

# 基于知识图谱关系路径的多跳智能问答模型研究

张元鸣, 姬琦, 徐雪松, 程振波, 肖刚

(浙江工业大学计算机科学与技术学院, 浙江杭州 310023)

**摘要:** 多跳问题是一类通过知识推理才能给出答案的复杂问题, 往往需要相关的多项关联知识融合生成最终答案. 现有基于知识图谱的多跳智能问答方法推理过程比较复杂, 没有考虑关系路径蕴含的结构信息和语义信息. 为此, 本文提出了基于知识图谱关系路径的多跳智能问答模型, 将多跳智能问答问题转换为在低维向量空间中查找知识图谱中最优关系路径的问题. 该模型利用表示学习将知识图谱和用户问题同时嵌入到低维的向量空间, 实现知识空间和问题空间的统一表示; 然后结合主题实体向量表示和问题向量表示对候选实体进行语义评分, 产生候选答案集合; 以问题实体为起始节点, 以候选答案实体为结束节点, 从知识图谱中抽取与问题相关的关系路径集合; 将关系路径进一步嵌入到低维的向量空间, 生成关系路径的向量表示, 在向量空间中查找与问题语义匹配度最高的关系路径, 最终根据关系路径生成多跳问题的答案. 在公开的数据集上对所提出的模型进行了实验, 结果表明该方法与现有方法相比不仅具有良好的性能, 而且具有良好的稳定性, 不会随着问题跳数的增加而降低性能.

**关键词:** 智能问答; 知识图谱; 复杂多跳问题; 关系路径; 表示学习

**基金项目:** 浙江省“尖兵”“领雁”研发攻关计划项目(No.2023C01022); 国家自然科学基金(No.61976193)

**中图分类号:** TP391.1

**文献标识码:** A

**文章编号:** 0372-2112(2023)11-3092-08

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.12263/DZXB.20230477

## Knowledge Graph Relation Path Network for Multi-Hop Intelligent Question Answering

ZHANG Yuan-ming, JI Qi, XU Xue-song, CHENG Zhen-bo, XIAO Gang

(College of Computer Science & Technology, Zhejiang University of Technology, Hangzhou, Zhejiang 310023, China)

**Abstract:** Complex multi-hop questions require knowledge reasoning to provide answers, which often involves integration of multiple pieces of knowledge to generate final answer. The existing knowledge graph (KG)-based multi-hop intelligent question answering methods often have complicated inference processes and do not consider structural and semantic information embedded in relation paths. To solve this problem, this paper proposes a knowledge graph relation path network for multi-hop intelligent question answering. It transforms the multi-hop intelligent question answering task into an optimization task of finding optimal relation path from KG. In this network, both the KG and question are embedded into low-dimensional vector spaces, and their unified vector representations are obtained. The topic entity and the question entity are combined to perform semantic scoring for generating candidate answers. Starting from the question entity and ending with candidate answers, a set of relation paths relevant to the question from the KG is extracted. The relation paths are further embedded into low-dimensional vector space to generate vector representations. By searching for the relation path with the highest semantic matching degree to the question in the vector space, the answer to the multi-hop question is generated. Experimental results on public datasets show that the proposed method has not only good performance but also good stability compared to the existing methods, and the performance does not decrease with the increase of problem hops.

**Key words:** knowledge graph; intelligent question answering; complex multi-hop question; relation path; representation learning

**Foundation Item(s):** “Pioneer” and “Leading Goose” R&D Program of Zhejiang Province China (No.2023C01022); National Natural Science Foundation of China (No.61976193)

## 1 引言

随着近年来信息技术的飞速发展,人类知识总量趋于指数级增长,智能问答综合运用信息检索、深度学习和自然语言处理等技术,充分理解用户语义,快速获得用户问题的精确答案,在搜索引擎、教育、金融、电商等领域具有广泛应用,成为当前自然语言处理领域的研究热点<sup>[1]</sup>.

知识图谱(Knowledge Graph, KG)以图结构方式刻画现实世界中实体与实体之间的关联关系,是一种结构化的语义知识库<sup>[2]</sup>. 基于知识图谱的智能问答以自然语言的形式提出问题即可获得答案<sup>[3]</sup>,避免通过结构化查询语言来表述需求. 对于简单的单跳问题,智能问答根据问题语义找到最优的单个三元组作为问题答案. 对于复杂的多跳问题,智能问答需要通过知识推理融合多个三元组生成问题答案<sup>[4,5]</sup>,主要分为基于模板的方法<sup>[6-8]</sup>、基于语义匹配的方法<sup>[9-12]</sup>和基于表示学习的方法. 基于模板匹配的方法针对特定知识领域和用户问题设计严密的问题模板,再利用模板匹配生成答案,但性能依赖于模板数量,难以全面覆盖用户问题和知识库. 基于语义解析的方法通过分析用户问题的语义组成,将用户问题转换为逻辑形式或结构化查询,但语义分析的级联误差将降低答案的准确性.

基于表示学习的方法则将知识库和用户问题特征嵌入到低维向量空间,通过向量计算进行知识推理,是目前智能问答研究的主流技术<sup>[13]</sup>. Sun 等<sup>[14]</sup>提出 GraftNet (Graphs of relations among facts and text Networks)智能问答模型,将结构化数据与大规模的文本数据融合,为智能问答提供丰富的上下文信息. Sun 等<sup>[15]</sup>进一步提出了 PullNet 模型,根据问题迭代生成相关子图,利用图神经网络对节点进行表示学习并提取答案. Zhang 等人<sup>[16]</sup>提出了 VRN (Variational Reasoning Network)模型,通过变分推理建立问题答案概率,实现知识图谱多跳问答. Saxena 等<sup>[17]</sup>基于链接预测思想,将知识图谱中的所有实体作为候选答案集合,为主题实体、问题和候选答案组成的三元组打分,选择得分最高的实体作为答案. Qiu 等<sup>[18]</sup>提出的 SRN (Stepwise Reasoning Network)模型基于强化学习在弱监督条件下由主题实体出发,沿知识图谱中的路径逐步搜索答案. William 等<sup>[19]</sup>提出的 ReifKB (Reified Knowledge Base)模型使用稀疏矩阵建模知识图谱,通过矩阵运算模拟知识图谱多跳推理过程. Shi 等<sup>[20]</sup>模拟每一跳实体和关系状态的变化,动态维护不同时间状态下每个实体的得分,预测问题的跳数概率并进行加权得到目标实体的最终得分. Li 等<sup>[21]</sup>提出的 SSKQA (Semantic Structure based framework for Knowledge graph Question Answering)模型预定义了问题可能满足的 6 种语义结构,先通过 BERT 模型预测最符合问题语义的语义结构,然后在知识图谱中检索符合语义结构的查询图,生成问题的答案.

现有基于表示学习的方法往往从问题的主题实体出发在知识图谱上通过逐步推理寻求问题答案,没有考虑多跳问题中关系路径蕴含的结构信息和语义信息,难以充分捕捉实体之间的复杂关系. 针对该问题,本文提出新的基于知识图谱关系路径的多跳智能问答模型,建立主题实体到答案实体之间的关系路径,并将关系路径嵌入到低维向量表示,在向量空间中查找与问题语义匹配度最高的关联路径,再根据最优关系路径生成最终答案,简化了多次检索知识图谱子图多步推理过程,具有良好的性能和适用性.

## 2 问题描述

知识图谱本质上是一种结构化语义网络,通常用<实体-属性-属性值>与<头实体-关系-尾实体>三元组方式表达,为知识推理提供了结构化知识库.

**定义 1 知识图谱** 知识图谱  $G = \{E, R, F\}$ , 其中,  $E = \{e_1, e_2, \dots, e_M\}$  表示实体集合,  $R = \{r_1, r_2, \dots, r_n\}$  表示关系集合,  $F = \{(h, r, t) | h, t \in E, r \in R\}$  为三元组集合, 其中,  $h$  为头实体,  $t$  为尾实体,  $r$  为关系.

**定义 2 主题实体** 主题实体是指问题中出现的实体,且可以无歧义地链接到知识图谱中唯一的目标实体,是问答推理的起点.

**定义 3 多跳问题** 多跳问题包含了实体和多个关系的自然语言问题,需要通过知识推理才能获得答案.

**定义 4 关系路径** 关系路径是知识图谱的关系序列,给定路径  $(h, r_1, e_1, r_2, \dots, e_{n-1}, r_n, a)$ , 其中  $h$  是主题实体,  $r_i (1 \leq i \leq n)$  为关系,  $e_i (1 \leq i \leq n-1)$  为中间实体,  $n$  为跳数,该路径对应的关系路径为  $\{r_i\}_{i=1}^n$ .

多跳智能问答可以形式化描述为:在知识图谱  $G$  上,根据主题实体  $h$ 、关系路径  $l$  给出问题  $q$  的答案集合  $A_q \subseteq E, \forall a \in A_q$  是问题  $q$  正确的答案实体. 本文假定问题的所有答案都是知识图谱中的实体,且每个问题只包含一个主题实体.

## 3 多跳智能问答网络模型

为了提高多跳智能问答的性能,本节给出了一个知识图谱关系路径网络模型 (Knowledge Graph Relationship Path Network, KGRPN),将问题与答案涉及的关联知识映射到知识图谱的关联路径,将智能问答问题转换为知识图谱以主题实体为开始节点的最优关联路径查找问题. 图 1 给出了模型的整体框架,该模型主要包括统一表示学习层、候选答案筛选层和关系路径表示学习层. 统一表示学习层分为知识图谱表示学习模块和用户问题表示学习模块,其中知识图谱表示学习模块将实体和关系进行向量表示,用户问题表示学习模块是对用户提出的问题进行了向量表示,并将其映射到与知识图谱相

同的向量空间;候选答案筛选层从知识图谱中提取主题实体的所有可达实体,筛选与问题语义相关的实体作为候选答案;关系路径表示学习层从知识图谱中抽取与主

题实体相关的关系路径,并将关系路径嵌入到低维的向量空间;根据问题语义相似度查找最优关系路径,生成问题最终答案.

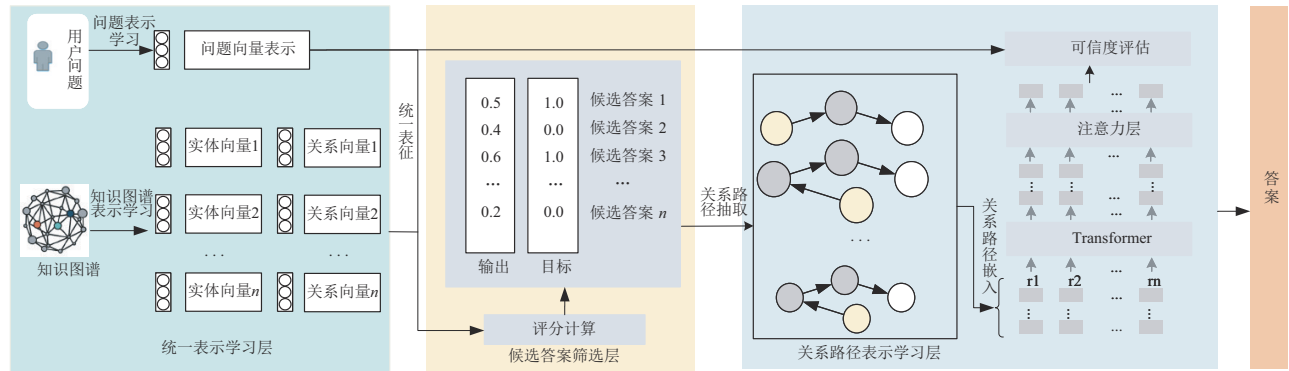


图1 知识图谱关系路径网络模型整体框架

### 3.1 统一学习表示层

#### 3.1.1 知识图谱表示学习

知识图谱表示学习旨在将知识图谱中实体和关系的语义信息嵌入到低维向量空间,增强智能问答的准确性.本框架采用 ComplEx 表示学习模型<sup>[22]</sup>,该模型能够将知识图谱中的实体和关系嵌入为包含实部和虚部的复向量,在保留点积运算计算效率优势的基础上,使实体的非对称关系能够得到不同的表征.

给定三元组  $(h, r, t)$ ,通过 ComplEx 模型学习实体和关系的向量表示,定义如下:

$$\begin{aligned} \phi(h, r, t) &= \text{Re}(\langle e_h, e_r, \bar{e}_t \rangle) \\ &= \text{Re}\left(\sum_{k=1}^d e_h^{(k)} e_r^{(k)} \bar{e}_t^{(k)}\right) \end{aligned} \quad (1)$$

其中,函数  $\phi$  是得分函数,  $e_h \in \mathbf{C}^d$  是头实体的向量表示,  $e_r \in \mathbf{C}^d$  是关系的向量表示,  $e_t \in \mathbf{C}^d$  是尾实体的共轭向量表示,  $\text{Re}(\bullet)$  表示复数的实数部分,  $d$  是向量表示的维度.

为了区分正确和错误的语义关系,训练过程不仅需要利用已有的正例三元组,还需要构造负例三元组.将知识图谱中的三元组作为正例  $f^+$ ,随机选择其他实体替换三元组的尾实体或其他关系替换原有关系以构建负例三元组  $f^-$ ,定义以下损失函数:

$$L = \min \sum_{f \in f^+ \cup f^-} \log(1 + \exp(-y_f \phi(h, r, t))) \quad (2)$$

通过迭代训练,使正例三元组  $\phi(h, r, t) > 0$ ,使负例三元组  $\phi(h, r, t) < 0$ .对于正例三元组  $f \in f^+$ ,  $y_f = 1$ ,对于负例三元组  $f \in f^-$ ,  $y_f = -1$ .

#### 3.1.2 问题表示学习

问题表示学习旨在将用户提出的问题也嵌入到低维向量空间,并将该向量映射到与知识图谱相同的向量空间.本模型采用 RoBERTa 预训练语言模型捕捉多跳问题

隐含的丰富语义信息,该模型根据输入的自然语言问句能够生成融合文本上下文信息的深层双向语言表征<sup>[23]</sup>.

给定多跳问题  $q = (w_1, w_2, \dots, w_q)$ ,其中主题实体  $h \in E$ ,答案实体集合  $A_q \subseteq E$ ,先通过 tokenizer 对问题进行文本预处理,并在头尾添加两个位置标记 [CLS] 和 [SEP],输入 RoBERTa 模型得到问题中每个单词的上下文表示,取倒数第二个隐藏层的平均语义向量作为问题的向量表示  $Q$ :

$$Q = \text{Mean}(\text{RoBERTa}([\text{CLS}], w_1, \dots, w_q, [\text{SEP}])) \quad (3)$$

然后,利用全连接网络将问题的向量表示  $Q$  转换到知识图谱所在的向量空间中,得到问题新的向量表示:

$$e_q = W_2(\sigma(W_1 Q + b_1)) + b_2 \quad (4)$$

其中,  $e_q \in \mathbf{C}^d$ ,  $W_1$  和  $W_2$  代表可训练的权重矩阵,  $b_1$  和  $b_2$  代表可训练的偏置项,  $\sigma$  代表激活函数.

为了使问题的向量表示能够表达多跳语义信息,本文仍采用 ComplEx 模型进行训练,利用交叉熵损失函数进行迭代训练,当实体是问题的答案时,得分函数的值大于零,该实体作为答案实体;当实体不是问题的答案时,得分函数的值小于零,该实体不作为答案实体,计算公式为

$$\begin{cases} \phi(e_h, e_q, e_a) > 0, & \text{当 } a \in A_q \\ \phi(e_h, e_q, e_a) < 0, & \text{当 } a \notin A_q \end{cases} \quad (5)$$

其中,  $A_q$  是答案实体集合,  $e_h$  是主题实体的向量表示,  $e_q$  是问题的向量表示,  $e_a$  是答案实体的向量表示.

### 3.2 候选答案筛选层

候选答案筛选是从知识图谱中选择候选答案实体,提高下游关系路径推理的准确性.在向量空间中,根据问题向量表示的语义信息和主题实体向量表示的特征信息评价答案实体的可信度,从而快速筛选出语义相关的实体作为候选答案.将问题视为主题实体和答案实体之间的语义联系,根据已经得到的向量表示

计算语义评分,计算公式为

$$s_{h,q,c} = \text{Re}(\langle \mathbf{e}_h, \mathbf{e}_q, \bar{\mathbf{e}}_c \rangle) \quad (6)$$

$$= \text{Re}(\sum_{k=1}^d \mathbf{e}_h^{(k)} \cdot \mathbf{e}_q^{(k)}, \bar{\mathbf{e}}_c^{(k)})$$

其中,  $s_{h,q,c}$  为实体的语义评分,  $\mathbf{e}_h$  是主题实体的向量表示,  $\mathbf{e}_c$  是答案实体的向量表示,  $\mathbf{e}_q$  是问题的向量表示,  $\text{Re}(\bullet)$  表示向量表示的实数部分.

通过计算实体的语义评分,最终选择评分排名前 Top-N 个实体作为问题的候选答案集合,作为关系路径抽取的依据.

### 3.3 关系路径表示学习层

关系路径是指在知识图谱中主题实体到候选答案实体依次经过的关系的序列,而跳数则表示关系路径的长度. 如果关系路径长度为 1,则是简单问题;如果关系路径长度大于 1,则是多跳问题. 对于多跳问题,需要通过融合关系路径的关联知识生成最终答案.

从知识图谱中抽取以主题实体为起点、候选答案实体为终点的所有关系路径,其中关系路径的长度需小于设定的最大跳数,并剔除重复的关系路径,关系路径示意图如图 2 所示.

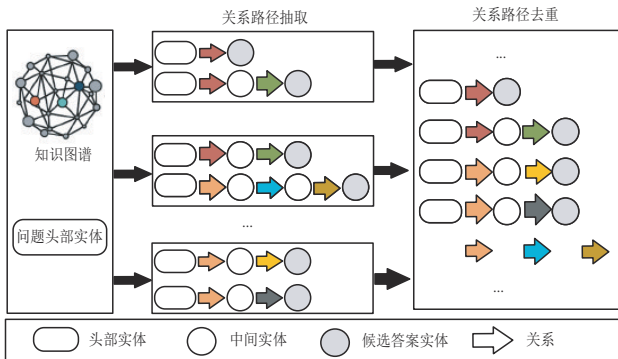


图2 关系路径示意图

将每个关系的向量表示进一步融合生成关系路径的向量表示. 本文采用 Transformer 网络<sup>[24]</sup>和全局注意力机制生成关系路径的向量表示,关系路径的表示学习网络模型如图 3 所示. Transformer 是一种基于自注意力机制的序列编码模型,该模型包括 Encoder 和 Decoder 两个部分,Encoder 包含 6 层叠加的 Transformer-block,每个 Transformer-block 包含多头注意力机制、残差连接、层归一化、全连接网络四个部分,输入为句子词汇的词向量编码和位置编码之和,其中位置编码层的目的是区分句子中词的位置关系能学习到输入序列与输出序列之间的对应关系.

关系路径中所有关系的向量表示构成了一个向量表示序列. 模型利用多头注意力机制提取向量表示序列的特征信息,不同注意力头得到的结果拼接并点乘

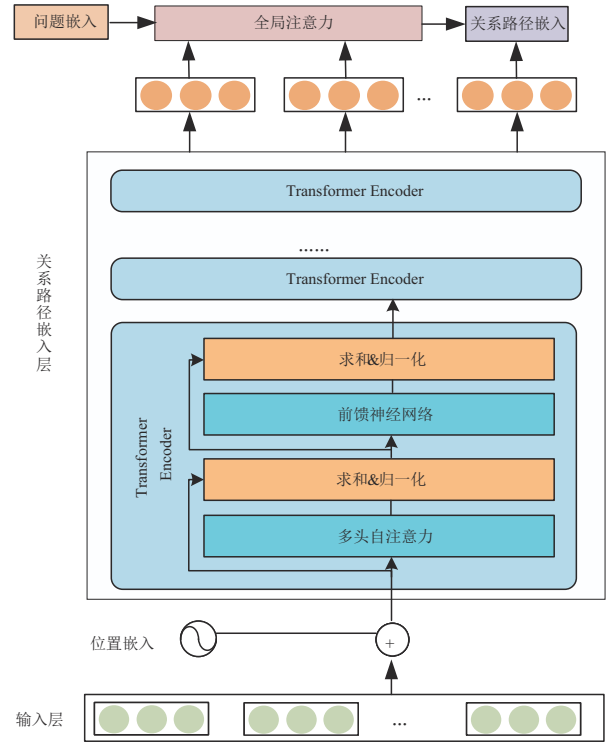


图3 关系路径表示学习模型

权重矩阵得到多头注意力的输出,再通过残差连接与前馈神经网络进行处理,得到融合序列特征的新向量表示,然后将问题的表示向量和关系路径中每个关系的向量表示进行点积运算,生成全局注意力矩阵,聚合不同关系的语义特征,生成整个关系路径的向量表示.

通过 Transformer 网络提取关系路径特征,计算不同注意力头下的注意力概率分布,计算公式为

$$f_{att(i)} = \text{softmax}(\frac{\mathbf{Q}_i \mathbf{K}_i^T}{\sqrt{d_k}}) \mathbf{V}_i \quad (7)$$

其中,  $\mathbf{Q}_i$ ,  $\mathbf{K}_i$  和  $\mathbf{V}_i$  分别为在不同注意力头问题对应的查询矩阵、键矩阵、值矩阵,并在训练过程中优化和迭代,  $d_k$  代表  $\mathbf{Q}_i$  和  $\mathbf{K}_i$  的维度. 根据注意力概率分布,再计算多头注意力的输出矩阵,计算公式为

$$\mathbf{X}_{\text{multi-head}} = \text{concat}(f_{att(1)}, f_{att(2)}, \dots, f_{att(n)}) \mathbf{W}_O \quad (8)$$

其中,  $n$  代表注意力头数,  $\mathbf{W}_O$  为输出变换矩阵.

将  $\mathbf{X}_{\text{multi-head}}$  经过残差连接、前馈神经网络和正则化层生成与关系路径长度相同的向量表示,计算公式为

$$\mathbf{X}_{\text{residual}} = \text{norm}(\mathbf{X}_{\text{multi-head}} + \mathbf{e}) \quad (9)$$

$$\hat{\mathbf{X}} = \text{norm}(\mathbf{X}_{\text{residual}} + \text{FFN}(\mathbf{X}_{\text{residual}})) \quad (10)$$

其中,  $\mathbf{e}$  为多头注意力的输入矩阵.

根据关系路径的向量表示序列生成整个关系路径的向量表示. 先计算问题的向量表示与每个关系的权重系数,计算公式为

$$\alpha_i = \frac{e_q \cdot x_i}{t \|x_i\| \|e_q\|} \quad (11)$$

其中,  $e_q$  是问题的向量表示,  $x_i$  是关系的向量表示,  $t$  是缩放系数.

对每个关系的权重系数进行归一化, 计算公式为

$$a_i = \text{softmax}(\alpha_i) \quad (12)$$

根据权重系数对关系路径的向量表示序列加权求和, 得到整个关系路径的向量表示  $p$ :

$$p = \sum_{i=1}^n a_i x_i \quad (13)$$

上述公式将产生代表整个关系路径的向量表示, 其嵌入了多跳问题候选答案的关联三元组信息.

### 3.4 模型训练

为了从候选关系路径中查找最优关系路径, 本模型使用三元组损失函数<sup>[25]</sup>, 该函数使用锚点、正样本和负样本组成三元组, 其中锚点和正样本类别相同, 锚点与负样本类别不同. 通过训练使正样本与锚点在向量空间中的位置接近, 使负样本与锚点的位置远离, 最小化同类别样本之间的距离, 并最大化不同类别样本之间的距离, 其训练原理如图4所示.

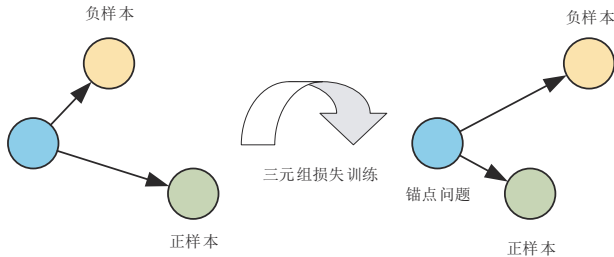


图4 三元组损失函数训练原理

本模型将问题视为锚点, 主题实体到正确答案之间的关系路径标记为正样本, 其他关系路径标记为负样本, 采用上述方式进行训练, 计算公式为

$$L = \sum_{i=1}^N \left[ \left\| e_q - p_i^+ \right\|_2^2 - \left\| e_q - p_i^- \right\|_2^2 + \theta \right]_+ \quad (14)$$

其中,  $N$  为构建的三元组样本个数,  $e_q$  是问题的向量表示,  $p_i^+$  是正样本的向量表示,  $p_i^-$  为负样本的向量表示,  $\|\cdot\|_2^2$  代表计算两个向量表示的欧式距离,  $\theta$  用于确保模型学习到的同类别样本之间的距离要比不同类别样本之间的距离更小,  $[\cdot]_+$  为 hinge 函数, 计算公式为

$$\text{hinge}(x) = \max(x, 0) \quad (15)$$

根据上述方式得到问题的最优关系路径, 再结合知识图谱生成问题的最优答案.

## 4 实验评价

本节详细给出了实验数据集、评价指标、实验结果

和消融实验结果.

### 4.1 实验环境

在 MetaQA<sup>[16]</sup> 和 WebQuestionsSP<sup>[26]</sup> 两个公开的问答数据集上对本文提出的 KGRPN 进行了评价. MetaQA 是一个电影知识图谱的问答数据集, 包括 43 234 个实体、9 种关系和 133 582 个三元组构成, 拥有 40 万余个问答数据集, 问题的跳数分为 1 跳、2 跳和 3 跳. WebQuestionsSP 是基于 Freebase 知识图谱构建的问答数据集, 包括 1 886 633 个实体、572 种关系和 5 780 246 个三元组, 是目前使用最广泛的问答数据集之一, 该数据集没有明确区分问题跳数, 但绝大多数问题都能够两跳范围内推理解答. 实验数据集在训练集、测试集和验证集上的划分情况如表 1 所示.

表1 数据集的规模统计分布

数据集	训练集	测试集	验证集
MetaQA 1-hop	96 106	9 992	9 947
MetaQA 2-hop	118 948	14 872	14 872
MetaQA 3-hop	114 196	14 274	14 274
WebQuestionsSP	2 998	100	1 639

本文采用智能问答领域广泛使用的 Hit@N 评估指标对模型性能进行评价, 该指标的含义为问题的正确答案在得分排名前  $N$  实体中的平均占比, Hit@N 的值越高代表模型的问答性能越好, 计算公式为

$$\text{Hit}@N = \frac{1}{|Q|} \sum_{i=1}^{|Q|} \prod_{x \leq N} (\text{rank}_i) \quad (16)$$

其中,  $Q$  表示问题的总数, 如果问题  $q_i$  的正确答案实体排名小于  $N$ , 即  $\text{rank}_i \leq N$ , 则  $\prod_{x \leq N} (\text{rank}_i) = 1$ , 否则当  $\text{rank}_i \geq N$  时,  $\prod_{x \leq N} (\text{rank}_i) = 0$ .

本文将所提出的模型与基于知识图谱的代表性智能问答模型进行对比, 包括 GraftNet<sup>[14]</sup>、PullNet<sup>[15]</sup>、VRN<sup>[16]</sup>、EmbedKGQA<sup>[17]</sup>、SRN<sup>[18]</sup>、ReifKB<sup>[19]</sup>、TransferNet<sup>[20]</sup>、SSKGQA<sup>[21]</sup>, 这些方法在前文已做了介绍.

### 4.2 实验结果

本文在 Pytorch 深度学习框架实现了 KGRPN 模型, 并采用 Adam 算法进行参数更新, 操作系统为 Ubuntu Server 18.04.1 LTS 64 位, CPU 为 Intel Xeon Gold 6133 @ 2.5 GHz, GPU 为 NVIDIA Tesla V100. ComplEx 算法的维度设置为 256, 且在后续的训练过程中, 维度保持不变. 预训练语言模型 RoBERTa 采用 Transformers 库的 roberta-base 版本的模型, 它由 12 层 Transformer 的编码层堆叠组成, 隐藏层为 768 维, 多头注意力的 head 数为 12. 学习率设置为  $2 \times 10^{-5}$ , batchsize 为 32, 最多训练 50 轮, 每轮训练后学习率进行指数衰减且  $\text{gamma}=0.1$ , 最终输出的候选答案实体集合大小为 10. 关系路径的向量表示由 4 层 Transformer 的编码器堆叠而成, 其隐藏层

为 256 维,多头注意力头数为 16,前馈神经网络部分使用 gelu 激活函数.学习率设置为  $5 \times 10^{-3}$ ,batchsize 为 8,最多训练 100 轮,三元组损失函数  $\theta$  值设置为 2.

表 2 给出了本模型与对比模型在两个数据集上的实验结果.根据该结果,可以看出本文提出的 KGRPN 模型在这些数据集上尽管性能不是最好,但表现最为稳健.在多跳情况下,EmbedKGQA 模型通过分析问题和知识图谱每类关系的相关性计算关系路径的可信度,而 KGRPN 模型考虑了关系路径的顺序语义和复合语义.在 MetaQA 的 2-hop 和 3-hop 数据集上,TransferNet 模型的性能最好,但该模型每一跳都需要维护一个代表实体间转移概率的矩阵,通过大量矩阵运算模拟每跳的关系选择,以实现复杂的推理过程.与该模型相比,KGRPN 模型则通过特征向量匹配最符合问题语义的关系路径,不需要复杂的矩阵运算.WebQuestionsSP 数据集具有百万级的知识图谱实体,但包含非常少的问答记录,因此这些智能问答模型在该数据集上的性能较低.在 MetaQA 的 1-hop 和 WebQuestionsSP 数据集上,SSKGQA 模型的性能最好,但该模型需要预先定义问题的语义结构,根据预测的问题语义结构在知识图谱中检索符合问题语义结构的查询图.与该模型相比,KGRPN 模型不需要预先定义问题的语义结构,而是以知识图谱中包含的关系和关系间的顺序语义信息为基础,识别最符合问题语义的关系路径来生成问题答案,具有更好的适用性.

表 2 对比实验结果

模型	MetaQA			WebQuestions SP
	1-hop	2-hop	3-hop	
VRN	97.5	89.9	62.5	—
GraftNet	97.0	94.8	77.7	66.4
PullNet	97.0	99.9	91.4	68.1
SRN	97.0	95.1	75.2	—
ReifKB	96.2	81.1	72.3	52.7
EmbedKGQA	97.5	98.8	94.8	66.6
TransferNet	97.5	<u>100.0</u>	<u>100.0</u>	68.3
SSKGQA	<u>99.2</u>	99.5	99.5	<u>70.9</u>
KGRPN	97.8	99.4	96.2	68.7

### 4.3 消融实验

先单独考察候选答案筛选模块性能,实验结果如表 3 所示,可以看出候选答案筛选模块能够生成高质量的候选答案集合,在 MetaQA 数据集中几乎所有问题的答案均被正确提取到候选答案集合中,在 WebQuestionsSP 数据集的实验中 Hit@10 值仍然能够达到 78.8%.然而,如果简单地选择候选答案筛选模块生成的语义评分最高的实体作为答案,在 MetaQA 2-hop 数据集上的 Hit@1 值只能达到 86.0%,在 WebQuestionsSP 数据集上的 Hit@1 值只能达到 48.1%,与表 2 中完整模型的性能

相比具有较大的差距.因此,如果不考虑关系路径包含的关系语义和关系间的顺序信息,模型的性能将显著下降,证明了关系路径推理模块的重要性.

表 3 候选答案筛选模型性能实验结果

数据集	Hit@1	Hit@5	Hit@10
MetaQA 2-hop	86.0	99.5	99.9
MetaQA 3-hop	85.8	98.4	99.6
WebQuestionsSP	48.1	74.6	78.8

再考察关系路径表示学习模块中注意力机制对性能的影响,本文在 WebQuestionsSP 数据集上分析了不同向量表示生成方法对性能的影响,实验结果如表 4 所示.根据该实验结果,可知注意力机制的性能最好.相较于平均池化方法,注意力机制能够更好地捕捉向量表示序列的全局语义,使问题和关系序列更关注彼此相关的部分,而采用最大池化策略会导致序列的语义不完整.

表 4 注意力机制对性能的影响

模块设置	WebQuestionSP Hit@1
注意力机制	68.7
平均池化	66.1
最大池化	57.6

使用热力图对问题和关系路径之间的注意力分布进行了可视化,每个热力图的单元格对应一个关系的注意力系数.图 5 给出了两个问题的注意力可视化示例,图 5(a)是 MetaQA 3-hop 数据集中的问题“who acted in the movies directed by the director of Zouzou”,该问题答案的关系路径包括“directed\_by”“directed\_by\_reverse”和“starred\_actors”三个关系,它们的注意力系数分别为 0.38、0.28、0.34;图 5(b)是 MetaQA 3-hop 数据集中的问题“in which years were movies released which starred actors who appeared in the movie Thunderbolt”,该问题答案的关系路径包括“starred\_actors\_reverse”“starred\_actors”“release year”三个关系,它们的注意力系数分别为 0.37、0.26、0.37.在生成关系路径的特征向量时,每个关系对路径的整体语义贡献不同.

最后考察关系路径的长度对性能的影响.最大关系路径长度  $L$  是影响关系路径检索范围的主要参数,本文通过设置该参数来控制关系路径的抽取策略,以观察抽取策略对性能的影响,实验结果如表 5 所示.根据该实验结果,对于只包含三跳问题的 MetaQA 3-hop 数据集,当  $L=3$  时本模型的性能最高;对于只包含两跳问题和单跳问题的 WebQuestionsSP 数据集,当  $L=2$  时模型性能最高.因此,当最大关系路径长度等于数据集的最大问题跳数时,可以抽取完整的关系路径语义信息,问答性能最好;当最大关系路径长度小于数据集的最

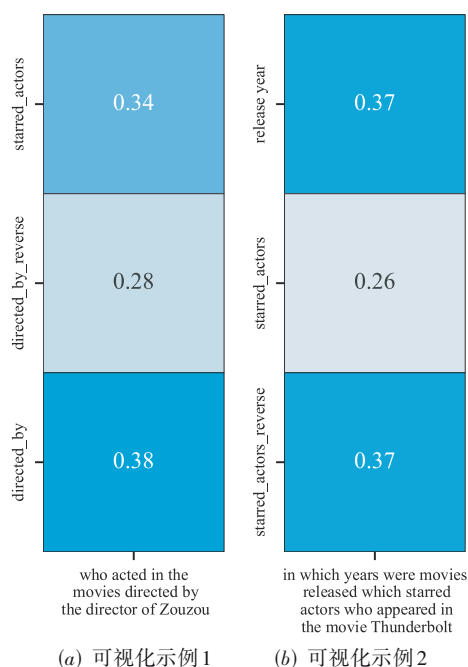


图5 关系路径中每个关系的注意力系数热力图

大问题跳数时,问答性能将会下降.

表5 最大关系路径长度对性能的影响

数据集	$L=1$	$L=2$	$L=3$	$L=4$
MetaQA 3-hop	55.1	80.6	96.2	94.7
WebQuestionsSP	53.6	71.4	68.7	67.3

## 5 结论

针对复杂多跳问题在知识推理中难以提取关系路径蕴含的结构信息和语义信息的问题,本文提出了基于知识图谱关系路径的多跳智能问答模型,通过表示学习实现了知识图谱和自然语言问题的统一表示,将知识图谱和问题映射到同一向量空间中.从知识图谱中抽取与问题相关的关系路径集合,并利用Transformer网络学习关系路径的语义和结构信息,在向量空间推理候选关系路径集合中最符合问题语义的关系路径,生成候选答案.本方法可以应用于智能搜索、电子商务和金融等领域,有效提高智能问答的精准度.

### 参考文献

[1] LIN Y H, SHEN H Y. SmartQ: A question and answer system for supplying high-quality and trustworthy answers[J]. IEEE Transactions on Big Data, 2018, 4(4): 600-613.

[2] JI S X, PAN S R, CAMBRIA E, et al. A survey on knowledge graphs: Representation, acquisition, and applications [J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(2): 494-514.

[3] 李凤英, 何晓蝶, 董荣胜. 融合语义信息的知识图谱多跳推理模型[J]. 模式识别与人工智能, 2022, 35(11): 1025-1032.

LI F Y, HE X D, DONG R S. Multi-hop inference model for knowledge graphs incorporating semantic information[J]. Pattern Recognition and Artificial Intelligence, 2022, 35 (11): 1025-1032. (in Chinese)

[4] LINJORDET T, BALOG K. Would you ask it that way? Measuring and improving question naturalness for knowledge graph question answering[C]//Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2022: 3090-3098.

[5] CHAKRABARTI S. Interpretable complex question answering[C]//Proceedings of the Web Conference 2020. New York: ACM, 2020: 2455-2457.

[6] 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. New York: ACM, 2017: 1191-1200.

[7] DING J W, HU W, XU Q X, et al. Leveraging frequent query substructures to generate formal queries for complex question answering[C]//Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP). Stroudsburg: Association for Computational Linguistics, 2019: 2614-2622.

[8] CHEN Y R, LI H Y, HUA Y C, et al. Formal query building with query structure prediction for complex question answering over knowledge base[C]//Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence. Menlo Park: AAAI, 2021: 3751-3758.

[9] DENG Y, XIE Y X, LI Y L, et al. Multi-task learning with multi-view attention for answer selection and knowledge base question answering[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2019, 33(1): 6318-6325.

[10] 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. Stroudsburg: Association for Computational Linguistics, 2020: 969-974.

[11] 高留杰, 赵文, 张君福, 等. G2S:基于语义块的知识图谱问答语义解析[J]. 电子学报, 2021, 49(6): 1132-1141.

GAO L J, ZHAO W, ZHANG J F, et al. G2S: Semantic segment based semantic parsing for question answering over knowledge graph[J]. Acta Electronica Sinica, 2021, 49(6): 1132-1141. (in Chinese)

[12] 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, 2018, 30(5): 824-837.

[13] LAN Y S, HE G L, JIANG J H, et al. A survey on complex knowledge base question answering: Methods, challenges and

solutions[C]//Proceedings of the Thirtieth International Joint Conference on Artificial Intelligence. Menlo Park: AAAI, 2021: 4483-4491.

- [14] 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. Stroudsburg: ACL, 2018: 4231-4242.
- [15] SUN H T, BEDRAX-WEISS T, COHEN 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. Stroudsburg: ACL, 2019: 2380-2390.
- [16] ZHANG Y Y, DAI H J, KOZAREVA Z, et al. Variational reasoning for question answering with knowledge graph [C]//32nd AAAI Conference on Artificial Intelligence. Menlo Park: AAAI, 2018: 2787-2795.
- [17] 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. Stroudsburg: ACL, 2020: 4498-4507.
- [18] QIU Y Q, WANG Y Z, JIN X L, et al. Stepwise reasoning for multi-relation question answering over knowledge graph with weak supervision[C]//Proceedings of the 13th International Conference on Web Search and Data Mining. New York: ACM, 2020: 474-482.
- [19] COHEN W W, SUN H T, HOFER R A, et al. Scalable neural methods for reasoning with a symbolic knowledge base [C]//International Conference on Learning Representations. New York: OpenReview, 2020: 1-17.
- [20] SHI J X, CAO S L, HOU L, et al. TransferNet: An effective and transparent framework for multi-hop question answering over relation graph[C]//Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing. Punta Cana: ACL, 2021: 4149-4158.
- [21] LI M C, JI S H. Semantic structure based query graph prediction for question answering over knowledge graph[C]// Proceedings of the 29th International Conference on Computational Linguistics. Gyeongju: International Committee on Computational Linguistics, 2022: 1569-1579.
- [22] 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.
- [23] LIU Y, OTT M, GOYAL N, et al. Roberta: A robustly optimized BERT pretraining approach[EB/OL]. (2019-05-26) [2023-07-26]. <https://arxiv.org/abs/1907.11692>.
- [24] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Process-

ing Systems, 2017, 30(12): 5998-6008.

- [25] SCHROFF F, KALENICHENKO D, PHILBIN J. FaceNet: A unified embedding for face recognition and clustering[C]// 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2015: 815-823.
- [26] 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 (Volume 2: Short Papers). Stroudsburg: ACL, 2016: 201-206.

### 作者简介



**张元鸣** 男, 1977年10月出生于河南省濮阳市。现为浙江工业大学计算机学院副教授、硕士生导师。主要研究方向为图神经网络、知识图谱、大数据处理和故障预测等。

E-mail: zym@zjut.edu.cn



**姬琦** 男, 1998年9月出生于辽宁省阜新市。2023年毕业于浙江工业大学计算机科学与技术学院。主要研究方向为知识图谱。

E-mail: jiqicims@163.com



**徐雪松** 男, 1992年11月出生于安徽省芜湖市。现为浙江工业大学计算机科学与技术学院博士后。主要研究方向为知识工程、智能制造、数字化设计等。

E-mail: song885280@zjut.edu.cn



**程振波** 男, 1975年生于江西省鄱阳县。现为浙江工业大学计算机科学与技术学院副教授、硕士生导师。主要研究方向为强化学习、决策的计算模型和脑启发的智能算法等。

E-mail: czb@zjut.edu.cn



**肖刚(通讯作者)** 男, 1965年4月出生。现为浙江工业大学计算机学院教授、博士生导师。主要研究方向为数据治理、智能制造、数字孪生等。

E-mail: xg@zjut.edu.cn