

基于关系记忆与路径信息的多跳知识图谱问答算法

孟令鑫¹, 才 华¹, 付 强², 易亚希¹, 刘广文¹, 张晨洁¹

(1. 长春理工大学 电子信息工程学院, 长春 130022; 2. 长春理工大学 空间光电技术研究所, 长春 130022)

摘要: 针对自然语言处理领域中不完整知识图谱导致实体关联膨胀, 进而需进行额外推理和推断使答案的推导过程变得更复杂的问题, 提出一种结合关系记忆与路径信息知识图谱问答算法 RMP-KGQA. 该算法利用关系记忆网络解决问题与知识图谱映射空间不一致的问题, 利用其路径信息丰富评分函数, 显著提高了智能问答检索系统的准确性和鲁棒性. 实验结果表明, 在基准数据集 WebQSP 和 WebQSP-50 上, RMP-KGQA 的准确率分别比 EmbedKGQA 提升了 2.8, 2.4 个百分点. 消融实验进一步验证了关系记忆感知和路径信息在模型中的关键作用. 因此, RMP-KGQA 是一种解决复杂环境下多跳知识图谱问答问题的有效方法.

关键词: 知识图谱问答; 知识图谱; 知识图谱嵌入; 关系记忆网络

中图分类号: TP391.1 **文献标志码:** A **文章编号:** 1671-5489(2024)06-1391-10

Multi-hop Knowledge Graph Question Answering Algorithm Based on Relational Memory and Path Information

MENG Lingxin¹, CAI Hua¹, FU Qiang², YI Yaxi¹, LIU Guangwen¹, ZHANG Chenjie¹

(1. School of Electronic and Information Engineering, Changchun University of Science and Technology, Changchun 130022, China; 2. Institute of Space Optoelectronics Technology, Changchun University of Science and Technology, Changchun 130022, China)

Abstract: Aiming at the problem that in the field of natural language processing, incomplete knowledge graphs led to the entity association expansion, which required additional inference and reasoning to make the derivation process of answers more complex, we proposed a knowledge graph question answering algorithm RMP-KGQA that combined relational memory and path information. The algorithm used a relational memory network to solve the problem of inconsistency between the problem and the knowledge graph mapping space, and enriched the scoring function with its path information, significantly enhancing the accuracy and robustness of the intelligent question answering retrieval system. The experimental results show that on the WebQSP and WebQSP-50 benchmark datasets, the accuracy of RMP-KGQA increases by 2.8 and 2.4 percentage points respectively

收稿日期: 2023-05-26.

第一作者简介: 孟令鑫(1999—), 男, 汉族, 硕士研究生, 从事深度学习与知识图谱的研究, E-mail: mlx0615@qq.com. **通信作者简介:** 才 华(1977—), 男, 汉族, 博士, 副教授, 从事图像处理、计算机视觉与人工智能算法的研究, E-mail: caihua@cust.edu.cn.

基金项目: 国家自然科学基金重大项目(批准号: 61890963)、国家自然科学基金联合基金(批准号: U2341226)、吉林省人才专项基金(批准号: 20240602015RC)、2023 年度西安市飞行器光学成像与测量技术重点实验室开放基金(批准号: 2023-13)和吉林省科技厅科技发展计划项目(批准号: 20240302089GX).

compared to EmbedKGQA. Ablation experiments further verify the key roles of relational memory perception and path information in the model. Therefore, RMP-KGQA is an effective method for solving multi-hop knowledge graph question answering problems in complex environments.

Keywords: knowledge graph question answering; knowledge graph; knowledge graph embedding; relational memory network

知识图谱问答(knowledge graph question answering, KGQA)作为满足人们对知识获取日益强烈需求的有效途径,已逐渐成为研究焦点^[1]. KGQA 通过查询和推理知识图谱,提取与自然语言问题相关的答案.其基础元素是三元组 (h, r, t) ,其中: h 表示头实体; r 表示关系,描述头尾实体间的联系; t 表示尾实体,作为事实或关系的目标实体. KGQA 已广泛应用于农业、轨道交通、医疗保健、水利信息、旅游以及政务数据等各领域^[2],使用户可以更准确、直接、专业地获取所需信息,从而提高了信息检索的效率和满意度.

近年来,深度学习的发展推动了多跳知识图谱问答的发展,主要包括基于路径^[3-4]、基于逻辑^[5-6]和基于嵌入^[7-11]的方法.基于路径的方法依赖于主题实体的识别和知识图谱的随机遍历;基于逻辑的方法则通过将问题转化为逻辑表达式并在知识图谱中进行推理.但这两种方法在处理知识图谱的多跳检索时,由于知识图谱的不完整性和稀疏性,经常会因缺少实体间的关系路径链接而无法得出正确答案.相比于上述两种方法,基于嵌入的方法则利用知识图谱嵌入,将实体和关系映射到低维空间进行推理,实现语义消歧并有效解决知识图谱中的查询不准确问题,提高问答的准确性和效率.但上述方法常独立处理问题嵌入和知识图谱嵌入,忽视了两者的潜在依赖关系.此外,单一的评分函数也可能导致答案的遗漏,影响模型的鲁棒性.

本文针对基于嵌入的 KGQA 模型中由于问题与知识图谱嵌入使用不同网络导致的映射空间不同,以及评分函数单一的问题,提出一种基于关系记忆与路径信息的多跳问答算法 RMP-KGQA(relation memory-based path for knowledge graph question answering).该算法通过引入基于关系记忆的感知网络,分析两者间的潜在依赖关系,解决映射空间不同的问题;同时,还引入了知识图谱的路径信息以丰富评分函数,从而提高智能问答检索系统的准确性和鲁棒性.

1 基于嵌入的多跳知识图谱问答

基于嵌入的多跳知识图谱问答方法利用知识图谱嵌入算法将实体和关系嵌入到低维向量空间中,并通过定义得分函数或解码器对目标查询对象进行排名,以实现问答推理^[12].早期的知识图谱嵌入算法如 TransE 模型^[13],其基于实体头、尾和关系之间的潜在关系计算实体之间的距离.之后出现的 TransR^[14],TransD^[15],RotatE^[16]等基于距离的嵌入模型,尽管在简单场景中表现出色,但在处理更复杂的多跳问答场景时还需更深入研究.

Chen 等^[7]提出的双向注意力记忆网络(BAMnet)模拟了问题与知识库之间的双向交互流程,提高了知识库问题回答(KBQA)的效率,并提供了超越其他基准方法的解释能力. Huang 等^[8]推出的知识嵌入式问题回答(KEQA)框架,通过嵌入问题的头实体、谓词和尾实体,利用联合距离度量返回最近的事实作为答案. Teru 等^[9]提出的基于图神经网络的关系预测框架 GraIL 能在局部子图结构上进行推理,显示了实体学习的能力. Saxena 等^[10]提出的 EmbedKGQA 方法使用知识图谱嵌入技术处理稀疏的知识图谱,并放宽了答案选择的限制. Niu 等^[11]提出了一种基于路径和知识嵌入增强的多关系问答模型(PKEEQA),该模型通过评估路径嵌入和多关系问题嵌入之间的相关性,获得更精确的答案.

尽管上述模型取得了很好的成果,但基于嵌入的 KGQA 模型通常忽视问题嵌入与知识图谱嵌入间的潜在关系,且评分函数的单一性可能导致答案遗漏,影响模型的鲁棒性.为解决这些问题,本文提出一种关系记忆和路径信息相结合的知识图谱问答算法 RMP-KGQA,它通过关系记忆网络解决问题与知识图谱映射空间不一致的问题,同时利用其路径信息丰富评分函数,显著提高了智能问答检索系统的准确性和鲁棒性.

2 本文方法

本文对知识图谱定义如下: 知识图谱 G 由实体集合 E 和关系集合 R 构成, 其中三元组集合 K 包含所有由 E 和 R 中的实体和关系组成的三元组, 即 $K = \{(h, r, t) | h, t \in E, r \in R\}$. 每个三元组 (h, r, t) 表示主体实体 h 与客体实体 t 之间存在关系 r . RMP-KGQA 模型的任务定义为: 给定自然语言问题 q 和主题实体 $e_h \in E$, 通过查询知识图谱中与主题实体 e_h 相关的信息, 提取实体 $e_t \in R$ 正确回答问题 q . 其中, 关系集合 R 用于表示知识图谱中实体之间的关联关系. 模型通过关系记忆网络与问题相关的路径信息 e_p 分析问题向量与实体向量之间的潜在依赖关系, 并将其重新映射为新的问题向量. 最后通过计算问题 q 和知识图谱中的实体及关系之间的匹配度选择最可能正确的实体 e_t 作为问题的答案 a . 该模型整体建构如图 1 所示.

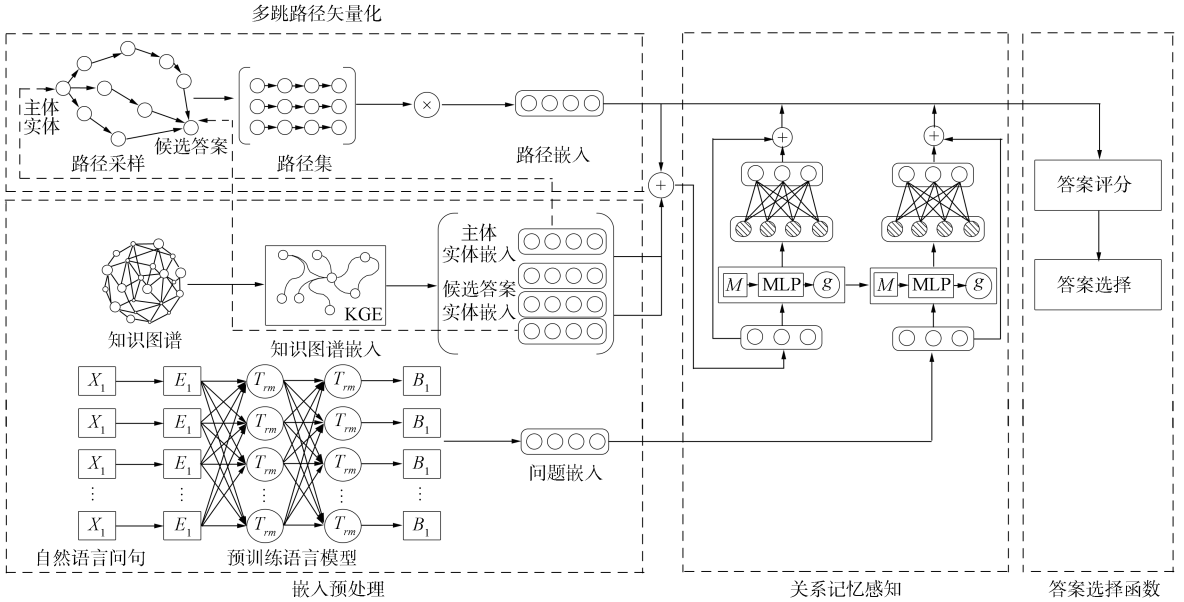


图 1 RMP-KGQA 整体流程

Fig. 1 Overall process of RMP-KGQA

- 1) 嵌入预处理: 学习知识图谱中实体和关系的嵌入表示与自然语言问题的嵌入表示, 分别将它们映射到嵌入空间中;
- 2) 多跳路径矢量化: 在知识图谱中抽取主体实体与答案之间的关系路径, 并通过路径嵌入的方式建立一个向量空间;
- 3) 关系记忆感知: 利用关系记忆网络将输入的嵌入向量分析问题嵌入与实体嵌入之间潜在的依赖关系, 得到重新映射的问题向量;
- 4) 答案选择: 通过结合路径的评分函数计算每个候选答案与问题之间的相似度并选择最终答案.

2.1 嵌入预处理

嵌入预处理分为知识图谱嵌入和自然语言问句嵌入两部分, 用于将知识图谱中的实体和关系以及自然语言问句分别嵌入到对应的低维空间中. 受 EmbedKGQA^[10] 启发, 本文选用 ComplEx 算法^[17] 将知识图谱进行嵌入映射, 将知识图谱中的实体 $e \in E$ 和关系 $r \in R$ 映射到复数向量空间, 得到实体嵌入 $e_e \in \mathbb{R}^{d_e}$ 和关系嵌入 $e_r \in \mathbb{R}^{d_r}$, 其中 e_e 和 e_r 分别是 d_e 和 d_r 维向量. 给定 $h, t \in E$ 和 $r \in R$, ComplEx 定义评分函数为

$$\varphi(h, r, t) = \text{Re}(\langle e_h, e_r, \bar{e}_t \rangle) = \text{Re}\left(\sum_{k=1}^d e_h^{(k)} e_r^{(k)} \bar{e}_t^{(k)}\right), \tag{1}$$

使得对于所有真三元组 $\varphi(h, r, t) > 0$, 对于假三元组 $\varphi(h, r, t) < 0$, 其中 Re 表示复数的实部.

其旨在准确地捕获和保留实体和关系间的语义关联性, 同时体现其线性与非线性交互. 另一方

面,自然语言问题嵌入先采用预训练的 RoBERTa 模型^[18]进行微调,再通过全连接网络层进一步加工,从而生成问题 q 的嵌入向量 $e_q \in \mathbb{R}^d$. 两种嵌入向量的生成过程如下,它们将作为后续模型的有效输入.

算法 1 RMP-KGQA 预处理.

- 1) 输入: 知识图谱 KG 与实体 E 和关系 R , 自然语言问题 Q , 预训练的 RoBERTa 模型 M ;
- 2) 输出: 实体的嵌入表示 E' 和关系 R' , 问题嵌入 Q' ;
- 3) 初始化: 为 KG 中的每个实体和关系随机初始化复嵌入向量;
- 4) 循环
 - 5) 从 KG 中随机选择一个三元组 (t, h, r) ;
 - 6) 随机选择一个负样本三元组 (t', h', r') , 其中 t' 或 h' 是一个随机实体, r' 是一个随机关系;
 - 7) 计算三元组的分数: $\text{score}(t, h, r) = \text{Re}(\langle h, r, t \rangle)$;
 - 8) 计算负样本的分数: $\text{score}(t', h', r') = \text{Re}(\langle h', r', t' \rangle)$;
 - 9) 计算损失: $\text{loss} = \max\{0, \text{margin} + \text{score}(t', h', r') - \text{score}(t, h, r)\}$;
 - 10) 使用梯度下降更新实体和关系的嵌入以最小化损失;
 - 11) 直到知识图谱实体和关系的嵌入 E', R' 稳定;
 - 12) 使用 RoBERTa 模型 M 将问题 Q 嵌入为一个实值向量;
 - 13) 通过 4 个带有 ReLU 激活的全连接层将实值向量投影到复空间以获得 Q' ;
 - 14) 返回实体的嵌入表示 E' 、关系 R' 和问题 Q' .

2.2 多跳路径矢量化

多跳路径矢量化旨在对问题和知识图谱中的多跳路径进行建模,其通过路径搜索算法寻找与问题相关的路径,并将路径中的实体、关系和属性嵌入表示成固定长度的向量,以便于后续的推理和推断.

首先,查询获取自然语言问句中的主体实体 h 与问题答案 a 在知识图谱 G 之间的链路连接. 三元组的实体之间通过关系相连接,在问答检索任务中,如果主体实体与问题答案存在知识图谱上的关系连接,则对当前关系的路径进行记录,记录为一个路径 $p = (r_1, r_2, \dots, r_l)$,将主体实体 h 与问题答案 a 所有的路径进行记录为 $P = \{p_1, p_2, \dots, p_i\}$.

其次,对上述获取的路径嵌入 $P = \{p_1, p_2, \dots, p_i\}$ 中的每条路径 $p = (r_1, r_2, \dots, r_l)$ 进行路径嵌入得到关系路径嵌入向量 e_p . 即在基于张量分解的知识图谱嵌入模型中,存在每个三元组的值可通过头部实体嵌入向量 h 和尾部实体嵌入向量 t 与关系矩阵 M_r 的乘积计算,期望满足 $h \cdot M_r t = 1$. 所以在基于张量分解的公式中对于路径满足约束:

$$e_p = \prod_{r_i \in P} e_{r_i}, \quad (2)$$

其中 P 表示包含从主体实体 h 到问题答案 a 或候选实体 h 的路径序列中所有关系的集合, e_{r_i} 表示第 i 个关系 r_i 在集合 P 中的嵌入.

最后,将主体实体嵌入向量 e_h 、问题答案嵌入向量 e_a 与关系路径嵌入向量 e_p 进行拼接,得到一个包含了答案路径信息的嵌入向量 e_x .

2.3 关系记忆感知

在 RMP-KGQA 模型中,关系记忆感知是一个关键的组成部分,用于对问句和实体进行嵌入处理,该模块使用关系记忆网络(relation-aware memory-based network, RAMN)^[19]捕捉问题中的关系信息,并将其映射为固定长度的向量表示. RAMN 网络可分别将问句中的实体和关系嵌入表示为向量,然后通过注意力机制将这些向量组合成一个表示问题的向量. 在该过程中, RAMN 网络可以学习到关系之间的交互信息,并在不同的语境下自适应地调整向量的权重,以获得更准确的问句表示. RAMN 的网络结构如图 2 所示.

首先,将自然语言问句嵌入所得的自然语言问句嵌入向量 e_q 与包含答案路径信息的嵌入向量 e_x 送入关系记忆感知模块,用于分析问句嵌入与实体嵌入之间潜在的依赖关系,并得到重映射的问题嵌

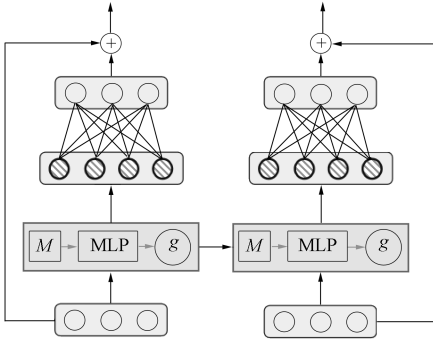


图 2 RAMN 网络结构

Fig. 2 Structure of RAMN network

头, $W^{h,V} \in \mathbb{R}^{n \times k}$ 是一个值投影矩阵, n 表示头的大小, $k = nH$. $\{\alpha_{i,j,h}\}_{j=1}^N$ 和 $\alpha_{i,N+1,h}$ 为注意力权重, 使用 Softmax 函数在比例点积上计算:

$$\alpha_{i,j,h} = \frac{\exp\{\beta_{i,j,h}\}}{\sum_{m=1}^{N+1} \exp\{\beta_{i,m,h}\}}, \quad (5)$$

$$\alpha_{i,N+1,h} = \frac{\exp\{\beta_{i,N+1,h}\}}{\sum_{m=1}^{N+1} \exp\{\beta_{i,m,h}\}}, \quad (6)$$

其中

$$\beta_{i,j,h} = \frac{(W^{h,Q}M_{i,:}^{(t)}) \cdot (W^{h,K}M_{j,:}^{(t)})}{\sqrt{n}}, \quad (7)$$

$$\beta_{i,N+1,h} = \frac{(W^{h,Q}M_{i,:}^{(t)}) \cdot (W^{h,K}x_t)}{\sqrt{n}}, \quad (8)$$

$W^{h,Q} \in \mathbb{R}^{n \times k}$, $W^{h,K} \in \mathbb{R}^{n \times k}$ 分别为查询投影矩阵和键投影矩阵. x_t 和 $\hat{M}_{i,:}^{(t+1)}$ 之间的残差连接提供给多层感知器, 然后通过内存的门控机制, 生成表示时间步长 t 的编码向量 $y_t \in \mathbb{R}^k$. 同时, 该门控机制也会生成代表时间步长 $(t+1)$ 的下一个内存槽 $M_{i,:}^{(t+1)}$.

其次, 使用一个全连接层和一个残差块. 全连接层将输入 H 线性变换为 $\hat{e}_q = e'_q W + b$, 残差块使用函数 f 进行非线性变换, 输出 $\vartheta_q = f(\hat{e}_q) + e_q$. 最终将 ϑ_q 作为新的嵌入向量, 用于后续的推理和推断.

整体 RAMN 网络训练使用 ComplEx 函数作为评分函数, 给定问题 q , 主题实体 $h \in E$ 和应答实体集 $A \subseteq E$, 其以如下方式学习问题嵌入:

$$\begin{cases} \varphi(e_h, \vartheta_q, e_a) > 0, & \forall a \in A, \\ \varphi(e_h, \vartheta_q, e_{\bar{a}}) < 0, & \forall \bar{a} \notin A, \end{cases} \quad (9)$$

其中 φ 是 ComplEx 评分函数, e_a 和 $e_{\bar{a}}$ 是在上一步中学习的实体嵌入. 对于每个问题, 使用所有候选答案实体 $a' \subseteq E$ 计算得分 $\varphi(\cdot)$. 该模型是通过最小化分数的 Sigmoid 和目标标签之间的二进制交叉熵损失学习, 其中对正确答案, 目标标签为 1, 否则为 0. 当实体总数较大时, 将进行标签平滑.

2.4 答案选择函数

答案选择在 RMP-KGQA 模型中的作用是通过结合路径评分计算每个候选答案与问题之间的相似度, 对所有候选答案进行打分并选择最佳答案, 以提高问答的准确性和效率.

将 ϑ_q, e_h, e_a 送入评分函数中进行评分计算, 并引入路径评分, 选择与计算最终得到答案 a_{ans} . 即将关系记忆感知模块得到的重映射的问题嵌入向量 ϑ_q 和主体实体嵌入向量 e_h 、候选问题答案嵌入向量 e_a 送入评分函数中进行评分计算, 并引入关系路径嵌入向量 e_p , 设置评分函数进行路径评分. 最终的评分函数为

$$a_{ans} = \operatorname{argmax} \varphi(e_h, \vartheta_q, e_{a'}) + \operatorname{atanh}(\operatorname{sim}(e_p, \vartheta_q)). \quad (10)$$

评分函数由两部分组成: 左半部分为 ComplEx 评分函数, 右半部分为路径评分函数. 其中:

入向量 e'_q . 即使用一种基于关系记忆感知的神经网络, 假设内存 M 由 N 行组成, 其中每行是一个内存槽. 用 $M^{(t)}$ 表示内存的步骤, $M_{i,:}^{(t)} \in \mathbb{R}^k$ 表示时间步骤 t 中的第 i 个内存槽. 遵循 x_t 更新 $M_{i,:}^{(t)}$ 使用多头自注意机制:

$$\hat{M}_{i,:}^{(t+1)} = (\hat{M}_{i,:}^{(t+1),1} \oplus \hat{M}_{i,:}^{(t+1),2} \oplus \dots \oplus \hat{M}_{i,:}^{(t+1),H}), \quad (3)$$

其中

$$\hat{M}_{i,:}^{(t+1),h} = \alpha_{i,N+1,h} (W^{h,V}x_t) + \sum_{j=1}^N \alpha_{i,j,h} (W^{h,V}M_{j,:}^{(t)}), \quad (4)$$

H 为注意头数, \oplus 为向量拼接操作. 对于第 h 个

$\tanh(\text{sim}(e_p, e_q))$ 表示问题嵌入向量和路径嵌入向量之间的相似度,选择余弦距离函数计算相似度; α 为超参数,表示三元关系和路径问题相关性之间权衡的权重. \tanh 函数的输出值在 $[-1, 1]$ 内,可反映路径和问题之间的两极相关性,因为与问题不匹配的路径甚至可以推断出不太可能的答案. 特定于路径的分数可表明路径和给定问题之间的正相关或负相关,这可进一步与三元组分数相结合,以探索更准确的答案.

3 实验结果与分析

3.1 数据集和评价指标

本文在数据集 WebQSP(Web QuestionSP)^[20]上进行实验,该数据集中的问题来自 Bing 搜索引擎的日志,并由人工标注者根据给定的知识图谱和答案标注进行标注,其包含 4 737 个问题. 这些问题为 1 跳和 2 跳问题,可通过 Freebase KG 进行回答. 为方便实验,将知识库限制为 Freebase 的一个子集,该子集包含 WebQSP 问题中提到的任何实体的 2 跳内的所有事实. 进一步,本文还修剪了知识库,仅包含数据集中提到的那些关系. 最终,得到较小的知识库包含 180 万个实体和 570 万个三元组实体.

为更符合实际场景,需对质量保证模型进行不完整知识库测试. 本文使用随机删除知识库中 1/2 的三元组的方式模拟不完整知识库,称为 WebQSP-50,对完整的知识库,称为 WebQSP-Full. 在 WebQSP-50 中,随机删除概率为 0.5 的事实,这样可以模拟在实际应用中遇到不完整知识库的情况.

使用准确率 P 作为主要评价指标衡量知识图谱多跳问答的性能. 在实验中,准确率定义为在测试集中的所有问题中,系统给出的答案中与标准答案完全匹配的数量除以总问题数. 如果一个问题有多个正确答案,则将所有正确答案计入总体统计中.

3.2 定量实验

为进一步评估本文模型的性能,进行了定性实验分析. 在这些实验中,手动挑选一些具有挑战性的问题,并使用本文模型与其他模型进行比较. 对比模型包括 KVMem^[21], GraftNet^[22], PullNet^[23]和 EmbedKGQA^[10]. 本文选择这些对比模型是因为它们在目前的基准测试中性能良好,并代表了现有最先进的问答系统模型.

不同方法的定量实验结果列于表 1. 由表 1 可见, RMP-KGQA 模型在数据集 WebQSP-Full 上的准确率为 68.9%, 相比其他模型具有较大优势. 在数据集 WebQSP-50 上,由于删除了 50% 的三元组,导致知识图谱变得非常稀疏,使得许多问题的头实体节点到答案节点的路径更长,路径跳转步长大于 3. 因此,需要构建问题特定子图的模型(如 GraftNet, PullNet)在生成的子图中无法调用答案实体,从而导致模型性能下降. 而 RMP-KGQA 模型并不受限于子图的范围,利用知识图谱嵌入预测链接属性,可以推断缺失链接之间的关系. 此外, RMP-KGQA 模型还引入了关系记忆感知模块和路径信息评分,充分利用了知识图谱的结构信息. 因此, RMP-KGQA 模型在知识图谱问答中的性能优越,为处理更复杂的多跳问答场景提供了一个强大且鲁棒的解决方案,有效改进了答案检索的准确性和鲁棒性.

表 1 不同方法在数据集上的实验结果对比

Table 1 Comparison of experimental results on dataset by different methods

方法	准确率/%	
	WebQSP-Full	WebQSP-50
KV-Men	46.7	32.7
GraftNet	66.4	48.2
PullNet	68.1	50.1
EmbedKGQA	66.1	53.2
RMP-KGQA	68.9	55.6

3.3 消融实验

为评估模型各组成部分对其性能的贡献,本文在数据集 WebQSP-Full 和 WebQSP-50 上进行消融

实验, 比较了剔除关系记忆感知模块和删除多跳路径矢量化模块后的模型性能, 结果列于表 2.

表 2 消融实验结果

Table 2 Results of ablation experiment

方法	准确率/%	
	WebQSP-Full	WebQSP-50
RMP-KGQA	68.9	55.6
-RAMN	64.2	52.7
-PATH	67.2	53.8

由表 2 可见, 在数据集 WebQSP-50 上删除关系记忆感知模块后, 准确率下降了 2.9 个百分点, 删除多跳路径矢量化模块后, 准确率下降了 1.8 个百分点. 表明这两个模块对 RMP-KGQA 模型的性能具有重要作用, 证明了本文模型在设计中添加路径信息和关系记忆的意义. 关系记忆感知模块能有效地将自然语言问句嵌入与知识图谱嵌入相联系, 从而解决了映射空间不同的问题, 并考虑了两者之间存在的潜在依赖关系; 而多跳路径矢量化模块能利用路径信息丰富评分函数, 从而提高知识图谱多跳问答检索系统的准确性和鲁棒性.

3.4 可解释性分析

利用可视化方法进行可解释性分析. 本文对模型预测的前 10 个答案 $E_{hit_{10}} = \{e_1, e_2, \dots, e_{10}\}$ 进行自相关性热力图的可视化, 并选取 8 组数据生成对应的热力图, 结果如图 3 所示.




图 3 答案嵌入自相关性热力图

Fig. 3 Heatmap of answer embedding autocorrelation

这些热力图展示了模型在嵌入空间中准确区分正确答案和错误答案的能力，主要表现在正确答案之间的嵌入相似度显著高于错误答案的嵌入相似度。自相关性的计算公式为

$$R(e_i, e_j) = \left[\sum_{k=1}^N (e_{i,k} - \bar{e}_i)(e_{j,k} - \bar{e}_j) \right] / \sqrt{\sum_{k=1}^N (e_{i,k} - \bar{e}_i)^2 \sum_{k=1}^N (e_{j,k} - \bar{e}_j)^2}, \quad (11)$$

其中 $R(e_i, e_j)$ 为嵌入向量 e_i 和 e_j 的自相关系数，实体嵌入向量 $e_i, e_j \in E$ ， $e_{i,k}$ 和 $e_{j,k}$ 为嵌入向量 e_i 和 e_j 在第 k 维的元素， \bar{e}_i 和 \bar{e}_j 为向量 e_i 和 e_j 的平均值， N 为嵌入向量的维度。

分析问题经过关系记忆感知模块处理前后嵌入向量与预测前 10 个答案嵌入向量之间的余弦相似度，并对 8 组数据生成对应的折线图，结果如图 4 所示。本文采用折线图进行可视化是因为它能有效揭示问题嵌入与答案嵌入的余弦相似度随答案排名的变化趋势，清晰地展示不同数据系列间的对比

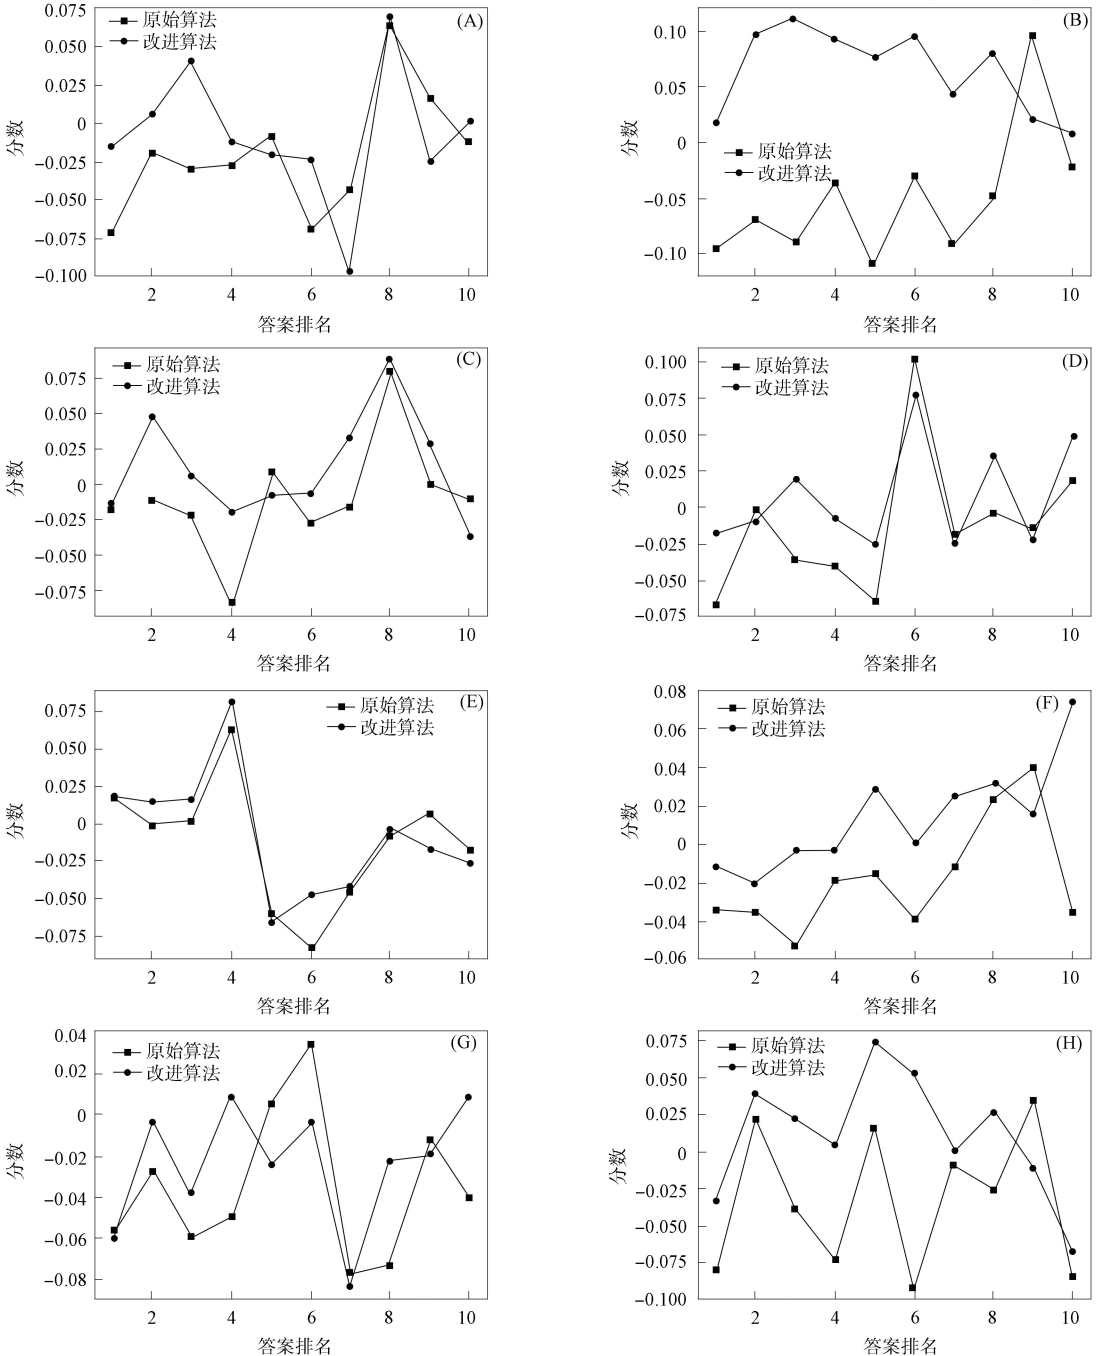


图 4 问题嵌入向量与答案嵌入向量的余弦相似度折线图

Fig. 4 Line graphs of cosine similarity between question embedding vectors and answer embedding vectors

差异, 并能反映数据的波动程度. 由图 4 可见, 经过关系记忆感知模块处理后的问题嵌入向量与正确答案的相似度普遍提高, 与错误答案的相似度则有所降低, 从而验证了关系记忆感知模块的有效性. 余弦相似度计算公式为

$$\text{Similarity} = \cos(\mathbf{e}_i, \mathbf{e}_q) = \frac{\sum_{i=1}^N (\mathbf{e}_i \times \mathbf{e}_q)}{\sqrt{\sum_{i=1}^N (\mathbf{e}_i)^2} \times \sqrt{\sum_{i=1}^N (\mathbf{e}_q)^2}}, \quad (12)$$

其中 $\cos(\mathbf{e}_i, \mathbf{e}_q)$ 是实体嵌入向量 \mathbf{e}_i 和问题嵌入向量 \mathbf{e}_q 的余弦值, 实体嵌入向量 $\mathbf{e}_i \in E$.

为更深入地理解模型性能, 本文选取一个案例进行分析. 在该案例中, 问题为“what else did ben franklin invent”, 预测的前 10 个答案为 Franklin stove, lightning rod, bifocal lens, glass harmonica, Boston, actor, Franklinton, Mobile, diplomat, Brevard County. 由图 3(A) 可见, 正确答案(答案 0, 1, 2, 3)之间的相关度很高, 与错误答案的相关度较低. 由图 4(A) 可见, 处理后的问题嵌入向量与正确答案的相似度提高, 与错误答案的相似度降低.

此外, 在可视化结果中, 自相关性热力图展示了模型在嵌入空间中明确区分正确和错误答案的能力. 同时, 折线图揭示了关系记忆感知模块能有效提升问题与正确答案之间的嵌入相似度, 降低与错误答案的相似度. 这些结果均验证了模块的有效性和提高模型预测性能的能力. 实验结果表明, RMP-KGQA 模型在知识图谱多跳问答领域具有较高的准确率, 并且关系记忆感知模块和多跳路径矢量化模块对提高模型性能具有重要作用.

综上所述, 针对自然语言处理领域中不完整知识图谱导致实体关联膨胀, 进而需进行额外推理和推断使答案的推导过程变得更复杂的问题, 本文提出了一种 RMP-KGQA 模型, 该模型结合了关系记忆网络和路径信息, 引入了关系记忆感知和多跳路径矢量化方法, 通过利用路径信息和关系记忆网络提高答案推断的准确率. 同时, RMP-KGQA 模型不局限于问题特定子图, 可通过利用 KG 嵌入的链接预测属性推断缺失链接的关系, 从而提高模型的鲁棒性. 实验结果表明, RMP-KGQA 模型性能优异, 尤其在处理复杂问题时的准确率明显高于其他模型.

参 考 文 献

- [1] 陈成, 陈跃国, 刘宸, 等. 意图知识图谱的构建与应用 [J]. 大数据, 2020, 6(2): 57-68. (CHEN C, CHEN Y G, LIU C, et al. Constructing and Analyzing Intention Knowledge Graphs [J]. Big Data, 2020, 6(2): 57-68.)
- [2] 社会芳, 王昊奋, 史英慧, 等. 知识图谱多跳问答推理研究进展、挑战与展望 [J]. 大数据, 2021, 7(3): 60-79. (DU H F, WANG H F, SHI Y H, et al. Progress, Challenges and Research Trends of Reasoning in Multi-hop Knowledge Graph Based Question Answering [J]. Big Data, 2021, 7(3): 60-79.)
- [3] XIONG W H, HOANG T, WANG W Y. DeepPath: A Reinforcement Learning Method for Knowledge Graph Reasoning [C]//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing. [S.l.]: ACL, 2017: 564-573.
- [4] MO Y, 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. [S.l.]: ACL, 2017: 571-581.
- [5] VARDHAN L, GUO J, KOK S. Probabilistic Logic Graph Attention Networks for Reasoning [C]//Proceedings of the 2020 International Conference on World Wide Web. New York: ACM, 2020: 669-673.
- [6] REN H Y, HU W H, LESKOVEC J. Query2box: Reasoning over Knowledge Graphs in Vector Space Using Box Embeddings [C]//8th International Conference on Learning Representations (ICLR). Washington DC: ICLR, 2020: 1-16.
- [7] CHEN Y, WU L F, ZAKI M J. Bidirectional Attentive Memory Networks for Question Answering over Knowledge Bases [C]//Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. [S.l.]: ACL, 2019: 2913-2923.

- [8] HUANG X, ZHANG J Y, LID C, et al. Knowledge Graph Embedding Based Question Answering [C]// Proceedings of the ACM International Conference on Web Search and Data Mining (WSDM). New York: ACM, 2019: 105-113.
- [9] TERU K K, DENIS E G, HAMILTON W L. Inductive Relation Prediction by Subgraph Reasoning [C]// Proceedings of the 37th International Conference on Machine Learning. New York: ACM, 2020: 9448-9457.
- [10] 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. [S.l.]: ACL, 2020: 4498-4507.
- [11] NIU G L, LI Y, TANG C G, et al. Path-Enhanced Multi-relational Question Answering with Knowledge Graph Embeddings [EB/OL]. (2021-10-29)[2023-04-22]. <https://arxiv.org/abs/2110.15622>.
- [12] WANG M, WANG R J, LIU J, et al. Towards Empty Answers in SPARQL: Approximating Querying with RDF Embedding [C]// Proceedingd of the 17th International Semantic Web Conference. Berlin: Springer, 2018: 513-529.
- [13] BORDES A, USUNIER N, GARCIA-DURAN A, et al. Translating Embeddings for Modeling Multi-relational Data [C]// Processing of the 26th Annual Conference on Neural Information Processing Systems. New York: ACM, 2013: 2315-2323.
- [14] LIN Y K, LIU Z Y, SUN M S, et al. Learning Entity and Relation Embeddings for Knowledge Graph Completion [C]// Proceedings of the AAAI Conference on Artificial Intelligence. New York: ACM, 2015: 2181-2187.
- [15] JI G L, HES S Z, XU L H, et al. Knowledge Graph Embedding via Dynamic Mapping Matrix [C]// Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing. [S.l.]: ACL, 2015: 687-696.
- [16] SUN Z Q, DENG Z H, NIE J Y, et al. RotatE: Knowledge Graph Embedding by Relational Rotation in Complex Space [C]// Proceedings of the 6th International Conference on Learning Representations. [S.l.]: ICLR, 2018: 1-18.
- [17] TROUILLON T, WELBL J, RIEDEL S, et al. Complex Embeddings for Simple Link Prediction [C]// Proceedings of the 33rd International Conference on Machine Learning. New York: ACM, 2016: 2071-2080.
- [18] LIU Y H, OTT M, GOYAL N, et al. RoBERTa: A Robustly Optimized BERT Pretraining Approach [EB/OL]. (2019-07-26)[2023-04-22]. <https://arxiv.org/abs/1907.11692>.
- [19] SANTORO A, FAULKNER R, RAPOSO D, et al. Relational Recurrent Neural Networks [C]// Advances in Neural Information Proceeding Systems 31 (NeurIPS 2018). New York: ACM, 2018: 7310-7321.
- [20] 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. [S.l.]: ACL, 2016: 201-206.
- [21] 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. [S.l.]: ACL, 2016: 1400-1409.
- [22] SUN H T, 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. [S.l.]: ACL, 2018: 4231-4242.
- [23] SUN H T, BEDRAX-WEISS T, COHEEN 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. [S.l.]: ACL, 2019: 2380-2390.

(责任编辑: 韩 啸)