实现,其效果处于传统语义解析方法中的较高位置,虽相比传统语义解析方法而言性能提升幅度不大,但省去了人工参与特征设置的步骤,证明了深度学习方法的有效性。

如图 25 所示,剩余方法的 F1 指标皆不低于 40.8%。基于模板规则的查询模板方法仍能与基于深度学习的方法性能相比较,F1 最高可取得 52.2% 的成绩,想继续提升性能则可尝试使用神经网络模块。

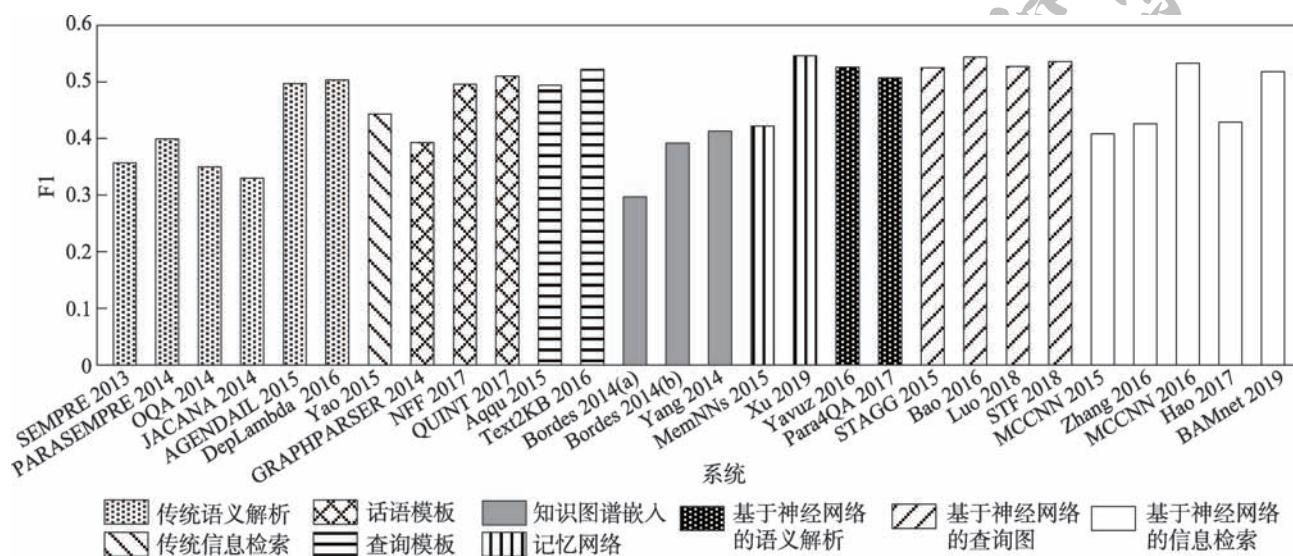


Fig.25 F1 of WebQuestions related systems

图 25 WebQuestions 相关系统 F1 值

在基于神经网络的信息检索方法中,若神经网络模型处理短语映射,则对应的性能指标介于40.8%~42.9%之间,想获得更大的提升,需要使用基于神经网络的查询图方法,可获得至少52.5%的F1值。其中使用CNN结合问题特征与图特征排序语义查询图的方法^[89]可获得本类方法目前的最高性能。

可获得更优效果的方法包括MCCNN^[28]系统,该系统使用维基百科页面的信息去除候选答案中的不正确项。其次,包括两种基于神经网络的语义解析方法。Yavuz等人^[82]将实体类型打分作为一个重要的排序因素;Dong等人^[83]使用复述方法,先对改写问题与原问题的相似度打分,之后对答案与相应改写问题的相似度打分,两者相乘作为最终的排序依据。

记忆网络在实现多跳查询后^[39],性能得到极大提升,接近于该数据集的最佳值。

5.2.3 ComplexQuestions

在ComplexQuestions数据集上进行实验的系统,所得指标如图26所示。

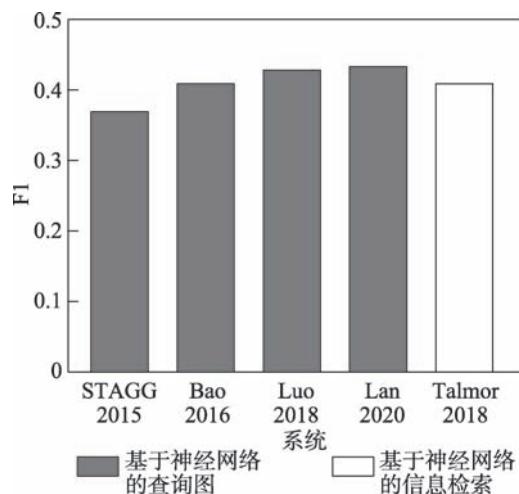


Fig.26 F1 of ComplexQuestions related systems

图26 ComplexQuestions相关系统F1值

有效用于解决复杂问题的方法并不多,主要以基于神经网络的查询图方法为主,该方法可对复杂多跳和多限制问题进行很好的图形化描述。一种可用于解决复杂问题的基于神经网络的信息检索方法^[38],将复杂问题分解为多个子问题逐个解决,子问题通过同时检索KG与搜索引擎获得答案,问题最终的答案通过子问题答案取交集获得。

对于基于神经网络的查询图方法,以神经网络

模块抽取的问题特征和图特征作为语义查询图的排序依据的方法^[36],不如在语义查询图的构建阶段就采用低召回、高精度方式完成的方法效果好^[43]。例如因问题增加限制条件或关系个数而需要对语义查询图进行扩展时,仅选择语义查询图的最佳扩展方向而非所有可能的方向进行扩展,可减轻排序模型的负担,以提高问答效果。

6 未来研究方向

通过上述分析比较可以看出,开放领域知识图谱问答已经取得一定进展,但现存的开放领域知识图谱问答方法仍有许多局限性,面临许多挑战。本章给出开放领域知识图谱问答的一些未来研究方向。

6.1 解决知识图谱不完整问题

由于通用领域KG的内容通常是稀疏且不完整的,导致系统无法从通用领域KG获得足够的信息以回答问题。对此,人们试图引入外部文本语料库作为开放领域知识库问答系统的另一信息源;或根据KG目前已有的知识推理得到KG缺失的知识,以解决KG不完整的问题。

目前有两种与外部文本语料库结合的方式:一种是语料库所提供的数据作为KGQA各环节所利用的特征信息,提高KGQA各环节的性能表现;另一种是将语料库提供的数据作为KGQA系统的答案来源,补充KG所缺失的实体信息。但目前已有的利用外部文本语料库的方法通常仅将外部文本语料库作为系统的唯一KG,或将KG与外部文本语料库信息视为单个KG整体,如何更加充分利用彼此独有的信息,以更巧妙的方式将KG与外部文本语料库进行结合,是未来需要研究的内容。

6.2 结合知识图谱推理

对于KG推理方法,目前常使用知识图谱嵌入完成事实三元组的推理工作,但使用该技术预测缺失事实的效果不佳,尤其对于包含长尾关系的三元组。而目前知识图谱推理的工作除了知识图谱嵌入方法外,还有使用GNN模型和统计关系学习(statistical relational learning, SRL)等方法,这些工作都可作为KGQA结合的方向进行探究。如何充分利用已有的三元组获得高置信度的推理结果,仍需进一步研究。

6.3 精确提取语义信息

由于KGQA处理的问题通常是一句简短且语义

信息有限的自然语言问题,抽取出丰富且精确的语义信息具有一定难度。对此,人们通常采用传统的实体关系抽取流水线方法或预训练模型来提高语义信息的提取能力。

针对实体关系抽取流水线方法,人们常通过提高候选实体与候选关系的召回率,而将消歧选优工作统一交给单个模型来实现。这种方法不仅会造成含有噪声的巨大搜索空间,降低系统精度,还将大幅提高问答所需时长。如何在保证结果高精度的同时保持实体关系的高召回率是未来需要解决的问题之一。

6.4 利用预训练模型

针对预训练模型,其高效的实体关系抽取表现得益于预训练过程中海量的文本训练数据,使得预训练模型在KGQA问答训练数据较少的情况下,仍可获得相对传统实体关系流水线方法更优的性能体现。但如何更加充分地结合KGQA系统,利用好预训练模型内的先验知识,同样是待研究的一个方向。

6.5 有效处理复杂问题

由于复杂问题涉及多跳关系或多限制条件,导致用户提高了对系统语义分析能力的要求。针对复杂问题语义分析难度大的情况,人们通常采用基于神经网络的查询图方法和基于神经网络的信息检索方法进行解决。

对于基于神经网络的查询图方法,目前主要通过提高语义查询图的召回率后进行排序的方法,或在语义查询图生成过程中及时完成剪枝工作的方法,得到复杂问题的语义解析结果。但如5.2.3小节ComplexQuestions数据集的实验结果所示,这些方法的效果与较为成熟简单的KGQA方法相比,仍有较大差距。如何在语义查询图生成过程中减少候选数量,提高语义查询图的生成质量,是需要进一步研究的问题。

对于基于神经网络的信息检索方法,目前主要通过将单个复杂问题分解为多个子问题,各子问题使用基于神经网络的信息检索方法进行解答,问题最终的答案通过子问题答案取交集获得。但应如何合理地完成子问题分解,并充分结合基于神经网络的信息检索方法在简单问题上的有效性,是未来的一个研究方向。

7 总结

问答系统能自动回答人类提出的自然语言问

题,开放领域知识图谱问答作为问答系统与通用领域知识图谱的融合,具有十分重要的意义。本文对开放领域知识图谱问答进行了研究综述,介绍了5种基于规则模板的知识图谱问答方法,描述了5种基于深度学习的知识图谱问答方法,对知识图谱问答常用的4个知识图谱及11个问答数据集进行了介绍,在3个问答数据集上比较了不同方法间的性能差异,最后展望了开放领域知识图谱问答的未来研究方向。

参考文献:

- [1] SINGH V, DWIVEDI S K. Question answering: a survey of research, techniques and issues[J]. International Journal of Information Retrieval Research, 2014, 4(3): 14-33.
- [2] GREEN B F, ALICE K W, CHOMSKY C, et al. Baseball: an automatic question-answerer[M]. New York: ACM, 1961: 219-224.
- [3] WOODS W A. Progress in natural language understanding: an application to lunar geology[M]. New York: ACM, 1973: 441-450.
- [4] BERNERSLEE T, HENDLER J, LASSILA O. The semantic web[J]. Scientific American, 2001, 284(5): 34-43.
- [5] SHADBOLT N, HALL W, BERNERS-LEE T. The semantic web revisited[J]. IEEE Intelligent Systems, 2006, 21(3): 96-101.
- [6] PUJARA J, HUI M, GETOOR L, et al. Knowledge graph identification[M]. Berlin: Springer, 2013: 542-557.
- [7] BOLLACKER K, EVANS C, PARITOSH P, et al. Freebase: a collaboratively created graph database for structuring human knowledge[C]//Proceedings of the 2008 ACM SIGMOD International Conference on Management of Data, Vancouver, Jun 10-12, 2008, New York: ACM, 2008: 1247-1250.
- [8] AUER S, BIZER C, KOBILAROV G, et al. DBpedia: a nucleus for a web of open data[M]. Berlin: Springer, 2007: 722-735.
- [9] SUCHANEK F M, KASNECI G, WEIKUM G. YAGO: a core of semantic knowledge unifying WordNet and Wikipedia [C]//Proceedings of the 16th International Conference on World Wide Web, Banff, May 2007. New York: ACM, 2007: 697-706.
- [10] WOOLDRIDGE M, JENNINGS N R. Intelligent agents: theory and practice[J]. Knowledge Engineering Review, 1995, 10(2): 115-152.
- [11] MLADEMID. Text-learning and related intelligent agents: a survey[J]. IEEE Intelligent Systems & Their Applications, 2002, 14(4): 44-54.
- [12] FAST E, CHEN B, MENDELSON J, et al. Iris: a conver-

sational agent for complex tasks[J]. arXiv:1707.05015, 2017.

[13] DIEFENBACH D, LOPEZ V, SINGH K, et al. Core techniques of question answering systems over knowledge bases: a survey[J]. *Knowledge and Information Systems*, 2017, 55(3): 529-569.

[14] CHAKRABORTY N, LUKOVNIKOV D, MAHESHWARI G, et al. Introduction to neural network based approaches for question answering over knowledge graphs[J]. arXiv:1907.09361, 2019.

[15] FU B, QIU Y, TANG C, et al. A survey on complex question answering over knowledge base: recent advances and challenges [J]. arXiv:2007.13069, 2020.

[16] DENG C Y, ZENG G F, CAI X Q, et al. A survey of knowledge based question answering with deep learning[J]. *Journal on Artificial Intelligence*, 2020, 2(4): 157-166.

[17] BERANT J, CHOU A, FROSTIG R, et al. Semantic parsing on Freebase from question-answer pairs[C]//Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing, Seattle, Oct 18-21, 2013. Stroudsburg: ACL, 2013: 1533-1544.

[18] KWIATKOWSKI T, CHOI E, ARTZI Y, et al. Scaling semantic parsers with on-the-fly ontology matching[C]//Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing, Seattle, Oct 18-21, 2013. Stroudsburg: ACL, 2013: 1545-1556.

[19] BORDES A, CHOPRA S, WESTON J. Question answering with subgraph embeddings[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing, Doha, Oct 25-29, 2014. Stroudsburg: ACL, 2014: 615-620.

[20] YAO X C, VAN DURME B. Information extraction over structured data: question answering with Freebase[C]//Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics, Baltimore, Jun 22-27, 2014. Stroudsburg: ACL, 2014: 956-966.

[21] YIH W T, HE X D, MEEK C. Semantic parsing for single-relation question answering[C]//Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics, Baltimore, Jun 22-27, 2014. Stroudsburg: ACL, 2014: 643-648.

[22] BAO J W, DUAN N, ZHOU M, et al. Knowledge-based question answering as machine translation[C]//Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics, Baltimore, Jun 22-27, 2014. Stroudsburg: ACL, 2014: 967-976.

[23] BERANT J, LIANG P. Semantic parsing via paraphrasing [C]//Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics, Baltimore, Jun 22-27, 2014. Stroudsburg: ACL, 2014: 1415-1425.

[24] BORDES A, USUNIER N, CHOPRA S, et al. Large-scale simple question answering with memory networks[J]. arXiv: 1506.02075, 2015.

[25] BAST H, HAUSSMANN E. More accurate question answering on Freebase[C]//Proceedings of the 24th ACM International on Conference on Information and Knowledge Management, Melbourne, Oct 2015. New York: ACM, 2015: 1431-1440.

[26] REDDY S, LAPATA M, STEEDMAN M. Large-scale semantic parsing without question-answer pairs[J]. *Transactions of the Association for Computational Linguistics*, 2014, 2(1): 377-392.

[27] YIH W T, CHANG M W, HE X, et al. Semantic parsing via staged query graph generation: question answering with knowledge base[C]//Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing, Beijing, Jul 26-31, 2015. Stroudsburg: ACL, 2015: 1321-1331.

[28] XU K, REDDY S, FENG Y, et al. Question answering on Freebase via relation extraction and textual evidence[C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics, Berlin, Aug 7-12, 2016. Stroudsburg: ACL, 2016: 2326-2336.

[29] LIANG C, BERANT J, LE Q, et al. Neural symbolic machines: learning semantic parsers on Freebase with weak supervision[C]//Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics, Vancouver, Jul 30-Aug 4, 2017. Stroudsburg: ACL, 2017: 23-33.

[30] XU K, FENG Y, HUANG S, et al. Hybrid question answering over knowledge base and free text[C]//Proceedings of the 26th International Conference on Computational Linguistics, Osaka, Dec 11-16, 2016. Stroudsburg: ACL, 2016: 2397-2407.

[31] ANDREAS J, ROHRBACH M, DARRELL T, et al. Learning to compose neural networks for question answering[C]//Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, San Diego, Jun 12-17, 2016. Stroudsburg: ACL, 2016: 1545-1554.

[32] MILLER A H, FISCH A, DODGE J, et al. Key-value memory networks for directly reading documents[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural

Language Processing, Austin, Nov 1-4, 2016. Stroudsburg: ACL, 2016: 1400-1409.

[33] ZHANG Y, DAI H, KOZAREVA Z, et al. Variational reasoning for question answering with knowledge graph[J]. arXiv: 1709.04071, 2017.

[34] CUI W, XIAO Y, WANG H, et al. KBQA: learning question answering over QA corpora and knowledge bases[J]. VLDB Endowment, 2017, 10(5): 565-576.

[35] YU M, YIN W, HASAN K S, et al. Improved neural relation detection for knowledge base question answering [C]//Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics, Vancouver, Jul 30- Aug 4, 2017. Stroudsburg: ACL, 2017: 571-581.

[36] SOROKIN D, GUREVYCH I. Modeling semantics with gated graph neural networks for knowledge base question answering[C]//Proceedings of the 27th International Conference on Computational Linguistics, Santa Fe, Aug 20-26, 2018. Stroudsburg: ACL, 2018: 3306-3317.

[37] SUN H, DHINGRA B, ZAHEER M, et al. Open domain question answering using early fusion of knowledge bases and text[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, Brussels, Oct 31- Nov 4, 2018. Stroudsburg: ACL, 2018: 4231-4242.

[38] TALMOR A, BERANT J. The web as a knowledge-base for answering complex questions[C]//Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, New Orleans, Jun 1-6, 2018. Stroudsburg: ACL, 2018: 641-651.

[39] XU K, LAI Y X, FENG Y S, et al. Enhancing key-value memory neural networks for knowledge based question answering[C]//Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics, Minneapolis, Jun 2019. Stroudsburg: ACL, 2019: 2937-2947.

[40] MAHESHWARI G, TRIVEDI P, LUKOVNIKOV D, et al. Learning to rank query graphs for complex question answering over knowledge graphs[C]//LNCS 11778: Proceedings of the 18th International Semantic Web Conference, Auckland, Oct 26-30, 2019. Cham: Springer, 2019: 487-504.

[41] SUN H, BEDRAX-WEISS T, COHEN W W. PullNet: open domain question answering with iterative retrieval on knowledge bases and text[C]//Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing, Hong Kong, China, Nov 3-7, 2019. Stroudsburg: ACL, 2019: 2380-2390.

[42] SAXENA A, TRIPATHI A, TALUKDAR P. Improving multi-hop question answering over knowledge graphs using knowledge base embeddings[C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, Jul 5-10, 2020. Stroudsburg: ACL, 2020: 4498-4507.

[43] LAN Y S, JIANG J. Query graph generation for answering multi-hop complex questions from knowledge bases[C]//Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics, Jul 5-10, 2020. Stroudsburg: ACL, 2020: 969-974.

[44] WANG X, ZOU L, WANG C K, et al. Research on knowledge graph data management: a survey[J]. Journal of Software, 2019, 30(7): 2139-2174.
王鑫, 邹磊, 王朝坤, 等. 知识图谱数据管理研究综述[J]. 软件学报, 2019, 30(7): 2139-2174.

[45] LIANG P. Lambda dependency-based compositional semantics [J]. arXiv:1309.4408, 2013.

[46] WONG Y, MOONEY R. Learning synchronous grammars for semantic parsing with lambda calculus[C]//Proceedings of the 45th Annual Meeting of the Association for Computational Linguistics, Prague, Jun 23- 30, 2007. Stroudsburg: ACL, 2007: 960-967.

[47] KWIATKOWSKI T, ZETTLEMOYER L, GOLDWATER S, et al. Inducing probabilistic CCG grammars from logical form with higher-order unification[C]//Proceedings of the 2010 Conference on Empirical Methods in Natural Language Processing, Cambridge, Oct 9-11, 2010. Stroudsburg: ACL, 2010: 1223-1233.

[48] ZETTLEMOYER L S, COLLINS M. Learning to map sentences to logical form: structured classification with probabilistic categorial grammars[J]. arXiv:1207.1420, 2012.

[49] YAHYA M, BERBERICH K, ELBASSUONI S, et al. Natural language questions for the web of data[C]//Proceedings of the 2012 Joint Conference on Empirical Methods in Natural Language Processing and Computational Natural Language Learning, Jeju Island, Jul 12-14, 2012. Stroudsburg: ACL, 2012: 379-390.

[50] YAHYA M, BERBERICH K, SSUONI S E B, et al. Robust question answering over the web of linked data[C]//Proceedings of the 22nd ACM International Conference on Information and Knowledge Management, New York, Oct 2013. New York: ACM, 2013: 1107-1116.

[51] BERANT J, LIANG P. Imitation learning of agenda-based semantic parsers[J]. Transactions of the Association for

Computational Linguistics, 2015, 3: 545-558.

[52] REDDY S, TCKSTRM O, COLLINS M, et al. Transforming dependency structures to logical forms for semantic parsing [J]. *Transactions of the Association for Computational Linguistics*, 2016, 4(2):127-140.

[53] REDDY S, TCKSTRM O, PETROV S, et al. Universal semantic parsing[C]//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, Copenhagen, Sep 9-11, 2017. Stroudsburg: ACL, 2017: 89-101.

[54] FADER A, ZETTLEMOYER L, ETZIONI O. Open question answering over curated and extracted knowledge bases[C]//Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, New York, Aug 24-27, 2014. New York: ACM, 2014: 1156-1165.

[55] LOPEZ V, MOTTA E. Ontology-driven question answering in AquaLog[C]//LNCS 3136: Proceedings of the 9th International Conference on Applications of Natural Languages to Information Systems, Salford, Jun 23-25, 2004. Berlin, Heidelberg: Springer, 2004: 89-102.

[56] LOPEZ V, UREN V, MOTTA E, et al. AquaLog: an ontology-driven question answering system for organizational semantic intranets[J]. *Social Science Electronic Publishing*, 2007, 5(2): 72-105.

[57] DAMLJANOVIC D, AGATONOVIC M, CUNNINGHAM H. Natural language interfaces to ontologies: combining syntactic analysis and ontology-based lookup through the user interaction[M]. Berlin: Springer, 2010: 106-120.

[58] KAUFMANN E, BERNSTEIN A, FISCHER L. NLP-Reduce: a “naive” but domain-independent natural language interface for querying ontologies[C]//Proceedings of the 4th European Semantic Web Conference, Innsbruck, Jan 2007.

[59] LOPEZ V, UREN V S, SABOU M R, et al. Cross ontology query answering on the semantic web: an initial evaluation [C]//Proceedings of the 5th International Conference on Knowledge Capture, Redondo Beach, Sep 1-4, 2009. New York: ACM, 2009: 17-24.

[60] MANACHER G K. An improved version of the Cocke-Younger-Kasami algorithm[J]. *Computer Languages*, 1978, 3(2): 127-133.

[61] OCH F J. Minimum error rate training in statistical machine translation[C]//Proceedings of the 41st Annual Meeting of the Association for Computational Linguistics, Sapporo, Jul 7-12, 2003. Stroudsburg: ACL, 2003: 160-167.

[62] YIN P, DUAN N, KAO B, et al. Answering questions with complex semantic constraints on open knowledge bases[C]//Proceedings of the 24th ACM International Conference on Information and Knowledge Management, Melbourne, Oct 19-23, 2015. New York: ACM, 2015: 1301-1310.

[63] BOS J, CLARK S, STEEDMAN M, et al. Wide-coverage semantic representations from a CCG parser[C]//Proceedings of the 20th International Conference on Computational Linguistics, Geneva, Aug 23-27, 2004: 1240-1246.

[64] LEI Z, HUANG R, WANG H, et al. Natural language question answering over RDF—a graph data driven approach [C]//Proceedings of the 2014 ACM SIGMOD International Conference on Management of Data, Snowbird, Jun 22-27, 2014. New York: ACM, 2014: 313-324.

[65] SHEKARPOUR S, MARX E, NGOMO A C, et al. SINA: semantic interpretation of user queries for question answering on interlinked data[J]. *Journal of Web Semantics*, 2015, 30: 39-51.

[66] ZHENG W, LEI Z, XIANG L, et al. How to build templates for RDF question/answering: an uncertain graph similarity join approach[C]//Proceedings of the 2015 ACM SIGMOD International Conference on Management of Data, Melbourne, May 31-Jun 4, 2015. New York: ACM, 2015: 1809-1824.

[67] SAVENKOV D, AGICHTEIN E. When a knowledge base is not enough: question answering over knowledge bases with external text data[C]//Proceedings of the 39th International ACM SIGIR Conference on Research and Development in Information Retrieval, Pisa, Jul 17-21, 2016. New York: ACM, 2016: 235-244.

[68] CAI Q, YATES A. Large-scale semantic parsing via schema matching and lexicon extension[C]//Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics, Sofia, Aug 4-9, 2013. Stroudsburg: ACL, 2013: 423-433.

[69] FADER A, ZETTLEMOYER L, ETZIONI O. Paraphrase-driven learning for open question answering[C]//Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics, Sofia, Aug 4-9, 2013. Stroudsburg: ACL, 2013: 1608-1618.

[70] USBECK R, NGOMO A, BUHMANN L, et al. HAWK—hybrid question answering using linked data[C]//LNCS 9088: Proceedings of the 12th European Semantic Web Conference, Portoroz, May 31-Jun 4, 2015. Cham: Springer, 2015: 353-368.

[71] YAO X C. Lean question answering over Freebase from scratch[C]//Proceedings of the 2015 Conference of the North American Chapter of the Association for Computational Linguistics, Denver, May 31-Jun 5, 2015. Stroudsburg: ACL, 2015: 66-70.

[72] UNGER C, BUHMANN L, LEHMANN J, et al. Template-based question answering over RDF data[C]//Proceedings of the 21st International Conference on World Wide Web, Lyon, Apr 16-20, 2012. New York: ACM, 2012: 639-648.

[73] ABUJABAL A, YAHYA M, RIEDEWALD M, et al. Automated template generation for question answering over knowledge graphs[C]//Proceedings of the 26th International Conference on World Wide Web, Perth, Apr 3-7, 2017. New York: ACM, 2017: 1191-1200.

[74] HU S, ZOU L, YU J X, et al. Answering natural language questions by subgraph matching over knowledge graphs[J]. IEEE Transactions on Knowledge and Data Engineering, 2017, 30(5): 824-837.

[75] BORDES A, WESTON J, USUNIER N. Open question answering with weakly supervised embedding models[C]//LNCS 8724: Proceedings of the 2014 European Conference on Machine Learning and Knowledge Discovery in Databases, Nancy, Sep 15-19, 2014. Cham: Springer, 2014: 165-180.

[76] ZHOU M, HUANG M, ZHU X. An interpretable reasoning network for multi-relation question answering[C]//Proceedings of the 27th International Conference on Computational Linguistics, Santa Fe, Aug 20- 26, 2018. Stroudsburg: ACL, 2018: 2010-2022.

[77] SUN H, ARNOLD A O, BEDRAX-WEISS T, et al. Faithful embeddings for knowledge base queries[C]//Advances in Neural Information Processing Systems 33: Proceedings of the Annual Conference on Neural Information Processing Systems, Dec 6-12, 2020: 22505-22516.

[78] WESTON J, CHOPRA S, BORDES A. Memory networks [J]. arXiv:1410.3916, 2014.

[79] JAIN S. Question answering over knowledge base using factual memory networks[C]//Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Student Research Workshop, San Diego, Jun 12- 17, 2016. Stroudsburg: ACL, 2016: 109-115.

[80] HE X D, GOLUB D. Character-level question answering with attention[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, Austin, Nov 1-4, 2016. Stroudsburg: ACL, 2016: 1598-1607.

[81] CHEN Z Y, LIAO J Z, ZHAO X, et al. Incorporating subgraph structure knowledge base question answering via neural reasoning[J]. Journal of Frontiers of Computer Science and Technology, 2021, 15(10): 1870-1879.

陈子阳, 廖劲智, 赵翔, 等. 融合子图结构的神经推理式知识库问答方法[J]. 计算机科学与探索, 2021, 15(10): 1870-1879.

[82] YAVUZ S, GUR I, SU Y, et al. Improving semantic parsing via answer type inference[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, Austin, Nov 1-4, 2016. Stroudsburg: ACL, 2016: 149-159.

[83] DONG L, MALLINSON J, REDDY S, et al. Learning to paraphrase for question answering[C]//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing, Copenhagen, Sep 9-11, 2017. Stroudsburg: ACL, 2017: 875-886.

[84] ANSARI G A, SAHA A, KUMAR V, et al. Neural program induction for KBQA without gold programs or query annotations[C]//Proceedings of the 28th International Joint Conference on Artificial Intelligence, Macao, China, Aug 10-16, 2019: 4890-4896.

[85] SAHA A, ANSARI G A, LADDHA A, et al. Complex program induction for querying knowledge bases in the absence of gold programs[J]. Transactions of the Association for Computational Linguistics, 2019, 7: 185-200.

[86] HUA Y, LI Y F, HAFFARI G, et al. Few- shot complex knowledge base question answering via meta reinforcement learning[C]//Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing, Nov 16-20, 2020. Stroudsburg: ACL, 2020: 5827-5837.

[87] YHA D, YFL B, GQA C, et al. Less is more: data-efficient complex question answering over knowledge bases[J]. Journal of Web Semantics, 2020, 65: 100612.

[88] HU S, ZOU L, ZHANG X B. A state-transition framework to answer complex questions over knowledge base[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, Brussels, Oct 31- Nov 4, 2018. Stroudsburg: ACL, 2018: 2098-2108.

[89] BAO J W, NAN D, YAN Z, et al. Constraint-based question answering with knowledge graph[C]//Proceedings of the 26th International Conference on Computational Linguistics, Osaka, Dec 11-16, 2016. Stroudsburg: ACL, 2016: 2503-2514.

[90] LUO K, LIN F, LUO X, et al. Knowledge base question answering via encoding of complex query graphs[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, Brussels, Oct 31- Nov 4, 2018. Stroudsburg: ACL, 2018: 2185-2194.

[91] XU K, WU L, WANG Z, et al. Exploiting rich syntactic information for semantic parsing with graph- to- sequence model[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, Brussels, Oct 31- Nov 4, 2018. Stroudsburg: ACL, 2018: 918-924.

[92] DONG L, WEI F R, ZHOU M, et al. Question answering over Freebase with multi-column convolutional neural networks [C]//Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing, Beijing, Jul 26-31, 2015. Stroudsburg: ACL, 2015: 260-269.

[93] HAO Y, ZHANG Y, KANG L, et al. An end-to-end model for question answering over knowledge base with cross-attention combining global knowledge[C]//Proceedings of the 55th Annual Meeting of the Association for Computational Linguistics, Vancouver, Jul 30- Aug 4, 2017. Stroudsburg: ACL, 2017: 221-231.

[94] MOHAMMED S, SHI P, LIN J. Strong baselines for simple question answering over knowledge graphs with and without neural networks[C]//Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, New Orleans, Jun 1-6, 2018. Stroudsburg: ACL, 2018: 291-296.

[95] YANG M C, NAN D, MING Z, et al. Joint relational embeddings for knowledge-based question answering[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing, Doha, Oct 25-29, 2014. Stroudsburg: ACL, 2014: 645-650.

[96] YIN W P, YU M, XIANG B, et al. Simple question answering by attentive convolutional neural network[J]. arXiv:1606.03391, 2016.

[97] ZHANG Y Z, LIU K, HE S Z, et al. Question answering over knowledge base with neural attention combining global knowledge information[J]. arXiv:1606.00979, 2016.

[98] GUPTA V, CHINNAKOTLA M, SHRIVASTAVA M. Retrieve and re-rank: a simple and effective IR approach to simple question answering over knowledge graphs[C]//Proceedings of the 1st Workshop on Fact Extraction and verification, 2018: 22-27.

[99] ZHANG Y Y, QIAN S S, FANG Q, et al. Multi-modal knowledge-aware attention network for question answering [J]. Journal of Computer Research and Development, 2020, 57(5): 1037-1045.
张莹莹, 钱胜胜, 方全, 等. 基于多模态知识感知注意力机制的问答方法[J]. 计算机研究与发展, 2020, 57(5): 1037-1045.

[100] LIN Q K, ZHANG L L, LIU J, et al. Question-aware graph convolutional network for educational knowledge base question answering[J]. Journal of Frontiers of Computer Science and Technology, 2021, 15(10): 1880-1887.
蔺奇卡, 张玲玲, 刘均, 等. 基于问句感知图卷积的教育知识库问答方法[J]. 计算机科学与探索, 2021, 15(10): 1880-1887.

[101] XIONG W H, YU M, CHANG S Y, et al. Improving question answering over incomplete KBs with knowledge-aware reader[J]. arXiv:1905.07098, 2019.

[102] FELLBAUM C, MILLER G. WordNet: an electronic lexical database[M]. Cambridge: MIT Press, 2000: 706-708.

[103] VRANDECIC D, KRTOETZSCH M. Wikidata: a free collaborative knowledgebase[J]. Communications of the ACM, 2014, 57(10): 78-85.

[104] SERBAN I V, GARCIA-DURAN A, GULCEHRE C, et al. Generating factoid questions with recurrent neural networks: the 30M factoid question-answer corpus[C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics, Berlin, Aug 7-12, 2016. Stroudsburg: ACL, 2016: 588-598.

[105] BAO J W, DUAN N, YAN Z, et al. Constraint-based question answering with knowledge graph[C]//Proceedings of the 26th International Conference on Computational Linguistics, Osaka, Dec 11-16, 2016. Stroudsburg: ACL, 2016: 2503-2514.

[106] YIN P, DUAN N, KAO B, et al. Answering questions with complex semantic constraints on open knowledge bases [C]//Proceedings of the 24th ACM International Conference on Information and Knowledge Management, Melbourne, Oct 19-23, 2015. New York: ACM, 2015: 1301-1310.

[107] YIH W T, RICHARDSON M, MEEK C, et al. The value of semantic parse labeling for knowledge base question answering[C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics, Berlin, Aug 7-12, 2016. Stroudsburg: ACL, 2016: 201-206.

[108] TALMOR A, BERANT J. The web as a knowledge-base for answering complex questions[C]//Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics, New Orleans, Jun 1-6, 2018. Stroudsburg: ACL, 2018: 641-651.

[109] YU S, SUN H, SADLER B, et al. On generating characteristic-rich question sets for QA evaluation[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing, Austin, Nov 1-4, 2016. Stroudsburg: ACL, 2016: 562-572.

[110] ZHOU M, HUANG M, ZHU X. An interpretable reasoning network for multi-relation question answering[C]//Proceedings of the 27th International Conference on Computational Linguistics, Santa Fe, Aug 20-26, 2018. Stroudsburg: ACL, 2018: 2010-2022.

[111] CIMIANO P, LOPEZ V, UNGER C, et al. Multilingual

question answering over linked data (QALD-3): lab overview[C]//LNCS 8138: Proceedings of the 4th International Conference of the Cross-Language Evaluation Forum for European Languages: Information Access Evaluation, Multilinguality, Multimodality, and Visualization, Valencia, Sep 23-26, 2013. Berlin: Springer, 2013: 321-332.

[112] UNGER C, FORASCU C, LOPEZ V, et al. Question answering over linked data (QALD-4)[C]//Working Notes for CLEF 2014 Conference, Sheffield, Sep 15-18, 2014: 1172-1180.

[113] UNGER C, FORESCU C, LOPEZ V, et al. Question answering over linked data (QALD-5)[C]//Working Notes for CLEF 2015-Conference and Labs of the Evaluation Forum, Toulouse, Sep 8-11, 2015.

[114] UNGER C, NGOMO A, CABRIO E. 6th open challenge on question answering over linked data (QALD- 6) [C]// Semantic Web Challenges: 3rd SemWebEval Challenge at ESWC 2016, Heraklion, May 29- Jun 2, 2016. Cham: Springer, 2016: 171-177.

[115] USBECK R, NGOMO A, HAARMANN B, et al. Open challenge on question answering over linked data (QALD- 7)[C]//Semantic Web Challenges: 4th SemWebEval Challenge at ESWC 2017, Portoroz, May 28-Jun 1, 2017. Cham: Springer, 2017: 59-69.

[116] TRIVEDI P, MAHESHWARI G, DUBEY M, et al. LC-QuAD: a corpus for complex question answering over knowledge graphs[C]//LNCS 10588: Proceedings of the 16th International Semantic Web Conference, Vienna, Oct 21- 25, 2017. Cham: Springer, 2017: 210-218.

[117] DUBEY M, BANERJEE D, ABDELKAWI A, et al. LC-QuAD 2.0: a large dataset for complex question answering over Wikidata and DBpedia[C]//LNCS 11779: Proceedings of the 18th International Semantic Web Conference, Auckland, Oct 26-30, 2019. Cham: Springer, 2019: 69-78.



陈子睿(1998—),男,新疆克拉玛依人,硕士研究生,CCF学生会员,主要研究方向为知识表示学习、知识图谱问答。

CHEN Zirui, born in 1998, M.S. candidate, student member of CCF. His research interests includes knowledge representation learning and knowledge graph question answering.



王鑫(1981—),男,博士,教授,博士生导师,CCF杰出会员,主要研究方向为知识图谱、数据管理、图数据库、大数据分布式处理。

WANG Xin, born in 1981, Ph.D., professor, Ph.D. supervisor, distinguished member of CCF. His research interests includes knowledge graphs, date management, graph databases and bigdata distributed processing.



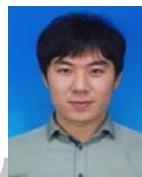
王林(1981—),男,博士,CCF专业会员,主要研究方向为大数据应用、人工智能。

WANG Lin, born in 1981, Ph.D., professional member of CCF. His research interests includes bigdata application and artificial intelligence.



徐大为(1989—),男,博士,CCF专业会员,主要研究方向为人工智能、自然语言处理。

XU Dawei, born in 1989, Ph.D., professional member of CCF. His research interests includes artificial intelligence and natural language processing.



贾勇哲(1987—),男,博士,CCF专业会员,主要研究方向为人工智能、先进制造业。

JIA Yongzhe, born in 1987, Ph.D., professional member of CCF. His research interests includes artificial intelligence and advanced manufacturing.