

# 基于门控思想的改进交互关系提取的多跳阅读理解研究

何奏捷<sup>1</sup>, 杜逆索<sup>1,2</sup>, 欧阳智<sup>1,2</sup>

<sup>1</sup>贵州大学数学与统计学院, 贵州 贵阳

<sup>2</sup>贵州大学贵州省大数据产业发展应用研究院, 贵州 贵阳

收稿日期: 2022年3月17日; 录用日期: 2022年4月29日; 发布日期: 2022年5月5日

## 摘要

多跳阅读理解需要搜集多个支持文档中的各个证据, 然后利用搜集到的证据, 进行多级跳跃的推理过程确认答案。目前图神经网络被大量运用在解决多跳阅读理解问题, 针对目前图神经网络相关模型中问题与节点的交互信息提取不充分的问题, 提出基于门控思想的改进交互关系提取的多跳阅读理解模型。首先, 将支持文档中与候选答案或问题中实体完全一致的词作为实体图节点, 将同一段落中的不同实体相连, 不同段落中的同一实体相连成边构建实体图。然后, 对提取的实体进行信息编码处理, 并通过图卷积网络模拟推理过程。最后, 利用改进的交互关系提取模型, 将推理过后的数据与原始节点进行信息对比与聚合, 保留更有效的交互信息进行结果预测。在WikiHop数据集中进行实验验证, 结果表明改进交互关系提取方法取得了更好的效果。

## 关键词

多跳阅读理解, 门控机制, 注意力机制

# Research on Multi-Hop Reading Comprehension Based on Improved Interaction Extraction with Gate Mechanism

Zoujie He<sup>1</sup>, Nisuo Du<sup>1,2</sup>, Zhi Ouyang<sup>1,2</sup>

<sup>1</sup>School of Mathematics and Statistics, Guizhou University, Guiyang Guizhou

<sup>2</sup>Guizhou Big Data Academy, Guizhou University, Guiyang Guizhou

Received: Mar. 17<sup>th</sup>, 2022; accepted: Apr. 29<sup>th</sup>, 2022; published: May 5<sup>th</sup>, 2022

文章引用: 何奏捷, 杜逆索, 欧阳智. 基于门控思想的改进交互关系提取的多跳阅读理解研究[J]. 运筹与模糊学, 2022, 12(2): 169-176. DOI: 10.12677/orf.2022.122016

## Abstract

Multi-hop reading comprehension needs leaping reasoning over multiple supporting documents to obtain the correct answer. Graph neural network is widely used to solve the problem of multi hop reading comprehension. Aiming at the insufficient extraction of interactive information between problems and nodes in the current graph neural network related models, the multi hop reading comprehension model based on improved interactive relationship extraction based on gating mechanism is proposed. Firstly, take the entities in the supporting document that are equal to the entities in the candidate set or question as the entity graph nodes, connect different entities in the same paragraph and the same entity in different paragraphs as edges to construct the entity graph. Then, embedding the graph nodes, and using graph convolution network to reason. Finally, the improved interactive relationship extraction model is used to compare and aggregate the information with the original graph nodes, and retain more effective interactive information for result prediction. The WikiHop experimental results show that the improved interactive relationship extraction method has achieved better results.

## Keywords

Multi-Hop Reading Comprehension, Gate Mechanism, Attention Mechanism

Copyright © 2022 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

机器阅读理解(Machine Reading Comprehension, MRC)是一项旨在让机器根据给定的上下文文档回答问题,以此来测试机器理解自然语言程度的任务。

随着 BERT [1]等模型的兴起,单跳的简单阅读理解任务取得了重大突破,其效果已经超过人工水平。但是在实际的应用中,还存在大量问题的答案不能由单跳推理来获得,而必须对多个段落整合后进行多跳推理才能回答,因此研究人员开始关注多跳阅读理解的研究。

多跳机器阅读理解(Multi-hop MRC)就是由问题推导出答案需要进行多次推理的阅读理解。为解决多跳机器阅读理解问题,需要搜集支持文档中的多处证据,然后利用搜集到的证据,进行多级跳跃的推理过程确认答案。解决多跳阅读理解问题过程中,人们为了得到更多有效的推理信息需要捕捉到文档中的关键实体词,从而推理出实体间递进的逻辑推理信息。这对于机器来说,存在着极大的难度以及挑战性。

多跳阅读理解的传统模型主要是将单跳阅读理解的模型应用到多跳阅读理解的多个段落中,对每个段落进行分析并抽取可能答案,最后通过比较分析得到可能性最大的答案。例如,Seo 等人[2]提出双向注意力流(BiDAF)并运用在多跳阅读理解任务上。该注意力流在每次迭代时都会不断根据上一层的信息表示来提取特征信息,保证了模型中在不丢失过多信息基础上更加关注与答案相关的信息。万静等人[3]在双向注意力流(BiDAF)模型的基础上,结合双向长短期记忆网络和自注意力机制构建了多段落排序(PR-BiDAF)模型,利用该模型定位答案所在的段落,然后在预测段落中寻找最终答案的始末位置,取得了不错的效果。Wang 等人[4]提出基于循环神经网络的双向长短期记忆(BiLSTM)模型,并采用问题与文档、候选答案与文档两个注意力向量来提取重要特征,使文档与问题的信息更加紧密地联系起来。Dhingra

等人[5]在使用外部系统提取共同指代信息基础上, 同样采用循环神经网络提取上下文表示和指代信息表示的组合表示信息。Feldman 等人[6]运用信息检索方法来查找与给定问题最相似的段落, 以此实现多跳推理的功能。然而这些模型都是基于单个段落的角度来提取答案, 不能很好的处理多跳信息间的连接。Jiang 等人[7]提出三模块系统, 包含以迭代方式选择相关文档的文档浏览器, 在单词级别上执行问题至上下文推理并预测答案的答案提议器, 以及从每个路径中提取包含建议答案的关键句子, 并将其组合以预测最终答案的证据集成器。但是以上各种方法都是将支持文档中的段落看作没有联系的个体, 忽视了段落之间可能存在的逻辑关联信息。

针对传统深度学习模型不能有效的提取文档中所存在的逻辑推理关系的问题, 还需要一种可以很好的提取推理实体间联系的模型。有学者[8]指出图神经网络[9]可以提取表示对象之间复杂关系, 在捕捉段落间递进的逻辑信息具有显著优势。Ding 等人[10]参照人类的认知方式, 提出了一种新的多跳阅读理解 CogQA 框架。该框架包含用于扩充信息量的直觉系统和使用图神经网络来执行逻辑推理的决策系统, 在实验迭代中不断扩充信息量并执行推理过程。Ye 等人[11]提出了基于增强信息的图神经网络 KGNN, 增强信息就是不断融入外部知识来执行推理过程。De Cao 等人[12]将问题和候选答案中的实体与提取的指代词作为节点, 并将支持文档中完全匹配上述实体的实体也提取出来, 之后将同一文档中的所有实体、不同文档的同一实体和同一文档中的指代词与实体连接为不同的三种边, 构建出实体图(Entity-GCN), 以此进行推理。Cao 等人[13]为了将问题和实体图更紧密联系起来, 在图神经网络模型后接了双向注意力层, 为最终预测提供更关键的推理信息。Song 等人[14]把外部知识图谱的知识加入到问答中, 并在实体图中提出三种类型的边(相同实体, 固定窗口中不同实体, 共同指代的实体), 以此进行推理。Zhong 等人[15]提出的异质文档实体图(HDE-Graph)包含不同粒度的节点及节点间不同的链接类型, 以此在上下文文档中进行推理。Tang 等人[16]基于关系图卷积网络, 在实体图中加入更多与问题相关的节点, 丰富节点数量的同时, 给推理提供更多问题相关信息。这些方法应用不同的图神经网络执行多跳推理, 大大增强了逻辑推理的能力, 但是大都采用了双向注意力的方法来提取问题与图节点的交互信息, 问题与节点的交互信息提取还不够充分。

综上所述, 针对问题与节点的交互信息提取不充分的问题, 提出基于门控思想的改进交互关系提取的多跳阅读理解模型。在提取实体图中节点与问题句子交互信息的传统方法中, 吸收门控思想中自适应的调整权重信息的思想, 通过与其他模型对比实验验证模型的有效性。

## 2. 模型概述

模型如图 1 所示包括 5 个模块, 分别为: 1) 图构建模块, 2) 多级特征提取模块, 3) GCN 多跳推理模块, 4) 交互信息提取模块, 5) 输出预测模块。

### 2.1. 图构建模块

基于 Entity-GCN 提出的实体图构建方法, 通过字符串匹配的方法提在支持文档中提取与候选答案完全一致的字段作为候选答案节点。根据 Welbl 等人分析, 数据集是沿着可能的推理链生成候选答案, 在支持文档中包含了问题相关的实体。通过提取支持文档中与问题实体一致的字段得到一组问题相关节点。图中边的定义是将同一段落中的不同实体相连成边和将不同段落中的同一实体相连成边。

### 2.2. 多级特征提取模块

通过使用 ELMo 对所有的节点的信息进行编码, 得到具有支持文档上下文语义的实体节点编码信息, 从而使图中各个节点不仅包含实体本身具有的编码信息, 还包含支持文档中各句子间的逻辑关联信息。此外, 通过使用 GloVe 捕捉单词之间一些语义特性, 以此来丰富节点的语义表示信息。

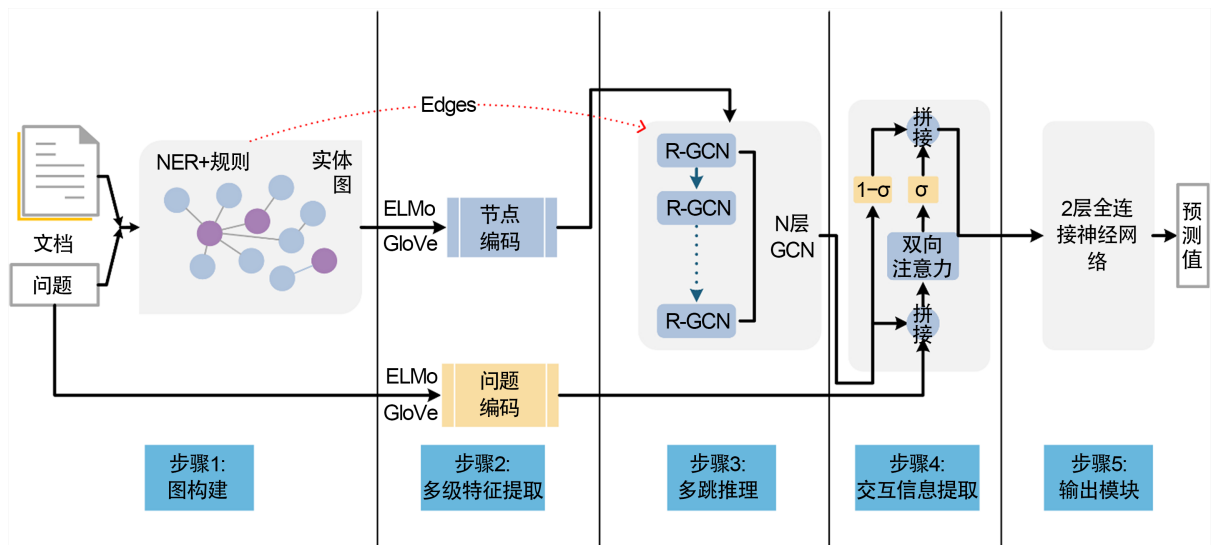


Figure 1. Model framework  
图 1. 模型框架图

由于每个图节点中实体包含的单词数量长度不一，为保持特征信息向量长度的一致性，对每个节点中的特征向量都进行平均化操作，最后将不同编码平均的节点特征向量进行拼接，得到每个节点最终的表示向量：

$$d_{node} = \text{concat} \left( \text{mean}(n_{elmo}), \text{mean}(n_{glove}) \right) \quad (1)$$

不同于平均池化操作获取节点特征信息的方式，本模型通过双向 LSTM 模块提取整个问题句的特征信息，该模块可以更好的提取问题句双向的语义依赖信息。最终的问题句信息表示向量为：

$$d_{query} = \text{BiLSTM} \left( \text{concat} \left( q_{elmo}, q_{glove} \right) \right) \quad (2)$$

### 2.3. GCN 多跳推理模块

根据多级特征嵌入模块编码后的特征向量，得到图节点的原始向量。由于每个节点都会与多个节点相连，因此要求节点有选择性地获取相邻节点的信息，在进行信息传递时可以在实体图中传递最为相关的信息，所以模型采用门控机制的关系图卷积神经网络(Gate-RGCN)来进行多跳推理。

在关系神经网络中，按照公式(3)进行节点之间的信息聚合，其中  $u_i^{(l+1)}$  表示第  $i$  个节点在第  $l+1$  层的更新信息， $\sigma(\cdot)$  表示 sigmoid 激活函数， $N_i^r$  表示第  $i$  个节点在第  $r$  种边关系下所有邻居节点的集合， $R$  表示第  $i$  个节点与其邻居节点的邻接关系矩阵， $c_{i,r}$  为正则化常量， $w_r^{(l)}$  代表在  $l$  层的邻接关系权重矩阵， $w_0^{(l)}$  是固定的初始化关系矩阵， $h_j^{(l)}$  表示第  $j$  个节点在第  $l$  层的隐藏状态。

$$u_i^{(l+1)} = \sigma \left( \sum_{r \in R} \sum_{j \in N_i^r} \frac{1}{c_{i,r}} W_r^{(l)} h_j^{(l)} + W_0^{(l)} h_i^{(l)} \right) \quad (3)$$

门控机制会有选择性在聚合邻居节点的信息，本模型由公式(4)通过门控机制更新关系矩阵，其中  $f_{gate}(\cdot)$  表示关系向量进行线性转换得到各关系向量的权重，经由 sigmoid 函数标准化后用于更新下一层节点  $i$  的隐藏状态。最终使用了 Gate-RGCN 节点传递信息如公式(5)得到最终的节点隐藏层状态，其中  $\odot$  表示哈达马积。

$$w_i^{(l)} = \sigma \left( f_{gate} \left( \text{concat} \left( u_i^{(l)}, h_i^{(l)} \right) \right) \right) \quad (4)$$

$$h_i^{(l+1)} = w_i^{(l)} \odot \tanh \left( u_i^{(l)} \right) + \left( 1 - w_i^{(l)} \right) \odot h_i^{(l)} \quad (5)$$

传统 GCN 只能根据相邻节点的聚合信息来更新中心节点,但在信息传播的过程中存在着大量的无关信息,使用带有门控机制的 GCN 会有选择性地传播更新信息,适当的保留了中心节点的原始状态信息。

## 2.4. 交互信息提取模块

传统模型在提取问题与节点的交互信息时往往采用双向注意力机制。例如, Cao 等人在 Entity-GCN 模型中引入了双向注意力流模块提出双向注意力图神经模型(BAG),由初始节点特征向量  $H_{raw}$ , 经过 Gate-RGCN 推理得到的最终的输出向量  $H_l$ , 计算出问题对于节点的注意力  $A_{q2n}$ , 以及节点对于问题的注意力  $A_{n2q}$ 。然后将注意力与原始节点进行拼接运算得到在最终的注意力流输出。

$$AF = \text{concat} \left( H_{raw}, A_{n2q}, H_{raw} \odot A_{n2q}, H_n \odot A_{q2n} \right) \quad (6)$$

双向注意力流模型并不能充分的提取节点与问题的交互信息。双向注意力流的输出  $AF$  中直接将注意力与原始节点信息进行哈达马积运算后拼接,输出中还存在着大量的无关信息。

根据 Seo 等人在机器阅读理解的任务中对双向注意力进行测试,发现的 N2Q 注意力更加重要的结论。在得到节点对于问题的注意力  $A_{n2q}$  和原始节点向量  $H_{raw}$  的表示技术上,计算二者的门控权重关系  $w_{AH}$ 。

$$w_{AH} = \sigma \left( f_{gate} \left( \text{concat} \left( H_{raw}, A_{n2q} \right) \right) \right) \quad (7)$$

不同于门控机制中将两者的信息相加得到最终输出的方式,本模型定义来一种全新的门控更新单元。

$$f_{inter} = \text{concat} \left( w_{AH} \odot H_{raw}, \left( 1 - w_{AH} \right) \odot A_{n2q}, w_{AH} * A_{n2q} \right) \quad (8)$$

最终经过与问题对于节点的注意力  $A_{q2n}$  聚合,输入至预测模块,进行最后的答案预测。

$$\hat{f} = \text{concat} \left( f_{inter}, A_{q2n} \odot H_{raw} \right) \quad (9)$$

## 2.5. 输出预测模块

通过将交互信息提取模块的最终输出经过两层全连接神经网络的转换之后,得到图中每个节点作为答案的概率值。由于答案选择是一个单项选择问题,本模型选择 softmax 交叉熵损失作为模型的损失函数,即:

$$p(x_i) = \frac{e^{x_i}}{\sum_{j=1}^k e^{x_j}} \quad (10)$$

$$Loss = -\sum_{i=1}^k y_i \log(p_i) \quad (11)$$

其中  $y_i$  表示样本  $i$  的标签,正类为 1,负类为 0。 $p_i$  表示样本  $i$  预测为正的的概率。

## 3. 实验结果与分析

### 3.1. 实验配置

根据以上模型概述,本实验采取在 QAngaroo 发布的 WikiHop 数据集上进行验证。WikiHop 数据集是需要多个支持文档中进行多跳推理的多跳阅读理解数据集。每个 WikiHop 的数据样本包含一个问题  $Q$ ,多个支持文档  $S_i (i=1,2,\dots,N)$  以及多个候选答案  $C_j (j=1,2,\dots,M)$ 。支持文档中来源于 WIKIREADING,

其中包含支持推理过程的正例文档和与问题无关的负例文档，候选答案可能是一个单词或者是一个词组。模型需要根据给定的支持文档进行推理，在所有的候选答案中选出最终的正确答案。WikiHop 数据集中，训练集数据共有 43,738 个样本，验证集共 5129 个。

实验环境：操作系统为 Ubuntu18.04，CUDA 版本为 CUDA10.0，深度学习框架 TensorFlow 版本为 tensorflow-gpu-13.1，GPU 为 2 块 GTX Titan Xp，内存为 125G。

为了验证模型在 WikiHop 数据集上的有效性，需要对模型的各个参数进行调整。实验过程中，尝试了多种不同的超参数组合。例如：多跳层数(4, 5, 6)，学习率(0.00005, 0.00002, 0.00001)，最大答案长度(200, 300, 400, 450)，hidden-size (300, 528, 768)等。根据实验结果，最后选择的最优参数组合见表 1。

**Table 1.** Setting of parameters

**表 1.** 超参数设置

参数	参考值
hops	5
learning-rate	2e-4
optimization	Adam
node-num	500
query-num	25
hidden-size	1024
epoch	30

### 3.2. 实验结果分析

为了显示本模型的有效性，本研究选取以下多种模型进行对比实验，将实验结果与本研究提出的模型做了比较。对比模型的简要说明如下。

基于注意力机制提取段落与问题交互信息的模型(BiDAF [2], CFC [17])、基于循环神经网络提取表示信息的模型(Coref-GRU [5], EPar [7])、基于图神经网络的实体图构建模型(Entity-GCN [12], BAG [13], MHQA-GRN [14])。

在训练集上训练且在验证集及测试集中评定，实验结果见表 2，评价指标为准确率。

**Table 2.** Model performance comparison

**表 2.** 模型性能比较

	模型名称	验证集(%)	测试集(%)
基于注意力机制	BiDAF	49.7	42.9
基于 RNN	Coref-GRU	56.0	52.3
	EPar	67.2	<u>69.1</u>
基于图神经网络	Entity-GCN	67.2	<u>69.1</u>
	BAG	66.5	69.0
	MHQA-GRN	62.5	65.4
	<b>本模型</b>	<b>67.3</b>	<b>69.1</b>

从表中显示的结果可以看到，与基于图神经网络的模型比较，在验证集中的准确率取得最优水平，说明本模型在不损失泛化能力的基础上，节点与问题的交互信息方面取得了较大的提升。与非图神经网络

络的模型相比，本模型也为最优模型，这表明了本模型在有效提取问题与答案实体的交互关系基础上，也可以很好的提取实体在段落中的表示信息。通过上述的对比表明使用基于门控思想的改进交互关系提取的模型，可以有效提取节点与问题的交互信息，以此提升了模型预测的准确率。

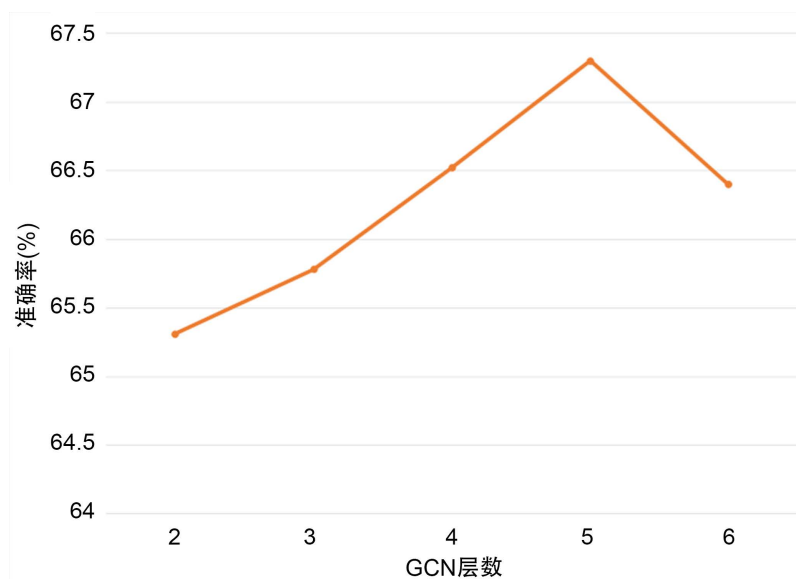
为了证明本模型各模块的有效性，在 WikiHop 验证集中进行了消融实验，结果见表 3。

**Table 3.** Model ablation experiments

**表 3.** 消融实验

Models	验证集(%)	$\Delta$ (%)
本模型	<b>67.3</b>	-
(a) 去除改进交互信息提取模块	66.04	-1.26
(b) 去除 ELMo	60.02	-7.28
(c) 调整 GCN 层数	4-hops	-0.78
	6-hops	-0.90

(a) 实验去除了本模型的改进交互信息提取模块，可以看到在验证集中准确率下降了 1.26%，这证明了本模型在提取问题与实体交互信息的有效性。(b) 实验去除 ELMo 提取的及节点表示信息，模型准确率下降 7.28%，证明了 ELMo 提取的节点语义表示信息是模型的关键。(c) 实验中将 GCN 的层级分别调整为如图 2 所示的 2~6 层，由图中数据可见，使用 Gate-RGCN 进行推理时准确率先随着层数的增加而提升，这证明了使用 Gate-RGCN 推理的有效性。而后因为更多的层数引入了噪声，导致后续准确率的下降，得到最佳的层数为 5 层。



**Figure 2.** Comparison of different GCN layers

**图 2.** GCN 层数对比

## 4. 结论

机器阅读理解是自然语言处理中一项具有挑战性的任务。针对现有图神经模型存在节点与问题交互信息提取不充分的问题，提出了一种新的多跳阅读理解模型。首先，采用基于匹配的实体提取方法从支

撑文档中提取与候选答案或问题中实体一致的字段作为节点构建实体图。然后通过对图节点进行 ELMo 及 GloVe 多级编码后使用 Gate-RGCN 进行多跳推理。最后根据全新的交互信息提取模型计算节点与问题的交互信息, 并进行最终答案预测。通过与已发布模型的实验结果进行比较, 表明模型在单模型上比绝大多数模型效果更好。

但是由于本模型中提取的问题相关节点与候选答案节点相互独立, 在构建的实体图中存在着较多的未连通的子图, 所以模型在图神经推理时还存在信息交互不够充分的问题, 需要进一步设计连通更多的图节点的实体图进行图神经推理。

## 参考文献

- [1] Devlin, J., Chang, M.W., Lee, K., et al. (2019) Bert: Pre-Training of Deep Bidirectional Transformers for Language Understanding. *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL-HLT)*, Volume 1, 4171-4186.
- [2] Seo, M., Kembhavi, A., Farhadi, A., et al. (2017) Bidirectional Attention Flow for Machine Comprehension. *Proceedings of the 5th International Conference on Learning Representations*, Toulon, 24-26 April 2017.
- [3] 万静, 郭雅志. 基于多段落排序的机器阅读理解研究 [J]. 北京化工大学学报(自然科学版), 2019, 46(3): 93-98.
- [4] Wang, S., Yu, M., Jiang, J., et al. (2018) A Co-Matching Model for Multichoice Reading Comprehension. In: *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (ACL)*, Association for Computational Linguistics, Melbourne, 746-751. <https://doi.org/10.18653/v1/P18-2118>
- [5] Dhingra, B., Jin, Q., Yang, Z.L., et al. (2018) Neural Models for Reasoning over Multiple Mentions Using Coreference. *Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies: NAACL-HLT*, Volume 2, 42-48. <https://doi.org/10.18653/v1/N18-2007>
- [6] Feldman, Y. and El-Yaniv, R. (2019) Multi-Hop Paragraph Retrieval for Open Domain Question Answering. In: *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics (ACL)*, Association for Computational Linguistics, Florence, 2296-2309. <https://doi.org/10.18653/v1/P19-1222>
- [7] Jiang, Y., Joshi, N., Chen, Y., et al. (2019) Explore, Propose, and Assemble: An Interpretable Model for Multi-Hop Reading Comprehension. In: *Proceedings of the 57th Conference of the Association for Computational Linguistics (ACL)*, Association for Computational Linguistics, Florence, 2714-2725. <https://doi.org/10.18653/v1/P19-1261>
- [8] Gori, M., Monfardini, G. and Scarselli, F. (2005) A New Model for Learning in Graph Domains. *Proceedings 2005 IEEE International Joint Conference on Neural Networks*, Volume 2, 729-734.
- [9] Santoro, A., Raposo, D., Barrett, D.G., et al. (2017) A Simple Neural Network Module for Relational Reasoning. *Annual Conference on Neural Information Processing Systems 2017*, Long Beach, 4-9 December 2017, 4967-4976.
- [10] Ding, M., Zhou, C., Chen, Q.B., et al. (2019) Cognitive Graph for Multi-Hop Reading Comprehension at Scale. In: *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics (ACL)*, Association for Computational Linguistics, Florence, 2694-2703. <https://doi.org/10.18653/v1/P19-1259>
- [11] Ye, D., Lin, Y., Liu, Z., et al. (2019) Multi-Paragraph Reasoning with Knowledge Enhanced Graph Neural Network.
- [12] Cao, D.N., Aziz, W. and Titov, I. (2019) Question Answering by Reasoning across Documents with Graph Convolutional Networks. *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (NAACL-HLT)*, Volume 1, 2306-2317.
- [13] Cao, Y., Fang, M. and Tao, D. (2019) Bag: Bi Directional Attention Entity Graph Convolutional Network for Multi-Hop Reasoning Question Answering. *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, Volume 1, 357-362.
- [14] Song, L., Wang, Z., Yu, M., et al. (2018) Exploring Graph-Structured Passage Representation for Multi-Hop Reading Comprehension with Graph Neural Networks.
- [15] Tu, M., Huang, K., Wang, G., et al. (2020) Select, Answer and Explain: Interpretable Multi-Hop Reading Comprehension over Multiple Documents. In: *The Thirty-Fourth AAAI Conference on Artificial Intelligence (AAAI)*, AAAI Press, New York, 9073-9080. <https://doi.org/10.1609/aaai.v34i05.6441>
- [16] Tang, Z., Shen, Y., Ma, X., et al. (2020) Multi-Hop Reading Comprehension across Documents with Path-Based Graph Convolutional Network. *Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence (IJCAI)*, Yokohama, 11-17 July 2020, 3905-3911. <https://doi.org/10.24963/ijcai.2020/540>
- [17] Zhong, V., Xiong, C., Keskar, N.S., et al. (2019) Coarse-Grain Fine-Grain Attention Network for Multi-Evidence Question Answering. *7th International Conference on Learning Representations (ICLR)*, New Orleans, 6-9 May 2019.