



计算机科学

COMPUTER SCIENCE

文档增强型知识库问答

冯程程, 刘派, 姜琳颖, 梅笑寒, 郭贵冰

引用本文

冯程程, 刘派, 姜琳颖, 梅笑寒, 郭贵冰. 文档增强型知识库问答[J]. 计算机科学, 2023, 50(3): 266-275.

FENG Chengcheng, LIU Pai, JIANG Linying, MEI Xiaohan, GUO Guibing. [Document-enhanced Question Answering over Knowledge-Bases](#) [J]. Computer Science, 2023, 50(3): 266-275.

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)

[一种基于GRU的半监督网络流量异常检测方法](#)

Semi-supervised Network Traffic Anomaly Detection Method Based on GRU

计算机科学, 2023, 50(3): 380-390. <https://doi.org/10.11896/jsjcx.220100032>

[门控机制融合多种特征的中文事件共指消解](#)

Employing Gated Mechanism to Incorporate Multi-features into Chinese Event Coreference Resolution

计算机科学, 2023, 50(3): 291-297. <https://doi.org/10.11896/jsjcx.220700146>

[演化循环神经网络研究综述](#)

Survey on Evolutionary Recurrent Neural Networks

计算机科学, 2023, 50(3): 254-265. <https://doi.org/10.11896/jsjcx.220600007>

[一种基于三维卷积的声学事件联合估计方法](#)

Sound Event Joint Estimation Method Based on Three-dimension Convolution

计算机科学, 2023, 50(3): 191-198. <https://doi.org/10.11896/jsjcx.220500259>

[基于迁移学习和多视图特征融合提高RNA碱基相互作用预测](#)

Improving RNA Base Interactions Prediction Based on Transfer Learning and Multi-view Feature Fusion

计算机科学, 2023, 50(3): 164-172. <https://doi.org/10.11896/jsjcx.211200186>

文档增强型知识库问答

冯程程¹ 刘派² 姜琳颖¹ 梅笑寒³ 郭贵冰¹

1 东北大学软件学院 沈阳 110000

2 西湖大学工学院 杭州 310000

3 马里兰大学软件学院 马里兰州 MD20740

(fengcc121@163.com)

摘要 近年来,知识库(Knowledge Base,KB)被广泛应用于问答(Question Answering,QA)任务中。给定自然语言问题,利用知识库为给定问题提供正确答案,被称为KBQA问题。然而,知识库本身可能是不完整的(例如,KB不包含问题的答案或问题中的一些实体和关系),这限制了现有KBQA模型的总体性能。为了解决这个问题,文中提出了一个新的模型,利用文本语料库信息提供额外信息来增强知识库覆盖率和背景信息以增强问题的表示。具体来说,该模型由3个模块组成,即实体和问题表征模块、文档和问题增强表征模块以及答案预测模块。实体和问题表征模块从检索到的知识库子图中学习实体的表示,然后通过融合种子实体信息更新问题表示;文档和问题增强表征模块尝试学习与给定问题相关文档的正确表示,然后通过融合文档信息进一步改进问题表示;最后,答案预测模块根据知识库实体表征、文档表征和更新的问题表征进行答案预测。利用所提方法在WebQuestionsSP数据集上进行了大量的实验,结果表明,与其他方法相比,所提方法可以获得更高的准确性。

关键词: 知识库问答;协同注意力机制;端到端;神经网络;融合门控函数

中图分类号 TP391

Document-enhanced Question Answering over Knowledge-Bases

FENG Chengcheng¹, LIU Pai², JIANG Linying¹, MEI Xiaohan³ and GUO Guibing¹

1 School of Software, Northeastern University, Shenyang 110000, China

2 School of Engineering, Westlake University, Hangzhou 310000, China

3 School of Software, University of Maryland, Maryland MD20740, USA

Abstract Recently, knowledge base(KB) has been widely adopted to the task of question answering(QA) to provide a proper answer for a given question, known as the KBQA problem. However, knowledge base itself may be incomplete(e. g. KB does not contain the answer to the question, or some of the entities and relationships in the question), limiting the overall performance of existing KBQA models. To resolve this issue, this paper proposes a new model to leverage textual documents for KBQA task by providing additional answers to enhance knowledge base coverage and background information to enhance the representation of questions. Specifically, the proposed model consists of three modules, namely entity and question representation module, document and enhanced-question representation module and answer prediction module. The first module aims to learn the representations of entities from the retrieved subgraph of knowledge base. Then, the question representation can be updated with the fusion of seed entities. The second module attempts to learn a proper representation of the document that is relevant to the given question. Then, the question representation can be further improved by fusing the document information. Finally, the last module makes an answer prediction based on the information of knowledge base, updated question and documents. Extensive experiments are conducted on the WebQuestionsSP dataset, and the results show that better accuracy can be obtained in comparison with other counterparts.

Keywords KB-QA, Co-attention, End-to-end, Neural network, Fusion gate function

到稿日期:2022-03-02 返修日期:2022-08-28

基金项目:国家自然科学基金(61972078);沈阳市科技计划项目(21-108-9-19)

This work was supported by the National Natural Science Foundation of China(61972078) and Technology Foundation of Shenyang, China(21-108-9-19).

通信作者:姜琳颖(Jiangly@swc.neu.edu.cn)

1 引言

问答是自然语言处理(Natural Language Processing, NLP)的一项重要任务,其目的是从特定信息源检索出人类提出的给定问题的正确答案。知识库因其结构化的数据、方便查询等特点而逐渐成为 QA 任务的重要信息源。建立在知识库上的 QA 任务也称为 KBQA 任务。解决 KBQA 任务有两种主流方法,即基于语义分析(Semantic Parsing, SP)和基于信息检索(Information Retrieval, IR)的方法。基于 SP 的方法需要将自然语言问题转换为逻辑查询形式^[1-3],过程复杂。基于 IR 的方法学习给定问题和候选答案的分布式表示(以嵌入向量的形式),根据候选答案与问题的相关度评分对候选答案进行良好的排序和选择^[4-5]。本文遵循 IR 的方法来处理 KBQA 任务。

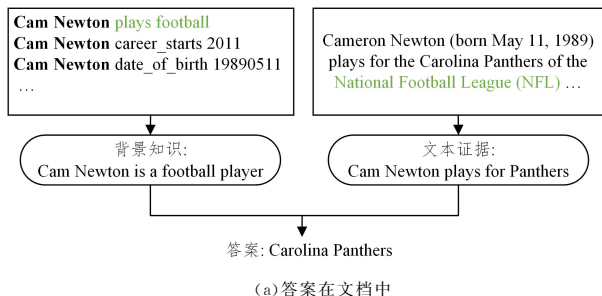
尽管知识库提供结构化数据并且便于查询,但它对事实的覆盖度有其自身的局限性,为 KBQA 方法的进一步改进留下了很大的空间。这些局限性表现在两个方面。第一,它

不能覆盖所有事实,因此我们不一定能从给定的知识库中检索到正确的答案。例如,如图 1(a)所示,对于“Which club did Cam Newton sign with?”这个问题,我们无法从给定的知识库中直接得到答案,因为没有相应的(头实体-关系-尾实体)三元组来描述这一事实。第二,可能缺乏关于问题所涉及实体/关系的必要知识,我们无法从给定知识库中找到正确答案。例如,如图 1(b)所示,对于“When did Cam Newton debut with Carolina Panthers?”这个问题,在 KB 中无法找到与“Carolina Panthers”对应的实体,尽管知识库包含正确答案 2011,但很难将“Carolina Panthers”与知识库中的实体或关系联系起来,从而导致检索失败。对于第一种情况,许多现有方法^[6-7]利用额外的文本语料库提供更多候选答案,并取得了很好的性能。然而,这些现有的方法不能很好地处理第二种情况,本文通过使用文档为答案检索提供背景信息的方式来处理此问题。本文相信额外的文本语料库不仅可以提供更多的候选答案,而且可以提供问题中实体/关系的背景信息,以便能够准确地找到正确的答案。

问题1: Which club did Cam Newton sign with?

KB子图

在文档中检索



问题2: When did Cam Newton debut with Carolina Panthers?

在KB子图中检索

文档

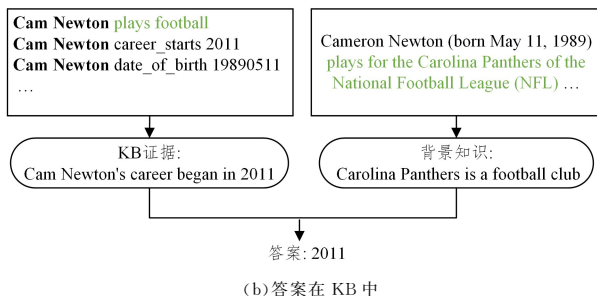


图1 不完整知识库的例子

Fig. 1 Examples of incomplete KBs

本文提出了一种新的 KBQA 解决模型,该模型利用额外的文本语料库来解决知识库不完整的问题。语料库中的文档(即句子)可以提供更多候选答案以补充知识库,并提供问题中的实体/关系的知识来为答案检索提供背景信息。具体来说,就是将额外文档中的信息融合到问题表征中,以提供更多该问题的实体/关系的相关知识。为了将相关实体和文本信息融合到问题表征,首先需要分别获得问题、实体和文档的表示。初始问题表征是通过自注意机制形成的。然后,使用问题来处理由候选实体组成的子图,以获得初步的候选实体表示。这里的子图是添加了文档片段中所链接到的实体的新的子图,具体描述见第 3 节。随后,使用融合函数将种子实体(Seed Entity)(即问题中提到的实体)信息融合到问题表示中,这是问题表征的第一次更新。文档表示的生成是通过问题和文档之间的协同注意机制来实现的。在获得文档表示后,我们通过将包含种子实体的文档表示融合进第一次更新的问题表征中来问题表征的第二次更新。最终的候选实体表示是通过连接初步候选实体表示和包含该实体的文档表示生成的。最后,我们将更新后的问题表示与最终的实体表示相匹配,以预测答案实体。

综上所述,本文的主要贡献如下:

(1)以孤立节点的形式将与问题相关的文档所链接到的实体添加到知识库子图中,使用提出的 Bground 模型学习子图

中的每个候选实体的包含邻居信息和文档句子补充信息的表征。以此实现利用额外的文档信息为给定问题提供更多候选答案的目的,从而解决知识库事实不完整的问题。

(2)采用文档作为问题中提到的实体/关系的背景知识的信息来源,将此背景知识与问题进行特征融合,以此来更好地学习问题的表征,解决缺乏问题相关背景知识导致的即使知识库中包含答案事实也无法检索到正确答案的问题。

(3)在 WebQuestionsSP 数据集上的实验结果表明,本文方法在排序准确度方面优于现有的方法。

2 相关工作

本节简要回顾文献中的相关研究,将其大致分为两类:单源 KBQA 和多源 KBQA。然后将单源 KBQA 进一步划分为简单 KBQA 和复杂 KBQA。简单 KBQA 指匹配一个(头实体-关系-尾实体)KB 三元组的 KBQA 任务,复杂 KBQA 指匹配多个三元组的 KBQA。本文中的多源 KBQA 是文档增强型 KBQA。

2.1 单源 KBQA

2.1.1 简单 KBQA

一般来说,简单的 KBQA 可以分为 3 个部分,即实体检测、实体链接和关系链接。简单的 KBQA 任务可以被看作是一个信息提取过程。我们只要从给定知识库中找到合适的

实体和关系,就可以从此实体和关系对应的元组中获取答案。例如,Ouyang 等^[8]将实体对弱约束添加在基于注意力机制的分段卷积神经网络模型上,进行远监督关系抽取,有效缓解假阳性问题。Yin 等^[9]设计了两个卷积神经网络(CNN),用于从问题中提取实体和谓词。为了提高提取性能,Golub 等^[10]采用字符级编码器-解码器模型,从问题中提取实体和谓词。Yin 等^[11]也认识到数据提取的重要性,即在编码实体表示时应用字符级 CNN 而不是单词级 CNN。对于上述两种方法,使用实体和谓词与问题之间的两个相似度得分的总和作为排序分数,以从知识库中选择最相关的三元组。Dai 等^[12]尝试了一种不同的方法,提出了一个条件概率框架,由两个递归神经网络(RNN)实现。

以上方法都是直接对知识库中的实体关系进行建模,这种方式建模的问题和知识库元组之间存在语义鸿沟,具体表现在知识库中的关系可以对应自然语言中的多种表达。为了改善自然语言问题与知识库中三元组之间存在的语义鸿沟,Wang 等^[13]将事实三元组表示成文本形式,即表示成:问题疑问词+尾实体类型+关系+头实体。然后,使用 BERT 编码文本形式的三元组与问题,将生成的三元组表示与问题表示进行匹配,来找到问题的答案。需注意的是,该方法虽将事实三元组表示成文本形式,但并未引入新的文本语料库,因此该方法仍属于单源 KBQA 方法。Wu 等^[14]提出了一种基于弱依赖信息的知识库问答方法,在进行答案匹配时不是遵循以往的将问题与谓词匹配的方法,而是直接将其与答案信息做匹配,弱化了模型对谓词等先验信息的依赖。

简单 KBQA 围绕着一个相对简单的任务展开,在这个任务中,答案可以通过知识库中的一个三元组直接找到。然而,在许多情况下,答案需要更复杂的推理、跨多个三元组才能找到,而且有时 KB 中可能不包含问题的答案。本文使用额外的文档信息补充知识库来处理这种情况,这些文档可以提供更多候选答案以及必要的背景信息,来帮助答案检索。

2.1.2 复杂 KBQA

Dong 等^[15]提出了一种多列卷积神经网络处理问答任务。他们考虑了答案的 3 个层面信息:答案类型、答案路径和答案上下文。相应地,他们分别使用 3 列 CNN 生成问题表示。最后,将答案和问题 3 个方面的匹配分数相加作为最终的匹配分数。该工作首次提出用 3 个层面建立答案模型,可以解决一些简单 KBQA 模型无法解决的复杂问题。但是,在不考虑答案影响的情况下,手动选择 3 个独立的 CNN 来生成问题表示是不灵活的。相比之下,Hao 等^[16]提出了一个端到端模型,通过交叉注意机制动态地表示问题。根据候选答案不同层面特征与问题分词进行交互,得到问题表征,过程更灵活。Chen 等^[17]提出了一个双向注意记忆网络来模拟问题和知识库之间的交互作用。与上述两种方法类似,他们也根据答案不同层面对问题进行建模。他们使用键值记忆网络来存储候选答案不同方面的信息,并使用答案不同层面和问题对应层面之间的双向注意机制来更好地建模问题和候选答案。与 Chen 等的方法类似,Cheng 等^[18]也在问题和知识图谱之间采用双向注意力机制。除此之外,他们还将位置信息加入问题编码过程,使得问题的语义和语法信息(语法信息主要指时序信息)得以同时建模。

综合来看,以上这 4 个模型都是基于信息检索的方法,也都在 WebQuestions 数据集上验证了其优异的性能。然而,它们只将知识库作为唯一的信息源。近年来,研究人员逐渐认识到,将多种信息源(如文档和知识库)相结合,对于提高 QA 任务的性能具有重要意义。为了进行实验,研究人员从 WebQuestions 数据集派生出了一个名为 WebQuestionsSP 的新数据集。

2.2 文档增强 KBQA

KB 数据的优点是便于查询,缺点是 KB 事实可能不完整,因此某些查询无法找到任何结果。为了解决这个问题,研究人员试图从非结构化数据(如文本文档)中提取更多信息。Das 等^[19]首次提出了将两种信息(知识库和文本语料库)结合起来,以提高知识库问答方法的性能。他们的方法建立在键值内存网络(Key-Value Memory Networks)上,使用通用模式作为内存模块。然后,KB 三元组和文本片段的表示被分别送到内存模块中。Sun 等^[6]将文档句子视为知识图中的异构节点,在此基础上提出了一种新的基于图卷积的神经网络,称为 GRAFTNet。Li^[20]提出了一种带问题注意力机制的图神经网络(GQAT),在由知识库中的元组和文档句子组成的异构图上积聚与问题相关的节点信息。这 3 种方法都是早期融合方法,它们缺少对文档句子中的隐含关系的使用,也缺少对元组和文档句子两者关系的考虑。早期融合指将知识库与文本作为一种知识来源结合在一起,对答案证据进行聚合。晚期融合将知识库和文本作为两种信息源进行答案检索。目前的方法中,早期融合优于晚期融合,因此这里只综述了早期融合的方法。

相比之下,Han 等^[21]将文档视为连接多个实体的超边(关系),并使用融合函数将文档信息(如果包含候选实体)融合到该实体的表示中。同样,本文也打算通过合并文档信息来增强实体表示,但在融合方式上有所不同:我们将实体的表示与包含该实体的句子直接拼接起来,以便保留更多的特征。Xiong 等^[7]认为,知识库的信息可以为检索文档提供背景知识,并基于此假设构建了两种模型,即子图阅读器(SGReader)和知识感知阅读器(KARReader)。SGReader 读取 KB 子图中每个候选实体节点的信息,KARReader 读取与问题和候选实体相关的文档信息。与 Xiong 等^[7]的假设不同,我们认为不仅知识库信息可以为文本证据的检索提供背景知识,而且文本信息也可以为知识库证据的检索提供背景知识。本文方法不是独立地计算事实元组和文本片段表示,而是增强了知识库数据和文本信息之间的交互。

3 任务设置

知识库 K 由 3 部分组成:一组实体集合 E ,一组关系集合 R ,还有一组事实集合 $F = \{(e_s, r, e_o)\}$,事实指头实体、关系和尾实体组成的三元组。文本语料库是文档的集合,每个文档是一段词序列(句子)。

本文的任务是利用两种信息源(知识库和额外的文档语料库),找到能够很好回答自然语言问题的合适的实体节点。对于每个问题,答案实体从既包含知识库中的实体又包含文档中的实体的候选集中检索。

为了生成候选集,我们分两步进行。第一步是通过从

种子实体运行 Personalized PageRank(PPR)^[22]来检索每个问题的子图。为了更公平地对比模型性能,我们与 Sun 等^[6]和 Xiong 等^[7]一样都是对每个问题只考虑一个子图。接下来,使用现有的文档检索器^[23]检索文档,然后根据 Lucene¹⁾索引对文档进行排序。文档中的实体也链接到 KB 实体。候选集由知识库实体和文档实体组成。下文提到的子图是将文档中的实体添加到原子图中构成的新子图。其详细生成过程如下:为了从知识库中检索与问题相关的子图,首先对问题 q 执行实体链接,产生一组种子实体,记作 E_q 。接下来,在这些种子周围运行 PPR^[22]方法,以确定知识库中种子实体周围的其他可能是问题答案的实体。保留 PPR 评分最高的前 E 个实体 v_1, \dots, v_E ,并连同它们之间的所有边,将其作为检索到的 KB 子图的一部分。在知识库中检索到一部分与问题相关的子图后,使用维基百科作为语料库,在句子级别检索文本。分两个步骤进行文本检索:首先,使用 DrQA 的加权词袋模型^[23]检索最相关的 5 篇维基百科文章;然后使用 Lucene 索引,根据与问题的相关性,对文章中的文档进行排序,并返回

排名最高的 D 篇文档 d_1, \dots, d_D ;最后,对检索到的文档进行实体链接,将链接到的所有实体作为孤立的实体节点添加到前面检索到的 KB 子图中,作为最终的子图。

4 BGround 模型

本文模型由 3 个模块组成,即实体和问题表示模块(EQRM)、文档和问题增强表示模块(DQRM)以及答案预测模块(APM)。我们将总体模型图命名为 BGround,总体框架如图 2 所示,问题、实体和文本分别以黑色、粉色和蓝色系列表示。EQRM 模块通过图注意力网络使子图中的每个实体(e)从它的邻居(N_e)²⁾中积累知识,并使用融合门控机制将实体信息融合到问题中,实现问题的第一次更新。DQRM 模块利用交替协同注意机制生成文档表示,并采用融合门控机制将文档信息融合到更新的问题中,实现问题的第二次更新。最后,在 APM 模块中,实体表示和文档表示被聚合,以匹配最终的问题表示,从而进行答案实体预测。

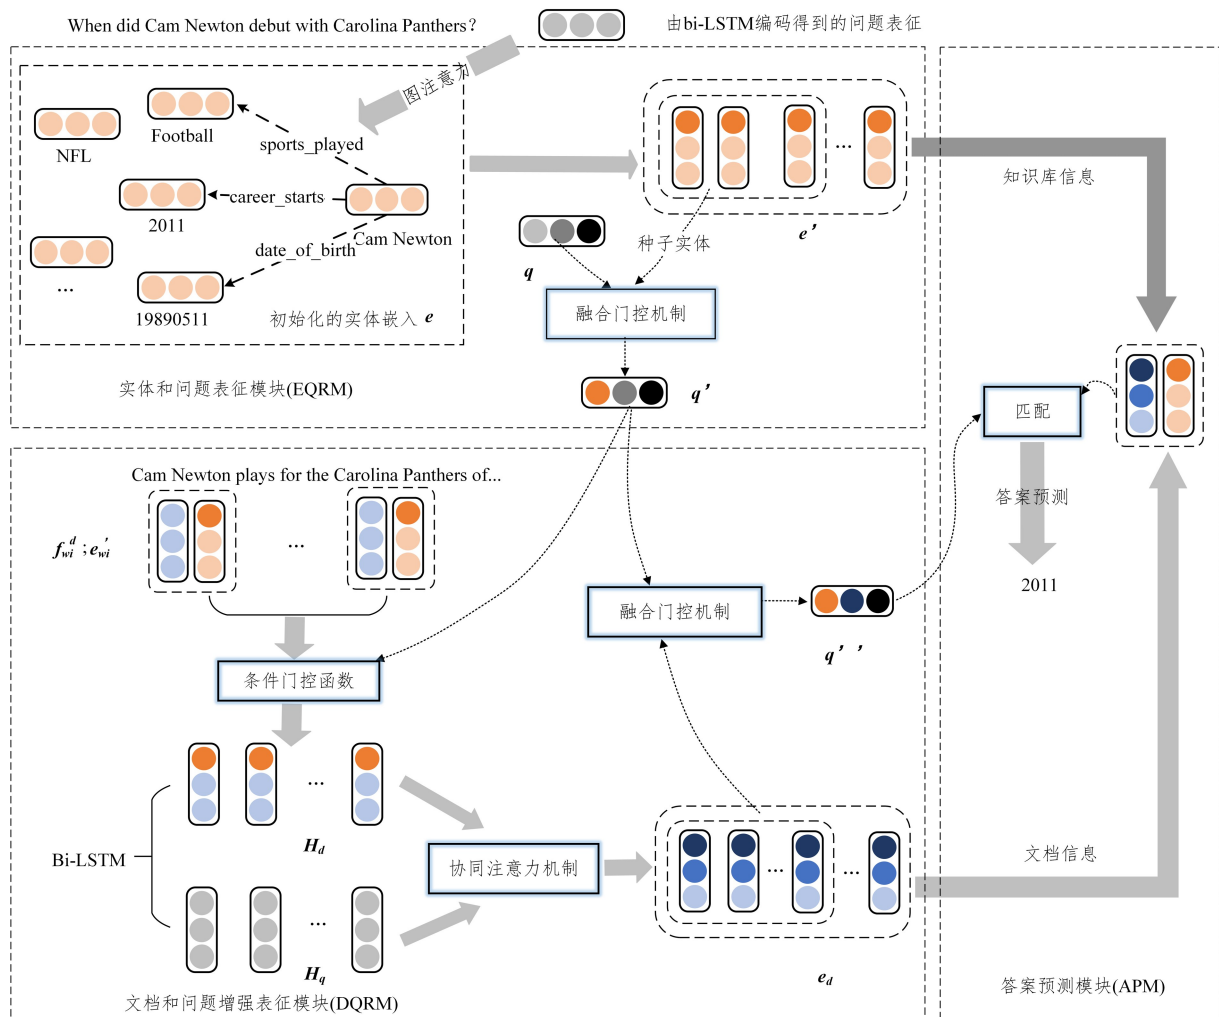


图 2 BGround 模型框架(电子版为彩图)

Fig. 2 BGround model framework

1) <https://lucene.apache.org/>

2) 与某个候选实体相连接的 1 跳内的关系和实体称为该候选实体的邻居

4.1 实体表示模块 (EQRM)

EQRM 模块的图注意力网络从两个层面考虑问题和邻居之间的相关度: 1) 问题和(邻居中的)关系的相关度; 2) 问题和(邻居中的)实体的相关度。将这两个部分的相关度相乘作为问题和此邻居的相关分数。然后, 使用线性门控函数将分数用于决定积累的邻居信息的量。这样, 对于子图中的每个实体, 我们就可以得到包含其邻居信息的实体表示。在 EQRM 模块中, 我们的做法与 SGReader^[7] 一致, 下面将进行具体论述。

给定一个自然语言问题 q , 它可以表示成单词序列 $w_1^q \cdots w_n^q$, 其中 n 是问题 q 的长度; 给定一个关系 r , 它可以表示成单词序列 $w_1^r \cdots w_m^r$, 其中 m 是关系 r 的长度。对于传统(正向)LSTM, 特定单词的输出只考虑其前面单词的信息, 而不考虑其后面单词的信息。为了避免这种情况, 我们使用共享双向 LSTM(即 Bi-LSTM) 得到问题 q 和关系 r 的词嵌入向量。输出它们的隐层状态 $\mathbf{H}_q \in R^{n \times h_d}$, $\mathbf{H}_r \in R^{m \times h_d}$, 其中 h_d 是隐层单元的大小。

一个问题可能包含多个关系, 而每个关系都只是该问题的部分描述。因此, 使用关系与问题的分词计算相似度, 并通过点积获得问题与关系的匹配分数 s_r , 如式(1)所示:

$$s_r = \mathbf{r} \cdot \sum_j \beta_j \mathbf{h}_j^q, j=1 \sim n \quad (1)$$

其中:

$$\beta_j = \text{softmax}(\mathbf{r} \cdot \mathbf{h}_j^q) \quad (2)$$

$$\mathbf{r} = \sum_i \alpha_i \mathbf{h}_i^r, i=1 \sim m \quad (3)$$

$$\alpha_i = \text{softmax}(\mathbf{w} \cdot \mathbf{h}_i^r) \quad (4)$$

其中, $\mathbf{w} \in R^{1 \times h_d}$ 是一个可训练的向量, \mathbf{h}_i^r 是关系 r 的第 i 个隐层单元, α_i 是 \mathbf{h}_i^r 的自注意力权重, \mathbf{r} 是由自注意力机制生成的关系表示, \mathbf{h}_j^q 是问题 q 的第 j 个隐层单元, β_j 是关系 r 与问题 q 的第 j 个单词的相似度权重, $\sum_j \beta_j \mathbf{h}_j^q$ 是考虑了关系影响的问题表示, s_r 是问题 q 和关系 r 的相似度得分。

如果一个实体 e_o 是种子实体, 那么它对应的元组 (e_i, r, e_o) 比其他非种子实体对应的元组与答案的相关性更大。我们使用二进制指示符计算匹配得分。具体来说, 对于任意一个实体 e 的第 i 个邻居 (r_i, e_i) , 这个二进制指示符可定义为 $I[e_i \in \epsilon_o]$, 其中 ϵ_o 是种子实体的集合。每个邻居 (r_i, e_i) 的最终图注意力得分定义为:

$$s_{(r_i, e_i)} = \text{softmax}(I[e_i \in \epsilon_o] s_{r_i}) \quad (5)$$

其中, s_{r_i} 是问题与实体 e 的第 i 个关系的相似度得分, $s_{(r_i, e_i)}$ 是问题与实体 e 的第 i 个邻居的相似度分数。

为了使子图中的实体 e 包含更多与问题相关的邻居信息, 我们使用线性门控函数来根据前面得到的问题和邻居的相似度分数决定融合进来的邻居信息的量, e' 就是包含邻居信息的候选实体 e 的嵌入。具体定义如下:

$$e' = \gamma^e e + (1 - \gamma^e) \sum_{(r_i, e_i) \in N_e} s_{(r_i, e_i)} \sigma(\mathbf{W}_1 [\mathbf{r}_i, \mathbf{e}_i]) \quad (6)$$

$$\gamma^e = \text{sigmoid}(\mathbf{W} [e, \sum_{(r_i, e_i) \in N_e} s_{(r_i, e_i)} \text{relu}(\mathbf{W}_2 [\mathbf{r}_i, \mathbf{e}_i])]) \quad (7)$$

其中, N_e 是邻居的集合, e 是子图中任意一个候选实体的预先训练好的实体嵌入, \mathbf{e}_i 是实体 e 的第 i 个邻居实体预先训练好的实体嵌入, \mathbf{r}_i 是 e 的第 i 个邻居关系的 Glove 词嵌入, \mathbf{W}, \mathbf{W}_1 和 $\mathbf{W}_2 \in R^{hd \times 2hd}$ 是可训练的参数矩阵, γ^e 是控制着原始实体表征 e

应该保留信息量的权衡参数^[24-25]。接下来, 使用融合门控机制, 通过融合种子实体的知识库信息来更新问题表示, 使它可以区分文本匹配之外的相关实体信息, q' 是包含种子实体信息的问题表征。计算式如下:

$$q' = \gamma^q q + (1 - \gamma^q) \tanh(\mathbf{W}_3 [q, e^q, q - e^q]) \quad (8)$$

$$\gamma^q = \text{sigmoid}(\mathbf{W}_4 [q, e^q, q - e^q]) \quad (9)$$

其中, q 是通过自注意力编码计算的问题表示: $\sum_j b_j \mathbf{h}_j^q$, $b_j = \text{softmax}(\mathbf{w}^q \cdot \mathbf{h}_j^q)$, \mathbf{w}^q 是可训练的参数。 e^q 是种子实体的表征, 通过问题中所有种子实体表征的均值计算 $e^q = \sum_{e \in \epsilon_o} e' / |\epsilon_o|$ 。 γ^q 是权衡参数, $\mathbf{W}_3 \in R^{h_d \times 3h_d}$ 和 $\mathbf{W}_4 \in R^{h_d \times 3h_d}$ 是可训练的参数矩阵。

4.2 文档和问题表示模块 (DQRM)

获得实体表征 e' 后, 我们改进存在的阅读理解模型^[7, 23] 来增强文档读取。本文方法有两个显著的特点: 1) 使用协同注意力机制来生成文档表示; 2) 通过将生成的文档表示融合到问题中来更新问题表示。

首先, 使用标准的 Bi-LSTM 对检索到的文档进行编码, 这采用了 Chen 等^[23] 使用的分词级特征。为了根据问题和输入文档分词特征/实体表征之间的相似性动态选择输入, 我们使用条件门控函数^[7], 以问题为条件将分词级特征与其连接的实体表征进行融合来增强文档分词表示, $i_{w_i}^d$ 就是增强的文档分词表示, 计算式如下:

$$i_{w_i}^d = \gamma^d e'_{w_i} + (1 - \gamma^d) f_{w_i}^d \quad (10)$$

$$\gamma^d = \text{sigmoid}(\mathbf{W}_5 [q' \cdot e'_{w_i}, q' \cdot f_{w_i}^d]) \quad (11)$$

其中, $f_{w_i}^d$ 表示文档 d 的第 i 个分词特征; e'_{w_i} 表示文档分词连接到的实体的表征, 它由实体表征模块学习到; γ^d 是权衡参数, $\mathbf{W}_5 \in R^{h_d \times 2h_d}$ 是可训练的参数矩阵。

在得到增强的文档分词表示 $i_{w_i}^d$ 后, 我们以一个文档句子中所有的分词表示的序列为输入, 使用 Bi-LSTM 来编码, 得到分词级别的隐层状态 $\mathbf{H}_d \in R^{k \times h_d}$ 。其中, k 是文档 d 的句子长度, h_d 是隐层单元的大小。

最终的文档表示考虑了问题对其的影响, 我们改进了 Lu 等^[26] 提出的用于视觉问答的协同注意力机制。在他们的工作中, 协同注意力机制使他们的模型能够关注图像的不同区域以及问题的不同片段。受他们工作的启发, 我们在问题和文档之间提出了两个新的协同注意模型, 即平行式协同注意力机制和交替式协同注意力机制, 如图 3 所示。协同注意力机制可以使模型关注问题分词和文档分词之间的影响, 实现更细粒度特征间的交互。

如图 3(a) 所示, 平行式协同注意力机制同时关注问题和文档, 它们之间的注意力是对称的。我们计算问题分词和文档分词之间的相似度, \mathbf{A} 就是相似度矩阵, 计算式如下:

$$\mathbf{A} = \tanh(\mathbf{H}_q \mathbf{W}_b \mathbf{H}_d^T) \quad (12)$$

其中, $\mathbf{W}_b \in R^{h_d \times h_d}$ 是参数矩阵。根据 Lu 等^[26] 的发现, 将此相关性矩阵视为一个特征, 可以提升注意力机制的性能。因此, 我们不是简单地在相似度矩阵 \mathbf{A} 上从不同维度进行最大值池化来得到问题和文档每个分词的注意力值, 而是通过将此相关性矩阵视为一个特征来预测问题和文档分词间的注意力值。 a^d 和 a^q 分别是每个文档分词特征注意力值和问题分词

特征的注意力值,计算式如下:

$$\mathbf{H}_q^d = \tanh(\mathbf{H}_d \mathbf{W}_d + \mathbf{A}^T(\mathbf{H}_q \mathbf{W}_q)) \quad (13)$$

$$\mathbf{a}^d = \text{softmax}(\mathbf{H}_1^d \mathbf{w}_{h_d}) \quad (14)$$

$$\mathbf{H}_1^q = \tanh(\mathbf{H}_q \mathbf{W}_q + \mathbf{A}^T(\mathbf{H}_d \mathbf{W}_d)) \quad (15)$$

$$\mathbf{a}^q = \text{softmax}(\mathbf{H}_1^q \mathbf{w}_{h_q}) \quad (16)$$

其中, $\mathbf{W}_d, \mathbf{W}_q \in R^{h_d \times h_d}$ 和 $\mathbf{w}_{h_d}, \mathbf{w}_{h_q} \in R^{h_d \times 1}$ 都是权重参数。 $\mathbf{a}^d \in R^{k \times 1}$ 是由文档 d 中每个分词的注意力值组成的向量, $\mathbf{a}^q \in$




图3 协同注意力机制

Fig. 3 Co-attention mechanism

在交替式协同注意力机制中,我们交替产生文档和问题的注意力值。这种注意力模型如图3(b)所示。具体来说,首先总结文档编码 \mathbf{H}_d 变成一个向量 \mathbf{d}_1 , 然后用 \mathbf{d}_1 参与问题的编码过程, 并得到问题表征 \mathbf{q}_1 , 最后使用问题表征 \mathbf{q}_1 来参与文档的编码过程, 并生成最终的文档表示 \mathbf{d} 。可以认为,此部分是3次迭代的过程。该操作的每一次迭代过程可以通过以下步骤表示:

$$\mathbf{H} = \tanh(\mathbf{X} \mathbf{W}_x + (\mathbf{W}_g \mathbf{g}) \mathbf{1}^T) \quad (19)$$

$$\mathbf{a}^x = \text{softmax}(\mathbf{H} \mathbf{w}_{h_x}) \quad (20)$$

$$\mathbf{x} = \mathbf{a}^x \mathbf{x}_i \quad (21)$$

其中, $\mathbf{1} \in R^{h_d}$ 是所有元素都是1的向量。 $\mathbf{W}_x, \mathbf{W}_g \in R^{h_d \times h_d}$, $\mathbf{w}_{h_x} \in R^{h_d \times 1}$ 都是可学习的参数。 \mathbf{a}^x 是特征 \mathbf{X} 的注意力权重, i 是 \mathbf{a}^x 的第 i 个元素。在交替式注意力机制的第一次迭代过程中, $\mathbf{X} = \mathbf{H}_d, \mathbf{g} = \mathbf{0}$, 设最终生成的中间文档表征 $\mathbf{x} = \mathbf{d}_1$; 第二次,

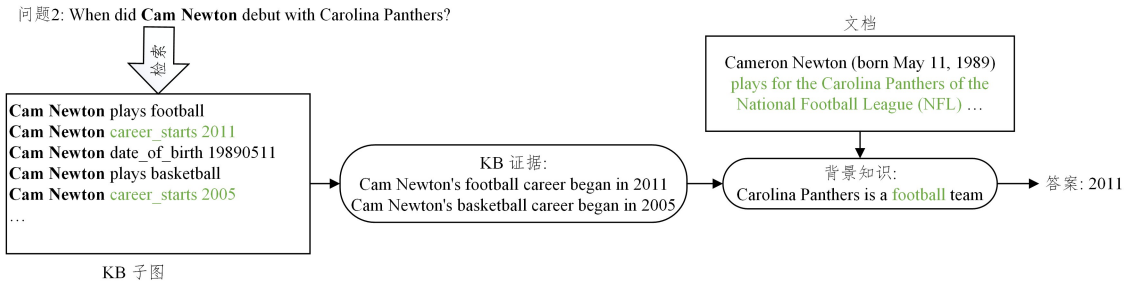
$\mathbf{X} = \mathbf{H}_q, \mathbf{g} = \mathbf{d}_1$, 生成中间问题表征 $\mathbf{x} = \mathbf{q}_1$; 最后一次, $\mathbf{X} = \mathbf{H}_d, \mathbf{g} = \mathbf{q}_1$, 生成最终的文档表征 $\mathbf{x} = \mathbf{d}$ 。

使用前面通过注意力机制得到的文档的表征 \mathbf{d} , 对于子图中任一候选实体 e , 将包含该实体的所有文档的信息进行聚合。 e_d 是聚合后的包含实体 e 的所有文档表征的平均值, 聚合方式如下:

$$e_d = \sum_{d \in D^e} \mathbf{d} / |D^e|, D^e = \{d | e \in d\} \quad (22)$$

其中, D^e 是包含实体 e 的文档的集合。

Xiong 等^[7] 只把实体信息融合到问题中, 而没有融合文本信息。由于知识库和文本可以相互补充缺失的信息, 相互提供背景知识, 因此将实体信息和文本信息融合到问题中, 使问题表征包含更丰富的信息。为了更好地理解融合文档信息的有效性, 将文档信息融合进问题表征, 具体过程如图4所示。



注: 当文档信息融合进此问题表征时, 此问题可以被看作“When did Cam Newton debut with football team?”

图4 将文档信息融合进问题表征的过程

Fig. 4 Process of fusing document information into question representation

图4中的问题包含实体“Carolina Panthers”, 这个实体在KB子图中找不到, 但是可以通过文档中的信息了解到, “Carolina Panthers”是一个足球队, 这样就将“Carolina Panthers”与KB中存在的实体“football”联系起来。通过将

文档中的信息合并到问题中, 可以解释问题中的一些实体, 从而提升答案检索的准确性。 \mathbf{q}^c 是既包含种子实体知识库信息又包含种子实体的文档信息的问题表征, 使用融合门控机制进行融合的具体方法如下:

$$\mathbf{q}^d = \gamma^d \mathbf{q}^t + (1 - \gamma^d) \tanh(\mathbf{W}^d [\mathbf{q}^t, \mathbf{e}_d^s, \mathbf{q}^t - \mathbf{e}_d^s]) \quad (23)$$

$$\gamma^d = \text{sigmoid}(\mathbf{W}^{sd} [\mathbf{q}^t, \mathbf{e}_d^s, \mathbf{q}^t - \mathbf{e}_d^s]) \quad (24)$$

其中, $\mathbf{e}_d^s = \sum_{e \in \epsilon_d} \mathbf{e}_d / |\epsilon_d|$ 是所有种子实体对应的文档表征的平均值, γ^d 是权衡参数, $\mathbf{W}^d, \mathbf{W}^{sd} \in R^{h_d \times 3h_d}$ 是可训练的参数矩阵。

4.3 答案预测模块 (APM)

为了充分利用文档句子中包含的信息,我们将包含实体的文档句子信息与实体信息连接起来,以增强实体表示。在获得问题的更新两次的表征 \mathbf{q}^d 后,该模型通过将问题向量与实体表征相匹配来预测候选实体是正确答案的概率。 s^e 是实体 e 是正确答案的概率值,计算式如下:

$$s^e = \mathbf{q}^{dT} \mathbf{W}_s [\mathbf{e}^t, \mathbf{e}_d] \quad (25)$$

其中, $\mathbf{W}_s \in R^{h_d \times 2h_d}$ 是可训练的参数矩阵。训练使用的二元交叉熵损失函数如下:

$$\text{loss}(s^n, y) = \text{mean}\{l_0, \dots, l_{N-1}\} \quad (26)$$

$$l_n = -(y_n \log(\sigma(s^n)) + (1 - y_n) \log(1 - \sigma(s^n))) \quad (27)$$

5 实验

本文在 WebQuestionsSP 数据集^[27]上进行了一系列实验,以验证本文模型的有效性。与 Sun 等^[6]的设置相同,我们将样本知识库(KB)按照不同的比率进行下采样,以模拟使用不完整知识库进行问答的场景。此外,我们从 Wikipedia 检索相关文档,将其作为补充知识库的额外文本信息。这里需要说明的是,目前使用文本语料库和知识库两个信息源执行问答任务的数据集主要有 WebQuestionsSP 数据集和 WikiMovies 数据集^[28]。WebQuestionsSP 是开放领域问答数据集,复杂问题占比约为 30%; WikiMovies 为特定电影领域问答数据集,其中的问题均为单个元组便可回答的简单问题。这里我们只使用 WebQuestionsSP 数据集进行实验。其原因如下:特定领域知识库问答任务只针对单一领域知识,所需知识范围明确,因此研究人员易于构建出答案覆盖度高的特定领域的知识图谱。相比之下,开放领域知识库问答任务针对多领域知识、所需知识范围广泛,这导致很难构建出答案覆盖完全的开放领域知识图谱。由此可见,相对于特定领域问题,开放领域问题的答案不被知识图谱覆盖的情况更多也更常见。为了更好地模拟现实中会遇到的知识图谱答案覆盖不全的情况,近期主要的研究工作^[7,20-21]只使用开放领域的 WebQuestionsSP 数据集。此外,相比单元组匹配的简单问题问答任务,在多元组匹配的复杂问题问答任务中,更易遇到问题中的某个实体和关系不被其子图覆盖的情况。由此可见,我们使用文本为问题中的实体和关系提供背景信息,这种方法主要是针对需要进行多个元组匹配的复杂问题。相比只包含简单问题的 WikiMovies 数据集,包含复杂问题的 WebQuestionsSP 数据集更适合作为我们实验的数据集。

5.1 WebQuestionsSP 数据集

WebQuestionsSP^[27]是学术界用于研究 KBQA 任务时广泛使用的数据集^[29-31]。它有 4737 个问题,可以直接从给定的知识库(例如 Freebase)中检索到答案。在我们的实验中,我们将 4737 个可回答的自然语言问题分为 3 部分:2848 个

问题用于训练、250 个问题用于验证和 1639 个问题用于测试。通过运行 Personalized PageRank^[22]在 Freebase 中检索问题的子图,它包含问题的种子实体周围的 500 个邻居实体。此外,对于每个问题,通过以下两个步骤从维基百科检索 50 个句子:首先,使用现有文档检索器^[23]在句子级别检索文本;然后,使用 Lucene 索引对检索到的句子进行排序。

5.2 对比的模型

为了验证模型的性能,我们将与以下方法进行实验比较。

(1)KV-KB&KV-EF^[19]。这是一个基于键值内存网络的基线方法,它将上下文(例如,要读取的知识库或文档)存储在键值结构化内存中。具体来说,KV-KB 是仅使用 KB 的键值内存网络的变体,而 KV-EF 是同时使用 KB 和文本的方法变体。

(2)GN-KB&GN-EF^[6]。GraftNet(GN)是一种改进的图卷积神经网络,用于聚合由 KB 事实和文本句子组成的异构图中的信息。类似地,我们将 GN-KB 记为只使用 KB 的 GN 模型,而将 GN-EF 视为同时使用 KB 和文本 GN 模型的变体。

(3)GOAT-KB&GOAT-EF^[20]。GOAT 是一种改进的图注意力网络。它以问题为标准,在知识库子图中积聚与问题相关的信息。类似地,将 GOAT-KB 记为只使用 KB 的 GOAT 模型,而将 GOAT-EF 视为同时使用 KB 和文本 GOAT 模型的变体。

(4)SGReader&(SGReader + KAREader)^[7]。SGReader 是一个精心设计的基于图注意力技术和门控机制的 QA 模型,此模型仅使用知识库信息构建。KAREader 是一个改进的阅读理解模型,用于读取文本信息。同时使用 SGReader 和 KAREader(即 SGReader + KAREader)便可以对 KB 和文本信息两者进行读取。SGReader + KAREader 模型是最先进的 KBQA 模型,它首先通过图注意力技术积累知识库信息,然后在潜在空间中更新查询,最后收集与之前积累的知识库信息相关的文本信息。

(5)HGNC^[21]。HGNC 将文档句子视为连接实体的超级边,使用文档句子来丰富知识图谱中的关系,为不同实体之间建立联系。他们首先使用图卷积网络获取每个实体包含邻居信息的表示,然后将包含实体的文档与该实体的表示进行融合,以此来构建出文档句子的元组结构。最后将实体表示与包含该实体的文档句子的元组结构进行融合,实现将文档句子作为子图中的超级边以丰富子图中的关系的目的。

5.3 参数设置

在本文的实验中,我们使用了与 Sun 等^[6]的方法相同的预训练实体嵌入,并采用了在 Common Crawl corpus¹⁾上训练的 300 维的 Glove 词嵌入。对于 KB 子图上的图注意力网络,每个实体的最大一跳内的邻居数设置为 50,最大问题长度设置为 10,最大文档长度设置为 50,梯度裁剪的范数设置为 1.0。对于单词嵌入、LSTM 隐藏状态以及协同注意机制中的线性层,我们采用了值为 0.2 的 dropout。我们使用学习率为 0.001 的 Adam 优化器来最小化二元交叉熵损失。Hits@1 和 F1 用作评估指标,其中 Hits@1 评估的是得分

¹⁾ Common Crawl 是一个公开的网页存档数据集,包含数十亿页的网络爬行数据,经常用于训练词嵌入

最高的预测答案的准确度,F1分数是准确率和召回率之间的权衡得分。一般来说,Hits@1和F1的值越大,表示性能越好。

5.4 实验结果分析

5.4.1 总体实验结果


本文在KB-only,KB+Text设置下对模型进行了实验,并将它们与基线方法进行了比较。表1和图5中的Hit@1和F1值为其乘以100的结果,即图表中的数值*a*表示的是*a*%。表1列出了在不同的KB完整度下所有模型的实验结果,数值前五行为只使用KB的情况下得出的,后六行是同时使用KB和文本的情况下得出的。图5(a)给出了在不同KB

百分比设置下,同时使用文本和KB的模型性能。即图5(a)体现了,随着KB完整性的增加,同时使用文本和KB的模型KV-EF,GN-EF,SGReader+KARReader,GAOT-EF,HGCN,BGroud的Hit@1值的对比。图5(b)给出了在不同KB范围设置下添加文本后所有模型的性能增量(“KB+文本”与“只有KB”的性能差值)。即图5(b)体现了,随着KB完整性的增加,同时使用文本和KB的模型(KV-EF,GN-EF,SGReader+KARReader,GAOT-EF,HGCN,BGroud)与它们对应的只使用KB的模型(KV-KB,GN-KB,SGReader,GOAT-KB,HGCN-KB,SGReader)的Hit@1增加值的对比。


表1 在不同KB百分比设置下,本文模型与Key-Value Memory Networks,GRAFT-Nets,KARReader等模型的比较

Table1 Comparisons of the proposed model with Key-Value Memory Networks,GRAFT-Nets and KARReader et al. under different KB settings

模型	10%KB		30%KB		50%KB		100%KB	
	Hit@1	F1	Hit@1	F1	Hit@1	F1	Hit@1	F1
KV-KB	12.5	4.3	25.8	13.8	33.3	21.3	46.7	38.6
GN-KB	15.5	6.5	34.9	20.4	47.7	34.3	66.7	62.4
GOAT-KB	18.5	7.2	34.9	18.7	48.3	31.9	67.3	59.5
HGCN-KB	18.3	7.9	35.2	21.0	49.3	34.3	66.9	60.1
SGReader	17.1	7.0	35.9	20.2	49.2	33.5	66.5	58.0
KV-EF	24.6	14.4	27.0	17.7	32.5	23.6	40.5	30.9
GN-EF	31.5	17.7	40.7	25.2	49.9	34.7	67.8	60.4
SGReader+KARReader	33.6	18.9	42.5	26.9	52.1	35.7	66.6	57.6
GOAT-EF	33.7	19.0	41.3	26.0	50.8	35.2	67.6	59.4
HGCN	33.7	19.9	42.8	27.5	52.8	37.1	68.4	60.6
BGroud	34.7	20.1	43.6	28.1	53.6	36.3	67.9	58.1



(a)同时使用文本和KB



(b)使用文本后带来的性能增量

图5 模型对比图

Fig.5 Model comparison diagram

从表1中可以观察到,在只使用KB信息的情况下,无论何种KB完整度的设置,HGCN-KB模型的总体性能均优于其他对比模型。但在同时使用KB和文本信息的情况下,我们的BGroud模型的性能在KB不完整的情况下优于HGCN模型,这说明我们将文本作为背景信息使用对模型性能的提升更有效。SGReader的性能在KB不完整(10%KB,30%KB,50%KB)的情况下优于KV-KB和GN-KB,但是在KB完整的情况下(100%KB)SGReader的性能逊于GN-KB。我们认为,这是因为在KB完整的情况下,每个实体的邻居

更多,而SGReader只能收集一跳内的邻居信息,导致其性能逊于可收集多跳邻居信息的GN-KB方法。值得注意的是,我们在EQRM模块遵循的也是SGReader的方法,虽然在KB完整情况下SGReader性能与GN-KB差距相对较大,但是我们的完整模型BGroud的性能却和GN-EF相差不多。由此可以反映出我们将文本作为背景信息使用的有效性。在同时使用KB和文本的模型中,我们的BGroud模型不论是Hit@1还是F1的成绩均取得了有竞争力的结果,这说明我们的模型不论是在返回答案的准确度上,还是对有多个答案的问题的回答上,都有出色的表现。

表2 在30%KB设置下的消融实验

Table2 Ablation experiment under 30%KB setting

注意力	有融合		无融合	
	Hit@1	F1	Hit@1	F1
交替式协同注意力	43.6	28.1	42.8	27.0
平行式协同注意力	43.0	26.9	42.9	26.8
无协同注意力	42.8	27.0	42.7	26.7

从图5(a)可以观察到,在所有使用文本和KB的方法中,我们的BGroud模型不仅在知识库不完整的情况下实现了最好的性能,在知识库完整的情况下也获得了有竞争力的结果。由此,我们认为,该方法比其他对比方法更有效。

从图5(b)可以观察到,KV的方法(KV-EF)在10%KB和30%KB设置下,引入文本对模型性能均有提升作用,在50%KB和100%KB设置下,引入文本反而降低了模型性能;GN-EF,SGReader+KARReader,GOAT-EF,HGCN,BGroud在每种KB设置下,使用文本均能提升模型性能,只是随着KB完整度的增加,对模型性能的影响越来越小。这说明,在KB越不完整的情况下使用文本对KBQA模型的性能提升

越有效果;在 KB 接近完整的情况下,使用文本对模型性能提升不明显,甚至可能因为对文本的使用方法不当,引入文本噪声,从而减低模型性能。我们还观察到,在 30%KB,50%KB 设置下,BGround 对文本的使用导致性能的提升量高于其他对比方法;在 10%KB 设置下,BGround 对文本的使用导致性能的提升量略低于 GN 的方法,但是依然很有竞争力。这证明,在知识库不完整的情况下,我们这种将文本作为背景信息的方法有效提升了 KBQA 性能。

5.4.2 消融实验

为了讨论每个组件的影响,我们在 30%KB 设置下进行了消融实验。实验结果如表 2 所列。从结果可以看出:

(1)融合。在使用交替式注意力机制的情况下,通过融合函数将文档表示融合到问题表示中,Hit@1 得分增加 0.8%,F1 得分增加 1.1%。由此可见,这种特征融合的方式可以提升模型的性能。

(2)协同注意力机制。在有融合的情况下,使用交替式协同注意力机制与无协同注意力机制相比,Hit@1 得分增加 0.8%,F1 得分增加 1.1%;使用平行式协同注意力机制与无协同注意力机制相比,Hit@1 得分增加 0.2%,F1 得分降低 0.1%;使用交替式协同注意力机制与平行式注意力机制相比,Hit@1 得分增加 0.6%,F1 得分增加 1.2%。由此可见,交替式协同注意力机制和平行式协同注意力机制对模型性能的提升均有帮助,且交替式协同注意力机制比平行式协同注意力机制效果更好。因此,本文最终采用交替式协同注意力来生成文档表示。

结束语 本文提出了一个先进的问答模型。我们充分利用文本信息,不仅像以前方法一样使用文本信息来弥补知识库缺失的信息,而且通过将相关文档信息融合到问题表示中来利用文本信息为答案检索提供背景知识,这显著提升了问答系统的性能。在未来的工作中,我们将使用知识库子图信息的多跳传播来提高子图读取器的性能。

参考文献

- [1] ZETTLEMOYER L S, COLLINS M. Learning context-dependent mappings from sentences to logical form[C]// Proceedings of the Joint Conference of the 47th Annual Meeting of the ACL and the 4th International Joint Conference on Natural Language Processing of the AFNLP. 2009.
- [2] 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. 2013:1545-1556.
- [3] YIH S W, CHANG M W, HE X, et al. Semantic parsing via staged query graph generation: Question answering with knowledge 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.
- [4] YAO X, 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 (Volume 1: Long Papers). 2014:956-966
- [5] 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. 2016:2326-2336.
- [6] 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, Belgium, 2018:4231-4242.
- [7] XIONG W, YU M, CHANG S, et al. Improving question answering over incomplete kbs with knowledge-aware reader [C]// Annual Meeting of the Association for Computational Linguistics. 2019.
- [8] OUYANG D T, XIAO J, YE Y X. Distant supervision for relation extraction with weak constraints of entity pairs[J]. Journal of Jilin University (Engineering and Technology Edition), 2019, 49(3):912-919.
- [9] YIH W, HE X, MEEK C. Semantic parsing for single-relation question answering[C]// Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Volume 2: Short Papers). 2014:643-648.
- [10] GOLUB D, HE X. Character-level question answering with attention[C]// Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. 2016:1598-1607.
- [11] YIN W, YU M, XIANG B, et al. Simple question answering by attentive convolutional neural network[J]. arXiv:1606.03391, 2016.
- [12] DAI Z, LI L, XU W. Cfo: Conditional focused neural question answering with large-scale knowledge bases[C]// Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics. 2016.
- [13] WANG G X, HE S Z, LI K, et al. Knowledge Base Question Answering Method Incorporating Fact Text[J]. Pattern Recognition and Artificial Intelligence, 2021, 3(3):267-274.
- [14] WU T B, LIU L P, LUO X D, et al. Knowledge Base Question Answering Method Based on Weak Dependency Information[J]. Computer Engineering, 2021, 47(6):76-82.
- [15] DONG L, WEI F, 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 (Volume 1: Long Papers). 2015:260-269.
- [16] HAO Y, ZHANG Y, LIU K, 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 (Volume 1: Long Papers). 2017:221-231.
- [17] CHEN Y, WU L, ZAKI M J. Bidirectional attentive memory networks for question answering over knowledge bases[C]// Proceedings of the 2018 Conference on the North American Chapter of the Association for Computational Linguistics. 2019.
- [18] CHENG Z, ZHOU X, HE X H, et al. Multi-angle Attention Question Answering Model Fused with Position Embedding[J].

- Innovation of Science and Technolog,2022,26(9):85-88.
- [19] DAS R,ZAHEER M,REDDY S,et al. Question answering on knowledge bases and text using universal schema and memory networks[C]//Proceedings of the Annual Meeting of the Association for Computational Linguistics,2017.
- [20] LI Z P. Research on Question Answering over Knowledge Bases with External Texts based on Graph Attention Network[D]. Guangzhou:South China University of Technology,2020.
- [21] 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.
- [22] HAVELIWALA T H. Topic-sensitive pagerank:A context-sensitive ranking algorithm for web search[J]. IEEE Transactions on Knowledge and Data Engineering,2003,15(4):784-796.
- [23] CHEN D,FISCH A,WESTON J,et al. Reading wikipedia to answer open-domain questions[C]//Proceedings of the Association for Computational Linguistics(ACL). 2017.
- [24] SONG L,ZHANG Y,WANG Z,et al. A graph-to-sequence model for AMR-to-text generation[C]//Proceedings of the Association for Computational Linguistics(ACL). 2018.
- [25] XU K,WU L,WANG Z,et al. Graph2seq:Graph to sequence learning with attention-based neural networks[J]. arXiv:1804.00823,2018.
- [26] LU J,YANG J,BATRA D,et al. Hierarchical Question-Image Co-Attention for Visual Question Answering [C]//Proceedings of the 30th Conference on Neural Information Processing Systems(NIPS). 2016.
- [27] YIH W,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 (Volume 2: Short Papers). 2016:201-206.
- [28] MILLER A,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(EMNLP 2016). Austin, Texas, USA, 2016:1400-1409.
- [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 Association for Computational Linguistics(ACL'17). 2017.
- [30] 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 2018 Conference on Empirical Methods in Natural Language Processing. 2019.
- [31] 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.



FENG Chengcheng, born in 1996, post-graduate. Her main research interest is natural language processing.



JIANG Linying, born in 1972, master, professor. Her main research interests include data analysis, natural language processing, embedded system, and information system engineering.

(责任编辑:喻黎)