

一种引入核心实体关注度评估的KBQA算法

赵卫东, 晋艳峰, 张睿, 林沿铮

引用本文

赵卫东, 晋艳峰, 张睿, 林沿铮. 一种引入核心实体关注度评估的KBQA算法[J]. 计算机科学, 2024, 51(11): 239-247.

ZHAO Weidong, JIN Yanfeng, ZHANG Rui, LIN Yanzheng. [KBQA Algorithm Introducing Core Entity Attention Evaluation](#) [J]. Computer Science, 2024, 51(11): 239-247.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于弱监督语义分割的道路裂缝检测研究](#)

Study on Road Crack Detection Based on Weakly Supervised Semantic Segmentation

计算机科学, 2024, 51(11): 148-156. <https://doi.org/10.11896/jsjcx.231000148>

[重参数化增强的双模态实时目标检测模型](#)

Re-parameterization Enhanced Dual-modal Realtime Object Detection Model

计算机科学, 2024, 51(9): 162-172. <https://doi.org/10.11896/jsjcx.230700106>

[任务感知的多尺度小样本SAR图像分类方法](#)

Task-aware Few-shot SAR Image Classification Method Based on Multi-scale Attention Mechanism

计算机科学, 2024, 51(8): 160-167. <https://doi.org/10.11896/jsjcx.230500171>

[基于多任务联合训练的长文本多实体情感分析](#)

Long Text Multi-entity Sentiment Analysis Based on Multi-task Joint Training

计算机科学, 2024, 51(6): 309-316. <https://doi.org/10.11896/jsjcx.230400001>

[面向多重属性的区块链去中心化程度度量模型](#)

Multi-attribute Blockchain Decentralization Degree Measurement Model

计算机科学, 2024, 51(5): 382-389. <https://doi.org/10.11896/jsjcx.230300076>

一种引入核心实体关注度评估的 KBQA 算法

赵卫东 晋艳峰 张睿 林沿铮

复旦大学软件学院 上海 200433

上海市数据科学重点实验室 上海 200433

摘要 摘要目前针对复杂语义和复杂句法的知识库问答(Knowledge Base Question Answering,KBQA)研究层出不穷,但它们多以已知问题的主题实体为前提,对问题中多意图和多实体重视不足,而问句中核心实体的识别是理解自然语言的关键。针对此问题,提出了一种引入核心实体关注度的 KBQA 模型。该模型基于注意力机制及注意力增强技术,对识别到的实体引用(Mention)进行重要性评估,得到实体引用关注度,去除潜在干扰项,捕获用户提问的核心实体,解决了多实体、多意图问句的语义理解问题。此外,还将评估的结果作为重要权重引入后续的问答推理中。在英文 MetaQA 数据集、多实体问句 MetaQA 数据集、多实体问句 HotpotQA 数据集上,与 KVMem,GraftNet,PullNet 等模型进行了对比实验。结果表明,针对多实体问句,所提模型在 Hits@n、准确率、召回率等评估指标上均取得了更好的实验效果。

关键词: 知识库问答;意图识别;实体关注度;多实体;多意图

中图分类号 TP391

KBQA Algorithm Introducing Core Entity Attention Evaluation

ZHAO Weidong, JIN Yanfeng, ZHANG Rui and LIN Yanzheng

School of Software, Fudan University, Shanghai 200433, China

Shanghai Key Laboratory of Data Science, Fudan University, Shanghai 200433, China

Abstract There are numerous knowledge base question answering(KBQA) researches on complex semantics and complex syntax, but most of them are based on the premise that the subject entity of the question has been obtained, and insufficient attention has been paid to the multi-intentions and multi-entities in the question, and the identification of the core entity in the interrogative sentence is the key to natural language understanding. To address this problem, a KBQA model introducing core entity attention is proposed. Based on the attention mechanism and attention enhancement techniques, the proposed model assesses the importance of the recognized entity mention, obtains the entity mention attention, removes the potential interfering items, captures the core entity of the user's question, so as to solve the semantic understanding problem of multi-entity and multi-intention interrogative sentences. Evaluated results are introduced into the subsequent Q&A reasoning as importance weights. Finally, comparative experiments are conducted with KVMem, GraftNet, PullNet and other models in English MetaQA dataset, multi-entity question MetaQA dataset, and multi-entity question HotpotQA dataset. For multi-entity question, the proposed model achieves better experimental results on Hits@n, accuracy, recall and other evaluation indexes.

Keywords Knowledge graph question answering, Intention recognition, Entity attention, Multi-entity, Multi-intention

知识库问答(KBQA)是在现有的知识库基础上,以知识库(Knowledge Base, KB)中的知识为来源,回答自然语言问题^[1]。现有关于 KBQA 的研究集中在语义或句法复杂的问题上,尤其是多跳 KBQA 问题。这类研究通常以获取到问句的主题实体为前提,对句式或语义复杂的问句进行解析,从知识库中寻找正确答案。而在实际的业务场景下,用户提问的意图可能并不是单一的,用户的提问中可能包含多个意图或多个实体,只有少部分实体才是用户提问的核心意图。

项目场景下的 KBQA 问题进行研究,基于 KBQA 信息检索方式的管道(Pipeline)探索研究了一种引入核心实体关注度的 KBQA 算法。该算法利用注意力机制创新性地对问句中出现的实体重要性进行评估,以捕获用户提问的核心实体,突出解决多实体、多意图问句的语义理解问题。

考虑到实际业务场景下问句的复杂性,本文针对企业项目场景下的 KBQA 问题进行研究,基于 KBQA 信息检索方式的管道(Pipeline)探索研究了一种引入核心实体关注度的 KBQA 算法。该算法利用注意力机制创新性地对问句中出现的实体重要性进行评估,以捕获用户提问的核心实体,突出解决多实体、多意图问句的语义理解问题。

本文模型主要由 3 部分构成,分别是核心实体关注度评估、知识表示学习与答案初筛、答案推理重排序。核心实体关注度评估阶段,通过解析问句中的实体引用,并基于实体关注度模型对实体引用进行关注度计算。首先使用 RoBERTa 模型

考虑到实际业务场景下问句的复杂性,本文针对企业

到稿日期:2023-10-07 返修日期:2024-04-04

基金项目:国家自然科学基金(71971066)

This work was supported by the National Natural Science Foundation of China(71971066).

通信作者:赵卫东(wdzhao@fudan.edu.cn)

对问句进行表征,再基于注意力机制以及注意力增强方法,获取问句对不同实体 Token 的关注程度分布,并将关注度作为重要权重输入到推理阶段中,使得句子的干扰信息得以减弱,重要信息得以加强。知识表示学习与答案初筛阶段,模型基于 Complex Embeddings (complEx) 算法^[2],将知识图谱中存在的实体和关系在连续的低维向量空间中进行嵌入,完成对知识图谱的表示学习,同时基于答案初筛模块中训练的排序函数获得的三元组得分排序实现答案三元组的初步筛选。答案推理重排序阶段,在弱监督情况下,通过考虑问题中核心实体周围的语义分布和核心实体到答案实体的关系路径来提高推理的精度。本阶段模型通过伪孪生网络实现,两个网络对问句和候选答案集合中的三元组链路分别进行表征,并融合核心实体关注度评估阶段的特征,进行答案推理结果三元组的重排序。对问句的表征向量表示,首先通过对 RoBERTa 模型的微调,实现问句编码的语义嵌入,用于下游任务的输入;接着引用 BiLSTM,对向量 Token[CLS]进行特征增强;最后通过全连接层,将处理过的[CLS]向量压缩到与 KG 处理部分输出的向量相同的维度,进而得到问句向量。对知识图谱的表征向量表示,首先使用知识表示学习模型中得到的实体和关系嵌入,对知识图谱中的三元组关系进行 Embedding;接着送入 BiLSTM 表征层得到一个关系内容向量;再将该关系内容向量与上游问句理解模型得到的前期特征,包括多实体问句中各实体的重要性评估得分以及问句中实体与知识库中的实体语义相似度计算得分,共同进行注意力计算,最终获取到融合核心实体关注度特征的知识图谱的向量化表示。

本文将上游任务的输出结果保留,并将其作为重要特征输入到答案推理重排序模型中,使用核心实体关注度与实体链接得分对后续的推理过程进行标注。即使上游任务对 Top1 的实体引用识别错误或实体消歧任务给错误实体赋予了最高得分,通过答案推理重排序模型,依然可以对这些实体所在的错误三元组进行筛选和剔除,使得正确的三元组作为答案项返回。核心实体关注度评估、知识表示学习与答案初筛、答案推理重排序这 3 个模块的有效组合改善了 KBQA 任务的整体表现。

1 相关工作

KBQA 解决方案存在两种主流方法,分别是基于语义解析的方法 (Semantic Parsing, SP)^[3] 和基于信息检索的方法 (Information Retrieval, IR)^[4]。它们在解决 KBQA 任务中使用了不同的工作机制。前者旨在将自然语言问句解析为逻辑形式,并在知识库上执行该逻辑形式以找到答案;而后者检索一个特定于问题的图,并应用一些排序算法从最高位置选择实体。

基于语义解析的方法,主要包括问题理解、问题逻辑解析、知识库逻辑转化这几个步骤。对于复杂的 KBQA 问题,该方法在复杂语义理解、复杂查询解析以及知识库实例化搜索方面面临很大挑战。首先对于复杂问题的语义理解,生成式句法分析的准确率表现一般。为了减弱从句法分析阶段到下游语义分析阶段的错误传播,Sun 等提出了一种基于骨架的句法分析方法,对复杂问题的主干进行解析^[5]。Zhu 等

通过引入结构感知的特征编码器,利用句法逻辑形式的结构属性对候选解析进行排名^[6]。Mahehwarri 等应用细粒度槽位匹配,以及添加关于查询结构的约束过滤噪音查询,进而改善问句与逻辑形式之间的匹配^[7]。

在复杂查询的句法分析环节,传统的语义句法分析方法在简单问题的语义分析上表现良好。然而,由于本体不匹配等问题,这些方法在复杂问句上的表现并不那么尽如人意^[8],因此,有必要利用知识库的结构进行更准确的解析。为了覆盖复杂问题,研究者将不同的表达逻辑形式作为目标。Bast 等设计了 3 个查询模板,可以涵盖查询 1-hop 关系、2-hop 关系和单约束涉及关系的问题^[9]。虽然该方案能够解析几种类型的复杂问句,但仍然存在覆盖范围有限的问题。Yih 等提出将问题解析成一个查询图,在复杂的 KBQA 任务中,这种查询图表现出了很强的表达能力^[10]。但是,由于查询图是由预定义好的人工规则生成的,因此并不适用于大规模数据集以及长尾复杂问题。

对于知识库实例化搜索,当知识库较为丰富时,一个实体节点可能链接到数百甚至数千条边,因此一个复杂问题建立所有可能的逻辑形式代价较大。针对上述问题,Zheng 等提出复杂问题分解的方案,将复杂问题拆解成简单问题,再将每个简单问题解析成一个简单的逻辑形式并用于生成中间答案,最终联合得到最终答案。该方式有效地缩小了在知识库中的搜索空间^[11]。Bhutani 等利用依赖关系减少了人工标注,从而有效缩小了搜索空间^[12]。另外,Beam Search 也是一种缩小搜索空间的方法。Chen 等采用逐次贪婪搜索策略,获取最可能的子图,基于此子图再进行扩展,直至得到最优子图^[13]。Lan 等提出了一种迭代匹配模块,在每个搜索步骤中无需重新访问生成的查询图即可对问题进行解析^[14]。

当前基于语义解析的方法在不断优化和提升,一定程度上满足了用户个性化精准问答需求,但在关系分类的标注上仍会消耗大量人力,以及难以预测训练集中未出现的关系,这在问答知识库中关系不完善时会对话答系统准确率和 Hits@1 指标造成较大影响。

基于信息检索的方法的核心是使用问题中传达出的信息,从知识库中检索并排序,生成答案。该方法主要包含知识图提取、问题表示、基于图的路径推理、路径排序这几个步骤。对于复杂的 KBQA 问题,该方法主要面临不完整知识库推理、复杂自然语言理解、推理过程的可解释性等方面的挑战。

为了应对不完整知识库推理这一挑战,研究人员利用辅助文本,提供广泛的知识作为补充知识。Sun 等提出使用问题相关的文本语料,对不完备知识库进行补充,与知识图谱形成一个异构图,并基于该图进行推理^[15]。Xiong 等在实体表示中通过融合额外的非结构化文本,来取代直接将非结构化文本作为知识节点补充到图中的做法^[16-17]。除了引入额外的文本语料外,还可以采用知识图谱嵌入的方法,通过链接预测 (Linking Prediction) 对缺失和隐含的关系进行表示。Saxena 等利用预先训练的知识图谱嵌入来丰富不完整知识图谱中的实体表示,从而解决知识库不完整问题^[18]。

对于复杂自然语言问题的理解这一挑战,先将问题转化为低维向量从而生成推理指令。但是该方法生成的推理指令

是静态的,并不一定能有效地表示复杂问题的组合语义。后来有学者利用在子图检索中获取到的信息对推理指令进行更新操作,在推理阶段采用动态更新指令的方式来弥补上述缺陷。除此之外,He 等还提出使用动态注意力机制来关注问题的不同部分,从而实现动态指令的修改^[19]。这种机制可以促使模型注意到问题其他部分的信息,并且这部分信息将会在推理阶段提供适当的指导。其次,传统的基于信息检索的方法的推理过程往往缺乏可解释性。Zhou 等提出从预定义的记忆模块中输出中间预测,并作为推理路径的解释^[20-21],这些中间预测通常是匹配的关系或实体,从而在每一跳中可以追溯和观察实体和关系。

相比语义解析的方法,基于信息检索的方法在路径生成方面具有更强的泛化能力,能够更好地应对多跳问题。但是此类研究往往基于完善的知识库,即在已标注了核心实体的复杂问句上进行问答的实现。另外,其对语义关系信息的利用不够充分,忽略了实际应用场景中知识图谱的稀疏性,以及实际场景用户提问形式的复杂多样性,对工业界实际应用中存在的多意图、复杂问句类型以及成分语义等难以理解。因此需要优化和提高多意图、复杂句型等问题下知识图谱问答的准确率以及多轮问答 KBQA 的准确率。

随着硬件性能的提升和分布式计算技术的发展,大模型的规模持续增长。自 2022 年 ChatGPT 横空出世,国内外各大科技企业开始了制造 AI 大模型的热潮^[22]。2023 年 9 月,百度正式发布国内首个“产业级”医疗 AI 灵医大模型;同年 9 月,华为云发布盘古古医学大模型,该模型能有效支撑医学检验、临床辅助诊疗、个人健康管理等场景应用;同年,腾讯云在南京发布国内首个金融行业大模型,其可以为金融行业客户提供一站式 MaaS(Model as a Service)服务,并支持金融客户构建自己的专属大模型;蚂蚁财富发布智能理财助理支小宝 2.0,实现了国内大模型在金融垂直领域的首次应用落地^[23]。

大模型能够处理更复杂的语境,理解和生成更自然、更具上下文连贯性的答案。大模型在训练时涵盖大量的互联网文本,不需要人为设计特定的问题模板或预定义的规则,可回答各主题的问题。但是大模型的工作原理相对复杂,生成的答案可解释性差。另外,大模型是基于统计学习的,某些情况下会给出不准确的答案,尤其在涉及特定领域的深度知识时。

相比大模型问答,KBQA 是基于预定义的、经过验证的知识构建而成,因此能够提供更准确、更可靠的答案。另外,由于 KBQA 答案来自预定义知识库,可追踪到具体的信息来源,因此,其生成的答案可解释性强,较适用于特定领域内专业知识的问答。但是 KBQA 也存在不足,其受限于知识库,无法回答超出知识库范围的问题。另外,为了确保信息的实时性和准确性,知识库需要不断更新和维护。

综上,大模型问答在处理开放领域的问题时效果更优,而 KBQA 更适合特定领域,在特定领域内 KBQA 能得到更准确、更可靠的回复。考虑到本研究基于实际企业应用场景,属于特定领域,知识库相对封闭和固定,对问答回复的精准性和可解释性要求较高,因此本文研究选用 KBQA 方式来实现。

本文针对企业场景下的 KBQA 问题进行研究,探索了一种引入核心实体关注度评估的 KBQA 算法,突出解决多意图

多实体问句解析问题。该算法通过核心实体关注度评估,赋予每个实体引用以及每个实体引用的链接结果,并将赋予作为重要信息融入到问答推理阶段。通过横向模型对比和消融实验,证明了该算法的有效性。

2 问题定义

实际业务场景下,请求方提供的大多是一个不带主题实体标注的问题集,因此需要进行问句的语义理解,获取问题真正的主题实体和意图。语义理解阶段的性能指标会直接影响到最终的问答结果,尤其是复杂的问句句式或问句中出現多个实体项。语义理解往往成为限制 KBQA 性能的主要原因。

定义 1(核心实体) 对于问句中的所有实体引用,核心实体指向问句所针对提问的实体,即用户提问的真正意图。

定义 2(实体关注度) 实体关注度用来衡量一个问句对问句中出现的不同实体引用的关注程度,是一个介于 0~1 的值。每个引用通过关注度计算都将获得一个关注度值,关注度值越大,则该实体引用更可能作为问句所提问的对象。当句子中仅出现一个引用时,该引用的关注度为 1。

定义 3(关注度计算) 计算过程分为 3 个阶段:

1) 第一阶段的主要目标是计算 Query 和某个 Key 的相似性或相关性,通常会采用点积(Dot Product)计算法、余弦距离计算法、多层感知机(MLP)网络求相似性,计算式分别如式(1)~式(3)所示:

$$\text{Similarity} = \mathbf{Q} \cdot \mathbf{K}_i^T \quad (1)$$

$$\text{Similarity}(\mathbf{Q} \cdot \mathbf{K}_i) = \frac{\mathbf{Q} \cdot \mathbf{K}_i^T}{\|\mathbf{Q}\| \cdot \|\mathbf{K}_i\|} \quad (2)$$

$$\text{Similarity}(\mathbf{Q} \cdot \mathbf{K}_i) = \text{MLP}(\mathbf{Q} \cdot \mathbf{K}_i) \quad (3)$$

2) 第二阶段的目标是对第一阶段的相似性得分进行归一化,通常采用类似于 Softmax 函数的计算方式,该计算方式的优势在于将相似度归一化到域值为[0,1]区间的同时,通过自然对数底数,可以更加突出重要元素的权重。该函数采用式(4)进行计算。

$$a_i = \frac{e^{sim_i}}{\sum_{j=1}^l e^{sim_j}} \quad (4)$$

3) 第三阶段的目标是将计算得到的注意力权重与句子不同部分的信息 Value 进行加权求和,通过加权求和获取句子的注意力分布,如式(5)所示:

$$\text{Attention}(\mathbf{Q}) = \sum_{i=1}^l a_i V_i \quad (5)$$

定义 4(评估指标 Hits@n) 该指标衡量在所有验证集中得分最高的 Top-n 实体中存在正确答案的比率。当 n=1 时,得分最高的实体被认为是答案,如果该答案与正确答案相同,则将该预测过程视为正确的预测过程,反之则认为这是一次错误的预测。Hits@n 指标的计算式如式(6)所示:

$$\text{Hits}@n = \frac{1}{|S|} \sum_{i=1}^{|S|} II(\text{rank}_i \leq n) \quad (6)$$

其中,S 为三元组集合;|S| 为三元组 S 集合个数;II(·) 为 Indicator 函数,若第 i 个三元组的排序在预先设置的前 n 名之内,则函数值为 1,否则为 0。

3 核心实体相关问题分析

本文引入核心实体关注度评估的 KBQA 算法,突出解决

多实体问句理解问题。通过核心实体关注度评估,对每个实体引用及其链接结果进行赋分,并且将赋分作为重要信息融入问答推理阶段。引入核心实体关注度评估的 KBQA 算法的整体框架如图 1 所示。

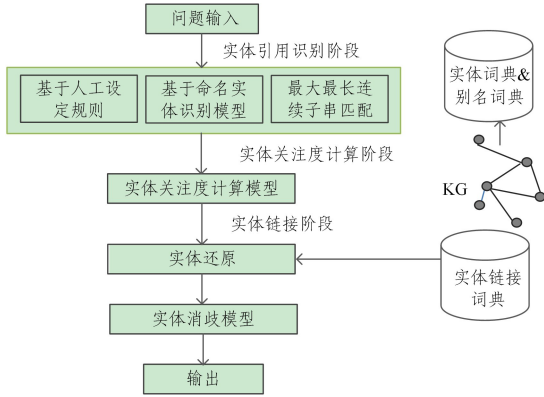


图 1 KBQA 算法的框架图

Fig. 1 Framework diagram of KBQA algorithm

整个流程包括实体引用识别、实体关注度计算和实体链接。首先,采用基于规则、基于最大最长词典匹配、基于命名实体识别(NER)模型的方式联合查找实体提及候选项,实现实体引用识别;然后,基于获取到的核心实体进行核心实体关注度计算,并对得到的实体引用进行实体链接,进而展开后续的推理环节。本章将详细阐述引入核心实体关注度评估的 KBQA 算法的具体实现细节。

3.1 实体引用识别

对问句进行实体引用识别:

1) 基于人工设定规则进行实体引用抽取

基于问句中某些特定特征提取子串,并存储至候选实体引用集合 Me_1 中。特定规则包括:书名号、引号所包含的字符串;特定日期、时间信息;特定地点、地名、专业术语名词。

2) 基于命名实体识别进行实体引用抽取

目前预训练语言模型 BERT 已经在多数自然语言处理任务中取得了很好的成绩。考虑到 BERT 是基于通用领域语料库训练的,研究者又采用专业语料库对其进行了微调。例如,生物学领域的 BioBERT 模型在医学领域相比 BERT 取得了更优的成绩^[24]。然而,目前基于 Transformer 架构的预训练模型并没有与知识库中结构化的领域知识进行有效融合;而企业特定领域常存在固定术语,直接采用现有通用领域训练的 BERT 预训练语言模型进行命名实体识别,无法准确提取此类固定术语实体引用。因此,可以考虑将已知的专家领域知识注入到预训练模型中,通过引入先验知识来提高模型抽取实体关系的准确性。

基于此,本文提出了融合领域特征编码技术,整合已有领域的结构化知识对应的三元组和人工标注的训练集对应的三元组作为先验知识库,采用知识图谱嵌入技术并基于 Complex Embeddings(complEx)算法把实体和关系嵌入到低维向量空间来表示图谱中头尾实体、关系的语义结构信息。

将三元组的先验知识特征表示向量记为 pre 。句子序列经过预训练模型 BERT 得到的语义特征向量记为 h 。将先验知识特征 pre 与语义特征向量 h 拼接,得到融合特征向量,

最后得到融合了特定领域先验知识的句子序列特征向量表示,提高了领域文本语义特征表示的准确性。

本文基于 BERT 预训练语言模型进行实体引用抽取。对于每个字(词),基于 BERT 的字典对问句文本进行索引编码,将文字转化为 Token,并与领域先验知识特征 pre 进行拼接,然后在模型的嵌入层将文本表示为多维向量,再使用全连接层进行 Token 级别的二分类,从而实现对问句文本的标注。其中,可能作为实体引用词的 Token 标注为 1,反之则标注为 0。如式(7)和式(8)所示:

$$p = FC(BERT(question) + pre), p_i \in (0, 1) \quad (7)$$

$$out_i = \begin{cases} 1, & p_i > \gamma_1 \\ 0, & p_i \leq \gamma_1 \end{cases} \quad (8)$$

对于标注完的问题 $question$,若存在标注为 1 的连续字符,则取连续字符的标注概率 p_i 的平均值 γ_1 ,查看其是否超过阈值。若超过,则将该连续字符文本存储至候选实体引用集合 out_i 中;反之,则丢弃。

3) 最大最长连续子串匹配法

长到短分别获取到问题的连续子字符串,若该子串能和知识库实体集合的某个实体或某个实体别名完全匹配,则将其提取到集合 Me_3 中。

经上述 3 种方法得到了 3 个候选实体集合 Me_1, Me_2, Me_3 ,最终将这 3 个集合取并集,即得到最终的实体引用集合 Me 。

3.2 核心实体关注度计算

在上一阶段获取到实体引用之后,基于实体关注度模型进行实体关注度计算。该模型计算主要包括 4 个步骤:词嵌入、实体关注度计算、局部注意力增强、池化与输出。算法的伪代码如算法 1 所示。该模型结构如图 2 所示。

算法 1 核心实体关注度计算

```

1. for all Q ∈ problemSet do
2.   for all m ∈ MeQ do
3.     for index, value in enumerate(m):
4.       idx.add(index);
5.     end for
6.     Q' = RoBERTa(Q)
7.     vqa = w1T Q' + b1
8.     vqb = w2T Q' + b2
9.     for all i, j ∈ [1, |I|] do
10.      if(i ∈ idx)
11.        aij = vqaiT * vqbjT
12.      else
13.        aij = 0
14.      end for
15.     Aq' = {mij | mij = ∑j=1|I|  $\frac{e^{a_{ij}}}{\sum_{k=1}^{|I|} e^{a_{ik}}}$  bj, i ∈ [1, |I|]}
16.     Aq'' = Concatenate()(Aq'; Aq; Aq' · Aq; Aq - Aq')
17.     mq = Concatenate()(Maxpooling(Aq''); Avgpooling(Aq''))
18.     αq = FC(mq)
19.   for all m ∈ MeQ do
20.     Aq = {aij | aij

```

$$= \begin{cases} v_{q_{a_i}} \cdot v_{q_{b_j}}^T, & \text{The Token at position } i \text{ belongs to Mention Token} \\ 0, & \text{The Token at position } i \text{ is not Mention Token} \end{cases}$$

$$i, j \in [1, l];$$

21. end for
22. End for

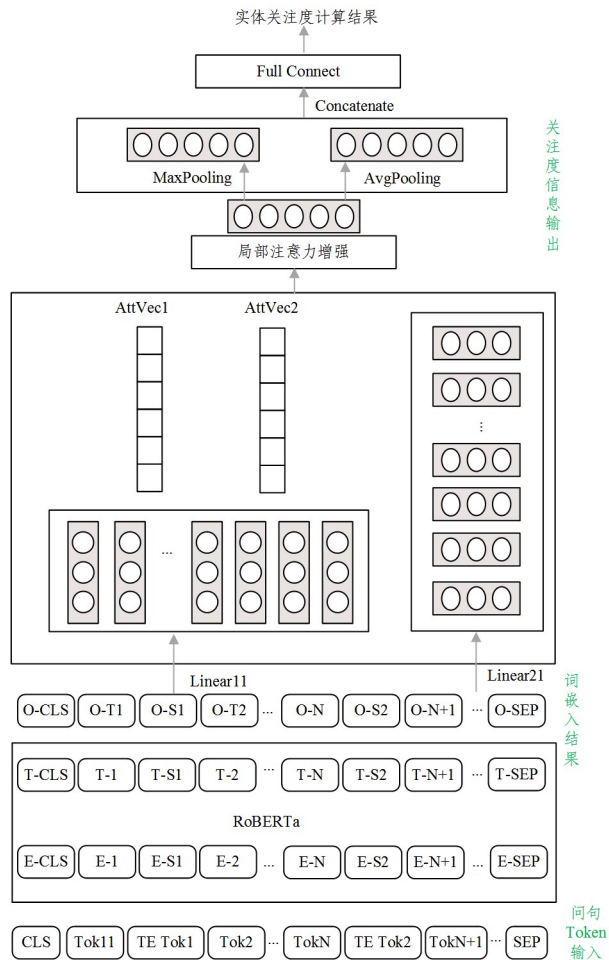


图2 实体关注度计算模型

Fig. 2 Entity attention calculation model

1) 词嵌入

首先对文本 Q 进行 Tokenize, 将文本中的所有字符/单词转化为 Token 形式。在该过程中, 问句中所有实体引用的 Token 将被特殊标注, 如图 2 所示, 实体引用对应的 Token 为 TE Tok1 和 TE Tok2。然后使用 RoBERTa 模型完成词嵌入, 获取问句 tokens 的 Embedding, 将其记作 Q' 。

2) 实体关注度计算

将问句 tokens 的 Embedding Q' 复制成两份, 分别经过 Linear1 和 Linear2 两个线性变换, 变换为 v_{q_a} 和 v_{q_b} , 如式(9)和式(10)所示。 v_{q_a} 作为被匹配的目标, 仅计算其中 Mention Token 位置的注意力值。若一个实体跨越了多个 Token, 则计算多个 Token 的注意力向量并取平均值作为该实体引用的注意力向量, 如式(11)所示。其中, a_{ij} 为每个位置的注意力值, l 是句子的长度。在注意力值计算阶段, 本文选用了点积计算方法, 相比余弦距离、拼接计算注意力值等方法, 当其中一个向量是一维向量时, 点积计算方法最为直观、可解释性最强。

$$v_{q_a} = w_1^T Q' + b_1 \quad (9)$$

$$v_{q_b} = w_2^T Q' + b_2 \quad (10)$$

$$A_q = \{a_{ij} \mid a_{ij} = \begin{cases} v_{q_a} \cdot v_{q_b}, & i \text{ 位置的 Token 属于 Mention Token} \\ 0, & i \text{ 位置的 Token 不属于 Mention Token} \end{cases}, i, j \in [1, l]\} \quad (11)$$

得到注意力值之后, 基于最大熵原理选用自然对数 e 为底数对句子的注意力分布进行计算, 如式(12)所示。这样做的优势是可使每个 Token 位置预测的概率是非负数, 并且所有 Token 位置的概率之和为 1, 能够直观地表达出句子对实体引用的注意力值。经过该步骤计算可初步得出每一个实体引用位置的注意力信息, 并将其施加到原问句中。

$$A_q' = \left\{ m_{ij} \mid m_{ij} = \frac{\sum_{j=1}^l \frac{e^{a_{ij}}}{\sum_{k=1}^l e^{a_{ik}}} b_j, i \in [1, l] \right\} \quad (12)$$

3) 局部注意力增强

针对步骤(2)中得到的 A_q 和 A_q' , 在本步骤通过点乘、求差、拼接的方式对局部信息进行注意力增强, 如式(13)所示:

$$A_q'' = \text{Concatenate}() (A_q'; A_q; A_q' \cdot A_q; A_q - A_q') \quad (13)$$

4) 池化与输出

针对步骤(3)中得到的向量 A_q'' , 在本步骤中通过池化层获取每个实体引用的注意力分布信息, 池化采用了最大池化(Maxpooling)和平均池化(Avgpooling)的拼接, 以尽可能保留注意力信息。最终映射成与句子长度相等维度的向量。在每个句子中, 标注不同实体引用的关注度, 并且取关注度最大的实体引用暂时作为该问句的核心实体, 如式(14)和式(15)所示:

$$m_q = \text{Concatenate}() (\text{Maxpooling} (A_q''); \text{Avgpooling} (A_q'')) \quad (14)$$

$$\alpha_q = \text{FC}(m_q) \quad (15)$$

本文使用 Adam 作为神经网络的优化器。相较于随机梯度下降法(SGD)和批梯度下降法(BGD), Adam 在梯度震荡方向上受到的影响更小, 从而使得学习速率和学习方向上都有较大的改进; 相较于 Adagrad 算法, 在累计平方梯度的计算中, Adam 引入了一个衰减的修正系数, 以解决 Adagrad 在正确梯度上学习速率较慢的问题; 相较于 RMSProp 算法, Adam 引入了一个估计值, 避免了优化冷启动的问题^[25]。

3.3 实体链接

在经过核心实体关注度计算后, 系统得到了每个实体引用的关注度得分。但由于部分数据集, 尤其是在中文场景下, 实体引用与知识库中的实体并不一定是完全对应的, 甚至存在一个实体引用对应多个实体项的问题, 因此需要进行实体链接。本文的实体链接方案步骤如下:

- 1) 基于实体库进行实体还原;
- 2) 基于实体链接词典, 找到每个实体引用对应的一个或多个具体实体项;
- 3) 将原问句与实体的具体描述做语义相似度计算。

其中, Me_1 是每个实体引用, Q 是原问句, T_i 是每个具体实体项。对于每一个实体引用, 通过相似度计算得到一个分数值, 将模型得分最高的作为该实体引用对应的候选实体并

保留得分,同时保留得分较高的5个实体,当实体链接模型的消歧任务出错时,可以通过后续的答案推理重排序模型进行纠正。语义相似度计算方案采用BERT+FC模型,实体消歧模型基于二分类的思想。另外,为防止歧义项过多导致正负样本严重失衡的问题,在模型训练时,选取正确的实体项作为正例,从链接到的其他实体中选取两个实体作为负例。在模型训练时,将问句查询文本作为input1,将待消歧实体的描述文本作为input2,输入到BERT模型中,取CLS位置向量作为BERT的输出。将CLS位置的向量经过全连接层,最后通过Sigmoid激活函数,得到候选实体的消歧得分。对所有候选实体的消歧得分进行排序并保留,作为特征输入下游推理模块中。

综上,经过核心实体关注度评估,系统对问句进行实体识别、核心实体关注度计算、实体链接操作,并基于已获取到的实体项与实体项之间的相关信息,为KBQA下一阶段在知识图谱中寻找相关的事实做准备。

4 实验

本章将详细介绍引入核心实体关注度评估算法的实验效果,具体包括实验数据准备、超参数设置、实验对比、实验结果及分析。

4.1 数据集

部分数据来源于开源数据集MetaQA(Movie Text Audio QA)。该数据集包含1-hop,2-hop,3-hop 3个数据集。这3个部分QA数据的主要来源是Facebook MovieQA。1-hop,2-hop,3-hop训练数据集问答数据条目数分别为208970,231844,227060,验证数据集的数据条目数分别为9992,14872,14274,测试数据集的数据条目数分别为9947,14872,14274。

由于MetaQA数据集问句中的Topic Entity已经被标注,因此为了验证本文核心实体关注度评估模型的有效性,本文所用数据将去除MetaQA数据集上的问句标注,并基于以下步骤,构造多实体问句。

步骤1 剔除答案中含有两个以上实体节点的问句。

步骤2 按照字符串匹配规则,将问句转化为陈述句,将陈述句集合进行存储,命名为Description集,将原问句命名为Question集。

步骤3 对Question集中的某一问句Q,通过遍历知识图谱,寻找与核心实体有关联的实体,命名为关联实体CE,并定义与核心实体存在5跳以内关系的实体作为有关联的实体。

步骤4 从陈述句集合中,取CE所在的若干句子作为陈述句集合,记为DescriptionCE集合。

步骤5 按照如下的4种计算规则,组合 $q \in \text{DescriptionCE}$, $d \in \text{DescriptionCE}$,生成问句并保存到多实体问句集合中。

- 1)用and连接前后句: q and d ?
- 2)用and连接前后句: d and q ?
- 3)用but连接前后句: d but q ?
- 4)用while连接前后句: q while d ?

最终生成了一组多实体问句,该多实体问句训练集的规模为800000条问答数据,按照8:1:1的比例划分为训练集、验证集和测试集。

为避免预测存在的偶然性以及MetaQA数据集部分多实体构造存在的不合理性,引入了HotpotQA(Hotpot Question Answering)数据集,进一步验证本文所提算法的有效性。

HotpotQA数据集包含来自Wikipedia的问题和答案,问题类型和答案形式多样,包括科学、历史、艺术等多个领域的知识。HotpotQA数据集中的问题通常涉及多个实体,能够测试模型对多实体问题的推理能力和对复杂问题的理解能力。为了进一步验证本文提出模型在特定领域多实体问题上的推理能力,选取HotpotQA中的艺术领域数据集作为本实验研究数据集。HotpotQA数据集共包含了112779个问题和答案对,其中艺术领域占8%,共9022个问答对。同样将其按照8:1:1的比例划分为训练集、验证集和测试集。

4.2 对比实验

本节将分别在MetaQA和HotpotQA数据集上将本文方法与目前先进方案模型进行对比分析。

1)单实体问句

评估指标采用Hits@1指标,在MetaQA原数据集和原知识库上,对MetaQA测试集的1-hop,2-hop,3-hop问句分别进行评估,如表1所列。

表1 在MetaQA原数据集上的Hits@1评估结果
Table 1 Hits@1 evaluation results on original MetaQA dataset (%)

方法	1-hop	2-hop	3-hop
KVMem	96.2	82.7	48.9
GraftNet	97.0	94.8	77.7
PullNet	97.0	99.9	91.4
EmbedKGQA	97.5	98.8	94.8
TransferNet	97.5	<u>100.0</u>	<u>100.0</u>
本文算法	99.1	99.7	99.4

表1中,加粗部分代表本文模型的评估结果,加下划线的数据为实验的最优结果。可以看出,本文提出的模型在MetaQA单实体问句的语境下,能够在1-hop,2-hop,3-hop问句上取得较优的表现。而相较于目前在MetaQA数据集上表现最好的TransferNet模型,本文模型在单实体问句上的表现还略有不足。TransferNet模型在MetaQA数据集的2-hop和3-hop问题中实现了100%的准确率。经分析,原因在于单意图问句可能含有隐含意图,使得单意图问句转化为多意图问句,而本文模型对该部分特征尚缺乏足够的学习。

2)多实体问句

在本文构建的多实体问句数据集上对模型进行评测,评测结果如表2所列,实验结果表明,在多实体问句下引入核心实体关注度评估,模型有明显的有效性和优越性。需要说明的是,上述模型在进行评测时,对于一个 n 实体问句,会将 n 实体问句拆分成 n 个句子,每个句子对应一个核心实体,并分别计算三元组排序得分,最终取 n 个句子中得分最高值作为当前 n 实体问句模型的预测结果。

由表2可知,当问句包含两个以上实体项时,相较于直接对多实体问句进行预测,引入核心实体关注度评估后在

1-hop 问句和 2-hop 问句上 Hits@1 值均提升较大,可见引入注意力机制可以捕捉到问题和多个实体之间的关联关系,进而实现多实体关系建模。通过核心实体关注度评估能够显著提升多实体问句的问答准确率。

表 2 在多实体问句 MetaQA 数据集上的评估结果

Table 2 Evaluation results on multi-entity interrogative sentence dataset MetaQA

方法	1-hop	2-hop
KVMem	68.3	57.2
GraftNet	70.1	61.7
PullNet	68.9	70.3
EmbedKGQA	81.6	74.8
TransferNet	79.3	76.6
不引入核心实体关注度 评估的知识库问答	82.5	75.3
本文算法	91.5	89.7

与 MetaQA 原数据集相比,其他模型在多实体问句上表现较弱,在 2-hop 问句的预测上 Hits@1 值下滑更为明显。其原因在于多实体关系往往会引入更多的实体-关系信息,这些信息会构成无关的三元组,对核心语义理解造成干扰;并且此时句子语义更为复杂,若不标注侧重点而将整个句子完全输入,则语义理解和语义解析将变得更加困难。本文通过引入注意力机制找到核心实体,有助于减少信息冗余,模型可以选择性地关注问题中最相关的实体,而不必处理所有实体的信息,从而提高了模型的性能和效率。

为避免预测存在的偶然性以及 MetaQA 数据集部分多实体问题构造存在的不合理性,引入多实体 HotpotQA 艺术领域数据集进一步验证本文引入核心实体关注度模型的有效性。评估指标同样采用 Hits@1 值,在 HotpotQA 艺术领域数据集上进行评估,评估结果如表 3 所列。

表 3 在多实体问句 HotpotQA 数据集上的评估结果

Table 3 Evaluation results on multi-entity interrogative sentence dataset HotpotQA

方法	Hits@1
KVMem	63.5
GraftNet	68.1
PullNet	70.3
EmbedKGQA	78.5
TransferNet	77.9
不引入核心实体关注度评估的 知识库问答	80.8
本文算法	88.2

通过表 3 可明显看出,引入核心实体关注度评估的知识库问答在多实体问题任务上效果明显更优,相比表现较优的 EmbedKGQA 和 TransferNet 模型,其 Hits@1 值分别提高了 9.7% 和 10.3%,有效证明了引入核心实体关注度的有效性。这是因为注意力机制是自适应的,可根据问题和实体的上下文来评估实体的重要程度,从而使得模型能够根据具体问题进行动态调整,而非静态地对所有实体分配相同的权重。通过关注与答案相关的实体,模型可以更精确地提取答案信息。

多实体 HotpotQA 艺术领域数据集上的实验结果再次验证了引入注意力机制能够有效帮助模型捕捉实体之间的关联

信息,更好地处理多实体问题,自动识别问题中最重要的实体,进而提高自然语言问题理解能力。

4.3 消融实验

本节将对知识图谱问答模型进行消融实验,以验证所提出的各个模型的有效性。消融实验分别在如下几个任务上进行:实体识别、实体关注度计算、整体模型。评测指标包含准确率、召回率、F1 分数、Hits@5 和 Hits@1。

4.3.1 实体识别

本节针对核心实体关注度中实体识别的实验结果进行分析,评估实体识别中最有效的实体引用提取方案。本节对比了最大连续子串匹配、传统的命名实体识别方案、基于预训练模型的命名实体识别方案、基于 BERT 预训练语言模型的识别方法^[26]、去除领域先验知识的融合方案及本文提出的最终融合方案。采用平均准确率、平均召回率、平均 F1 分数作为对比指标,对比结果如表 4 所列。

表 4 实体识别方案实验结果

Table 4 Experimental results of entity recognition methods

方法	平均准确率	平均召回率	平均 F1 分数
最大最长词典匹配	100.0	80.4	89.1
Word2vec Embedding+ BiLSTM+CRF	85.2	80.4	82.7
BERT+BiLSTM+CRF	88.9	87.4	88.1
BERT+FC	86.2	92.1	89.0
BERT+FC+最大最长 词典匹配+规则	87.6	96.8	92.0
本文算法	90.1	97.5	93.4

对比表 4 中的 BiLSTM+CRF 和 BERT+BiLSTM+CRF 方案可以发现,BERT 预训练语言模型的实体识别任务效果在各个方面均优于 BiLSTM+CRF 模型。这是因为 BERT 模型在词嵌入过程中会通过 6 个 Transformer Encoder 计算不同上下文环境下的词向量,相较于 Word2vec Embedding 固定的词向量模型,BERT 预训练模型将同一个词在不同的语境下表示为不同的词向量,所以使用 BERT 预训练模型进行词嵌入具有较高的灵活性,能一定程度上解决一词多义问题。

由实验结果还可发现,基于 BERT 预训练语言模型的 Token 分类模型相较于 BERT+BiLSTM+CRF 有着更低的准确度和更高的召回率。原因在于,为保证 Token 分类任务的准确性,CRF 对给定的状态序列计算转移分数时,一定程度上会剔除残缺实体,而基于 BERT 预训练的 Token 分类模型通过对该模型输出的处理及对残缺抽取结果的还原和整合,使其在召回率上表现更为优秀。由于实体引用识别任务更加关注能召回的实体数量,要求不遗漏候选实体项,更加关注召回率,因此本文沿用融合领域专业知识的实体识别方案,并加入了最大连续子串匹配和规则进行联合抽取。此外,MetaQA 数据集中,由于可以通过对问句的标注得到明确的实体词典,因此可以直接采用最大连续子串匹配法识别候选实体引用。

对比去除领域先验知识的融合方案及本文提出的最终融合方案发现,引入领域先验知识,所提模型的准确率、召回率、F1 值均得到了提高。这是因为对于特定的领域,常存在固有

的一些规范化知识,而常规通用领域模型的输入部分只有字符向量的语义表征,缺少专业领域已有的实体、关系信息。通过在编码层融入领域先验知识,可有效加强输入文本序列的领域专业语义表示。因此,本文将领域知识图谱中实体关系信息作为模型先验知识,指导模型的学习过程,使得模型在实体识别任务中能够取得更优的实验效果。

4.3.2 实体关注度计算

本节对实体关注度计算模型进行实验,在基于 MetaQA 构建的多实体问句数据集上进行模型训练和评估,评估指标采用准确率。实验中,针对实体关注度计算,本文对比了 3 种实体关注度计算方法的效果,分别是 Term Weight、不采用注意力增强的实体关注度计算模型、采用注意力增强的实体关注度计算模型。实验结果如表 5 所列。

表 5 核心实体关注度的实验评估结果

Table 5 Results of experiment evaluation of core entity attention (%)

方法	准确率(MetaQA)
Term Weight	58.8
不采用注意力增强的实体关注度计算模型	82.3
本文算法	91.1

由表 5 中的实验结果可发现,相较于 Term Weight 方法,本文方法明显更优。Term Weight 方法定义实体引用为 Term,通过计算词共现关系来获取 Question 中各 term 的重要性关系。对比采用 query-doc 计算共现关系的传统 Term Weight 方法,本文方法采用包含实体引用的连续子串作为 query,对应的问句作为 doc,计算句中实体引用词的 Weight 值。Term Weight 方法表现较差的原因是其计算得到实体引用的 Weight 都比较高,通过先验数据得到的实体引用流行度依赖于语料库,而非依赖于语境下的核心实体。此外,本文通过消融实验对比了不采用和采用注意力增强机制的核心实体关注度评估模型的表现,验证了采用注意力增强机制的核心实体关注度模型的有效性。

结束语 本文提出了一种针对多实体问句的 KBQA 方法,侧重于解决多实体问句中核心实体的识别,并基于识别的结果进行后续推理任务。在问句语义理解阶段,提出了核心实体关注度评估,以解决多实体问句语义理解问题。使用 RoBERTa 模型对问句进行语义表征,并提出融合领域特征编码技术,整合已有领域的结构化知识对应的三元组和人工标注的训练集对应的三元组作为先验知识库,得到融合了特定领域先验知识的句子序列特征向量表示,提高了领域文本语义特征表示的精准性。再基于注意力机制的计算方法以及注意力增强方法,获取问句对不同实体 Token 的关注程度,从而获取句子对不同实体的关注程度分布,并将评估结果作为重要权重引入后续的问答推理中。此外,本文还提出将上阶段任务的输出结果保留,并作为特征输入到答案推理重排序模型中。本文不完全信任管道上游问句语义理解任务的输出,而是将上游任务的输出作为特征融入到下游问答推理阶段的模型中。使用核心实体关注度与实体链接得分对后续的推理过程进行标注,即使上游任务得到了错误的 Top1 实体引用或实体消歧任务给错误实体赋予了最高得分,通过答案

推理重排序模型,依然可以对这些实体所在的错误三元组进行筛选和剔除,使得正确的三元组作为答案项返回。

实际业务场景下,多实体多意图的问句往往是复杂多样的,单意图问句可能也含有隐含意图,使得单意图问句需转化为多意图问句。目前本文模型在多实体问句 Hits@n、准确率、召回率指标上相比其他模型均取得了更优的问答表现,但是在单实体问句的问答表现上,本文模型还略有不足。TransferNet 模型在 MetaQA 数据集的 2-hop 和 3-hop 问题中实现了 100% 的准确率,而本文模型分别为 99.3% 和 98.3%。后续针对单实体关系图多跳问答任务,需融合 TransferNet 模型思想进行进一步优化。同时,对单意图问句含有的隐含意图特征的学习也需要加强。此外,如何让模型加速适应不同业务场景下的语境,如何在专有领域语料不充足的情况下进行小样本学习,也是后续研究的方向。

参考文献

- [1] WANG Y, CHEN Q, HE C, et al. Knowledge base question answering system based on knowledge graph representation learning[C]//Proceedings of the 2020 the 4th International Conference on Innovation in Artificial Intelligence. 2020:170-179.
- [2] TROUILLON T, WELBL J, RIEDEL S, et al. Complex embeddings for simple link prediction[C]//International Conference on Machine Learning. PMLR, 2016:2071-2080.
- [3] AGHAEI S, RAAD E, FENSEL A. Question answering over knowledge graphs: A case study in tourism[J]. IEEE Access, 2022, 10:69788-69801.
- [4] 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.
- [5] SUN Y, ZHANG L, CHENG G, et al. SPARQA: skeleton-based semantic parsing for complex questions over knowledge bases [C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2020:8952-8959.
- [6] ZHU S, CHENG X, SU S. Knowledge-based question answering by tree-to-sequence learning [J]. Neurocomputing, 2020, 372: 64-72.
- [7] MAHESHWARI G, TRIVEDI P, LUKOVNIKOV D, et al. Learning to rank query graphs for complex question answering over knowledge graphs[C]//The Semantic Web-ISWC 2019: 18th International Semantic Web Conference, Auckland, New Zealand, October 26-30, 2019, Proceedings, Part I 18. Springer International Publishing, 2019:487-504.
- [8] REDDY S, LAPATA M, STEEDMAN M. Large-scale semantic parsing without question-answer pairs[J]. Transactions of the Association for Computational Linguistics, 2014, 2:377-392.
- [9] BAST H, HAUSSMANN E. More accurate question answering on freebase[C]//Proceedings of the 24th ACM International on Conference on Information and Knowledge Management. 2015: 1431-1440.
- [10] YIH S W, CHANG M W, HE X, et al. Semantic parsing via staged query graph generation: Question answering with know-

- ledge base[C]//Proceedings of the Joint Conference of the 53rd Annual Meeting of the ACL and the 7th International Joint Conference on Natural Language Processing of the AFNLP. 2015: 1321-1331.
- [11] ZHENG W, YU J X, ZOU L, et al. Question answering over knowledge graphs: question understanding via template decomposition[J]. Proceedings of the VLDB Endowment, 2018, 11(11): 1373-1386.
- [12] BHUTANI N, ZHENG X, JAGADISH H V. Learning to answer complex questions over knowledge bases with query composition[C]//Proceedings of the 28th ACM International Conference on Information and Knowledge Management. 2019: 739-748.
- [13] CHEN Z Y, CHANG C H, CHEN Y P, et al. UHop: An unrestricted-hop relation extraction framework for knowledge-based question answering[J]. arXiv:1904.01246, 2019.
- [14] LAN Y, WANG S, JIANG J. Multi-hop knowledge base question answering with an iterative sequence matching model[C]//2019 IEEE International Conference on Data Mining (ICDM). IEEE, 2019: 359-368.
- [15] SUN H, BEDRAX-WEISS T, COHEN W W. Pullnet: Open domain question answering with iterative retrieval on knowledge bases and text[J]. arXiv:1904.09537, 2019.
- [16] XIONG W, YU M, CHANG S, et al. Improving question answering over incomplete kbs with knowledge-aware reader[J]. arXiv:1905.07098, 2019.
- [17] HAN J, CHENG B, WANG X. Open domain question answering based on text enhanced knowledge graph with hyperedge infusion[C]//Findings of the Association for Computational Linguistics: EMNLP 2020. 2020: 1475-1481.
- [18] 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. 2020: 4498-4507.
- [19] HE G, LAN Y, JIANG J, et al. Improving multi-hop knowledge base question answering by learning intermediate supervision signals[C]//Proceedings of the 14th ACM International Conference on Web Search and Data Mining. 2021: 553-561.
- [20] 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. 2018: 2010-2022.
- [21] XU K, LAI Y, FENG Y, 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: Human Language Technologies, Volume 1. 2019: 2937-2947.
- [22] RAY P P. ChatGPT: A comprehensive review on background, applications, key challenges, bias, ethics, limitations and future scope[J]. Internet of Things and Cyber-Physical Systems, 2023, 3(4): 121-154.
- [23] ZHAO C Y, ZHU G B, WANG J Q. The Inspiration Brought by ChatGPT to LLM and the New Development Ideas of Multi-modal Large Model[J]. Data Analysis and Knowledge Discovery, 2023, 7(3): 26-35.
- [24] LEE J, YOON W, KIM S, et al. BioBERT: a pre-trained biomedical language representation model for biomedical text mining[J]. Bioinformatics, 2020, 36(4): 1234-1240.
- [25] ZHANG W, GU X, TANG L, et al. Application of machine learning, deep learning and optimization algorithms in geoengineering and geoscience: Comprehensive review and future challenge[J]. Gondwana Research, 2022, 109: 1-17.
- [26] LAN Y, HE G, JIANG J, et al. Complex knowledge base question answering: a survey[J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 14(8): 1-20.



ZHAO Weidong, born in 1971, Ph.D, associate professor. His main research interests include machine learning, deep learning and recommender systems.

(责任编辑:何杨)