

文章编号: 1003-0077(2020)04-0085-07

基于外部知识和层级篇章表示的阅读理解方法

谭红叶^{1,2}, 李宣影¹, 刘蓓¹

(1. 山西大学 计算机与信息技术学院, 山西 太原 030006;

2. 山西大学 计算智能与中文信息处理教育部重点实验室, 山西 太原 030006)

摘要: 阅读理解指的是基于给定文章自动回答相关问题, 这是人工智能及自然语言处理领域的一个研究热点。目前已提出许多基于深度学习的阅读理解方法, 但是这些方法对问题理解及篇章建模不充分, 导致模型获取答案准确率不高。为了解决上述问题, 该文提出一个基于外部知识和层级篇章表示的阅读理解方法。该方法特点有: ①通过引入问题重要词的字典释义、HowNet义原, 并结合问题类型, 加强问题理解; ②使用层级篇章表示, 提升模型对篇章的理解; ③在一个框架下联合优化问题类型预测与答案预测两个子任务。在 DuReader 数据集上的实验结果表明, 该方法与基线系统性能相比最大提升了 8.2%。

关键词: 阅读理解; 外部知识; 篇章表示

中图分类号: TP391

文献标识码: A

Reading Comprehension Based on External Knowledge and Hierarchical Discourse Representation

TAN Hongye^{1,2}, LI Xuanying¹, LIU Bei¹

(1. School of Computer and Information Technology, Shanxi University, Taiyuan, Shanxi 030006, China;

2. Key Laboratory of Ministry of Education Intelligence and Chinese Information Processing of Shanxi University, Taiyuan, Shanxi 030006, China)

Abstract: Reading Comprehension (RC) refers to automatically answering questions on the given text, which has become a popular issue in natural language processing. Many deep learning RC methods have been proposed. However, these methods do not fully understand questions and the discourse, leading to poor performance of the model. In order to solve the problem, this paper proposes a reading comprehension method based on external knowledge and hierarchical discourse representation. The method uses the external knowledge and question types to enhance question comprehension. And the method utilizes the hierarchical discourse representation to improve the understanding of the discourse. Moreover, the two subtasks of the question type prediction and the answer prediction are jointly optimized in a unified framework. Experiments performed on the DuReader dataset show that the proposed method increased the performance by 8.2% at most.

Keywords: reading comprehension; external knowledge; discourse representation

0 引言

阅读理解任务的目的是使计算机像人一样深层理解文本并回答一系列问题。近年来, 机器阅读理解在很多领域得到广泛应用, 如自动问答、搜索引

擎、对话系统、高考自动批阅等。

近几年, 学者主要通过端到端神经网络模型对阅读理解进行研究, 将问题和篇章共同作为输入进行编码, 通过注意力机制获取两者的交互信息, 最终从篇章中选取合适片段作为答案输出。然而, 阅读理解任务还面临一些挑战, 主要有: ①问题理解不

收稿日期: 2019-09-16 定稿日期: 2019-10-16

基金项目: 国家重点研发计划重点专项项目课题(2018YF131005103); 国家自然科学基金(61673248); 山西省自然科学基金(201701D121054)

充分。Mudrakarta 等^[1]在问题中添加与问题无关词、助词,模型效果反而有所提升,表明深度学习模型并没有真正理解问题含义。②模型对篇章建模不充分。研究者主要通过注意力机制对篇章信息隐式建模,而问题答案通常由篇章中的多个子句组成,具有篇章性,因此需要对篇章显式表示或建模。

为了解决上述问题,本文提出一种基于外部知识和层级篇章表示的阅读理解方法。首先,针对问题重要词引入字典释义与 HowNet 义原,并结合问题类型,加强问题理解;其次,使用由词到句子再到篇章的层级编码方式得到篇章表示,提升模型对篇章的理解,从而更准确地回答与篇章相关的问题。

1 相关工作

本文从阅读理解数据集及模型、问题理解、篇章表示三方面介绍阅读理解任务的相关工作。

1.1 阅读理解

目前,阅读理解任务主流数据集的构建情况如下:2013 年,微软采用众包方式建立了 MCTest 阅读理解数据集^[2];Hermann 等人于 2015 年针对 cloze 问题发布了 CNN/Daily Mail 数据集^[3];2016 年,斯坦福大学基于维基百科建立了 SQuAD 数据集^[4];同年,微软发布了英文 MS MARCO 数据集^[5];2018 年,百度发布了最大的中文数据集 DuReader^[6];2018 年,斯坦福又提出 SQuAD 2.0 数据集,在原来数据集的基础上增加了不可回答的问题。

围绕这些数据集,研究者主要采取深度学习方法,其思想是将问题和篇章同时输入模型进行嵌入式表示,将相应表示传入注意力机制获取两者的交互信息,再根据交互层的输出预测答案。例如,2016 年,Kadlec 等^[7]提出了一个使用注意力机制直接从上下文中选择答案的阅读理解模型;2017 年,刘飞龙等^[8]提出一种双线性函数注意力双向长短期记忆网络模型,较好地完成了抽取候选答案的任务;2018 年,梁小波等^[9]提出了一个采用双层 self-attention 机制的阅读理解模型 N-Reader,不仅可以获取单篇文档中的关键信息,还可以利用多篇文档中的相似性信息。

综上可知,现有模型主要通过注意力机制来捕捉问题和篇章的关系,对问题和篇章理解得不充分。

1.2 问题理解

早在 21 世纪初,学者就在自动问答背景下开始

对问题理解进行研究。近几年,研究者主要从问题的语义分析、问题分类、问题焦点和主题识别这几个方面对问题进行理解。例如,南加州大学信息科学研究所开发的 Webclopedia 系统通过构造问题的语义解析树实现问题理解;Zhang 等^[10]基于 SVM 算法利用 tree kernel 提取特征对问题进行分类;文勘等^[11]使用贝叶斯分类器及句法结构进行问题分类;陈永平等^[12]先对问句进行语义分析,再基于人工制定的匹配规则确定问题句中的焦点和主题,加强对问题理解。

综上所述,研究者们从问题本身的不同角度对问题进行理解,但并没有加入外部知识帮助理解问题。

1.3 篇章表示

近几年,学者们越来越注重对篇章结构建模的研究,在机器翻译、情感分类、阅读理解等任务中都对篇章结构进行表示。例如,Guzmán 等^[13]利用核函数捕捉篇章结构信息,改进了机器翻译质量的评估方法;Tang 等^[14]基于组合性原理对篇章进行建模,先由词对句子表示,再通过句子表示获取篇章表示,使文档级情感分类任务取得较好效果;Narasimhan 等^[15]使用词法和句法信息,基于判别模型的思想对篇章关系进行建模,在 MCTest 数据集上取得了较好的结果。

受文献^[14]启发,本文采用层级表示方法对篇章进行建模,提升模型对篇章的理解,在句子级、篇章级拼接的具体实现方法上与该文献有所不同;文献^[16]在图像识别任务中添加字典释义加强对图片中动作强度的识别,受该文献启发我们在阅读理解任务中引入字典释义并加入 HowNet 义原加强对问题的理解。

2 方法

阅读理解任务可形式化为:给定一个问题 Q 和一篇文档 D ,目标是从文档 D 中选取与问题 Q 相关的答案片段 A 作为输出。

本文提出一个加强问题理解和篇章表示的模型。首先,该模型在问题表示中结合了问题类型和外部知识——字典释义和 HowNet,并对篇章采用层级编码表示,然后将两者的表示一起输入到双向注意力机制层获取问题和篇章的交互信息,最后对答案预测和问题类型预测两个子任务共同优化并预测问题答案。具体模型如图 1 所示。

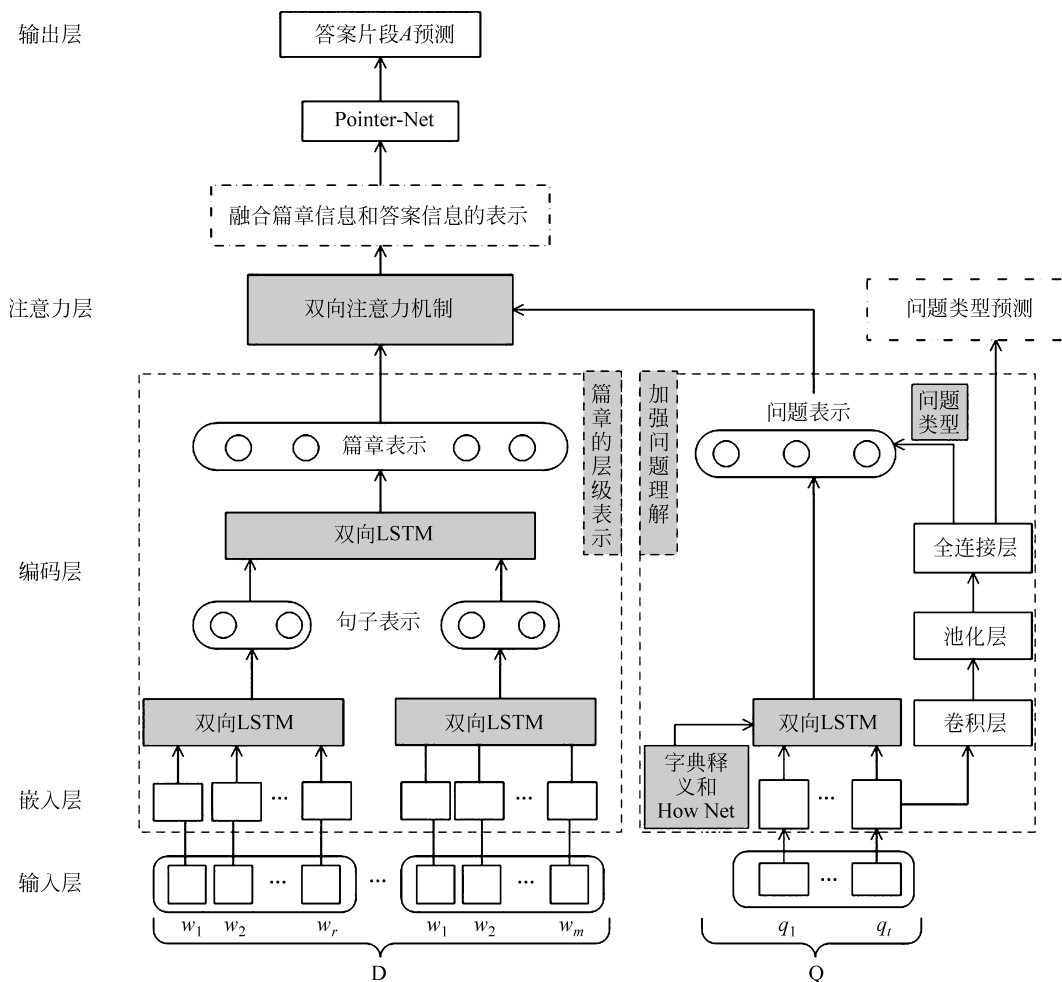


图1 基于外部知识和层级篇章表示的模型示意图

2.1 问题理解

2.1.1 基于外部知识加强问题理解

问题重要词定义 问题理解的关键是获取问题主要语义信息。我们认为问题重要词是包含问题主要语义信息的词语。通过大量数据观察,发现主题词和焦点词能够反映问题的主要内容,因此将主题词与焦点词定义为问题重要词。其中,主题词是指问题中的话题,问题焦点是围绕话题的问点。例如,“曲筱绡的结局是什么?”中,“曲筱绡”和“结局”分别为问题的主题词和焦点词。

问题重要词的识别 本文通过句法分析获取问题的主题词和焦点词。

与文献[17]做法类似,本文首先构建“为什么、怎么、谁、哪里”等疑问词词表(QW)及包含虚词、副词、助词等的停用词词表(SW);然后基于以下规则识别问题的主题和焦点词。

规则1 如果 \$(w_i, w_j)\$ 存在依存关系且 \$w_i \in

QW,若 \$w_j \notin\$ SW,则 \$w_j\$ 为问题焦点,否则与 \$w_j\$ 存在依存关系的词为问题焦点;

规则2 如果 \$w_k\$ 修饰(ATT)\$w_j\$,则 \$w_k\$ 为问题主题;

规则3 如果 \$(w_i, w_j)\$ 存在 COO 关系,则 \$w_i\$、\$w_j\$ 为问题主题,与 \$w_i\$ 或 \$w_j\$ 存在 ATT 关系的为问题焦点;

规则4 如果 \$w_i \in\$ QW 以 SBV 依存于 \$w_j \in\$ SW,则和 \$w_j\$ 存在依存关系的词为问题焦点。

外部知识的引入 本文使用的第一个外部知识为《现代汉语词典》(第六版)词语释义。为了降低停用词的干扰,只对问题重要词引入字典释义。使用字典释义时遵循以下约束:①当包含多个释义时,只添加常用的第一个释义;②对于植物或动物类名词,只使用其概括性解释,不添加属性描述。如“雪莲”的字典释义为:“雪莲:草本植物,叶子长椭圆形,花深红色……”,模型只使用“草本植物”作为“雪莲”的解释。字典释义引入的具体步骤为:先提取

字典释义并分词,然后获取每个词的词向量,最后和问题词的嵌入式表示进行向量拼接,得到融入字典释义的问题表示。

我们使用的第二个外部知识为 HowNet。HowNet 使用更小的语义单位——义原来描述词语语义信息。因此我们在模型中引入了 HowNet 义原进一步加强问题理解,使用方法与字典释义类似^①。

2.1.2 问题类型定义及预测

问题类型的定义 有学者将问题分为方式、比较、原因、解释、评价、简述、其他七类。通过数据分析发现该分类体系较粗糙,导致一些类别问题过多,占比不平衡。例如,方式类、简述类问题分别占 49.45% 与 26.12%。为了缓解该问题,本文将方式类问题更细粒度分为方法、步骤、攻略三类,简述类问题分为简述类和影响类。将问题细化后,方法类、简述类问题占比分别下降了 20%、10%,剩余类型均在 7% 左右,缓解数据不平衡现象。

最终,本文将问题分为方法、步骤、攻略、原因、解释、对比、评价、影响、简述、其他。分类示例如表 1 所示。

表 1 本文问题分类及示例

问题类型	示例
方法类	交管 12123 怎么交罚款?
步骤类	flash 动画制作步骤是什么?
	毕业论文答辩流程有什么?
攻略类	上海有什么旅游攻略?
	立体几何有什么解题技巧?
对比类	截至和截止有什么区别?
影响类	泻药有什么副作用?
原因类	威海为什么发展不起来?
解释类	纠缠的意思是什么?
	超声波洗牙的原理是?
简述类	男生喜欢一个人有什么表现?
	曲筱绡的结局是什么?
评价类	太平车险怎么样?
其他类	北欧家具的特点有?

问题类型预测 本文使用卷积神经网络 CNN 对问题进行分类,将问句以字符级形式输入到模型,并转化为二维矩阵表示传送到卷积层,依次通过最

大池化层、全连接层、softmax 层计算每个类型概率,最后选择概率最大的类型作为问题类型。

2.2 篇章表示

通常阅读理解问句简短而篇章较长,答案常常是篇章中的一句话或几句话,具有篇章性,所以要对篇章结构化表示。受文献[14]启发,本文在阅读理解中对篇章采用层级表示方法,但在句子级、篇章级表示的具体实现方面与该文献有所不同。

我们使用双向长短期记忆网络(LSTM)对篇章进行表示,并采用了两种句子表示的计算方法,模型结构如图 2 所示。




图 2 基于 LSTM 的篇章表示

具体方法如下：

(1) 使用双向 LSTM 对句子进行编码,前向 LSTM 使得每个词具有上文的的信息,后向 LSTM 使得每个词具有下文的的信息,双向 LSTM 则使得篇章中的每个词具有上下文信息。

(2) 句子采用以下计算方式获取,其中 s 表示句子,如式(1)、式(2)所示。

$$s = \max(\text{concat}(\vec{h}, \overleftarrow{h})) \in R^{2d} \quad (1)$$

$$s = \text{average}(\text{concat}(\vec{h}, \overleftarrow{h})) \in R^{2d} \quad (2)$$

其中,式(1)先将两个方向上每个时刻的输出进行拼接,得到矩阵 U ,保留 U 中每列的最大值作为句子的表示,这样可以保留句子最重要的信息。式(2)拼接方式同上,将 U 中每列的平均值作为句子的表示,这样可以保留句子的全局信息。

(3) 将计算得到的表示句子信息的向量输入到

^① 《现代汉语词典》对问题中重要词的覆盖率为 88.1%, HowNet 对问题中重要词的覆盖率为 92.7%。本文主要探索加入外部知识对阅读理解任务的影响,对外部知识没有覆盖的词暂不作处理,之后的研究会未覆盖词做相应处理。

双向 LSTM, 得到篇章表示 $D^h = \{s_i^h\}_{i=1}^l \in R^{l \times 2d}$, 这样可以隐式对句间关系建模, 使每句话保留上下文的语义信息, s_i^h 的计算如式(3)所示。

$$s_i^h = \text{concat}(\overrightarrow{\text{LSTM}}(s_{i-1}^h, s_i), \overleftarrow{\text{LSTM}}(s_{i+1}^h, s_i)) \quad (3)$$

2.3 双向注意力机制及答案预测

这一层的主要作用是获取问题和篇章的交互信息。本文使用和 Bi-DAF 一样的双向注意力机制, 即计算了 query-to-context (Q2C) 和 context-to-query (C2Q) 两个方向的 attention 信息, C2Q 和 Q2C 能相互补充问题和篇章的交互信息。

问题答案预测的目标是根据问题 Q , 在篇章 D 中寻找最合适的子序列 $d \in D$ 作为问题的答案, 所以我们需要预测篇章中子片段的开始和结束位置, 在整个篇章上开始位置的概率分布如式(4)所示。

$$P^1 = \text{softmax}(W_{P_1}^T [G; M]) \quad (4)$$

其中, W_p 为可训练的权重向量, G 为基于该注意力计算 query-aware 的原文表示, M 为包含整个上下文信息和问题信息的矩阵, M 再通过一次双向 LSTM 得到 $M^2 \in R^{2d \times T}$, 然后基于 M^2 来计算得到结束位置的概率分布如式(5)所示。

$$P^2 = \text{softmax}(W_{P_2}^T [G; M^2]) \quad (5)$$

2.4 优化

模型训练目标由两部分组成: 第一部分是将预测答案的似然损失最小化; 另一部分是将预测问题类型 y' 与标准问题类型 y 之间的交叉熵最小化。

答案预测的训练损失值定义为开始位置和结束位置对应的负对数似然损失之和, 并在所有样本上取均值, 计算如式(6)所示。

$$L_{\text{answer}} = -\frac{1}{N} \sum_{i=1}^N [\log(P_{y_i}^1) + \log(P_{y_j}^2)] \quad (6)$$

其中, N 表示每批次训练的数据量, y_i, y_j 分别表示第 k 个样本的真实的起始位置和结束位置。

我们使用交叉熵函数作为问题类型预测的损失函数, 计算如式(7)所示。

$$L_{\text{type}} = -\sum_{i=1}^n y' \times \log(y) \quad (7)$$

其中, y' 表示预测问题类型, y 表示标准问题类型, n 为问题类型个数。

为了共同优化这两个目标, 本文的最终损失函数 L 如式(8)所示。

$$L = L_{\text{answer}} + L_{\text{type}} \quad (8)$$

3 实验

3.1 实验建立

3.1.1 数据集

本文采用 2018 年百度发布的大规模中文机器阅读理解数据集 DuReader 进行实验。根据答案类型, 将问题分为: Entity(实体)、Description(描述)和 YesNo(是非)。DuReader 数据集包含训练集、验证集、测试集三部分, 共 20 万个问题、100 万篇原文和 42 万个答案。所有问题及原文都来自百度搜索引擎和百度知道问答社区, 问题对应答案由人提供。

3.1.2 实验细节

由于 DuReader 数据集没有标注问题类型, 所以我们随机抽取了 4 000 条问题进行手工标注(训练集 3 200 条、验证集 500 条、测试集 300 条)并训练得到一个类型初标注器。使用该标注器对 DuReader 数据集中训练集和验证集的问题进行大致的类型标注, 来获得问题类型已知的数据集^①。

实验中采用的预训练词向量是通过 Word2Vec 对中文维基百科数据进行训练得到的。

问题类型预测模型参数: 字向量维度 64, 卷积核函数 ReLU, 卷积核尺寸 6, 过滤器数量 256, 优化算法 Adam, 批大小 32, 迭代次数 40, 学习率 0.001。

整体阅读理解模型参数: 采用 Bi-DAF 的默认参数, 具体为: 词向量维度 300、批大小 32、隐藏层数 150、篇章长度 500、问题长度 80、答案长度 60、优化算法 Adam、迭代次数 6、学习率 0.001。

3.2 实验结果及分析

3.2.1 阅读理解模型实验结果

本实验以不加任何特征的 BI-DAF 模型作为 Baseline, BI-DAF 模型是解决机器阅读理解的经典模型, 曾在 SQuAD 和 CNN/Dailymail 数据集上达到了最先进的结果, 具有一定的代表意义。由于 DuReader 数据集没有公布测试集答案, 本实验只对验证集进行评价, 实验结果如表 2 所示。

^① 初标注模型的正确率为 86.2%, 但本文目标是探索问题类型对问题回答是否有帮助, 未来将研究进一步提升初标注模型的方法。

表 2 DuReader 数据集实验结果(%)

模型	Rouge-L	Bleu-4
Baseline	37.1	32.7
①Baseline+字典释义	38.7	33.4
②Baseline+HowNet	40.5	34.8
③Baseline+问题类型	42.0	34.8
④Baseline+层级篇章表示	43.4	36.3
⑤Baseline+层级篇章表示+外部知识+问题类型	44.8	37.0
⑥Baseline+层级篇章表示+外部知识+问题类型+共同优化	45.3	39.7

从表 2 可以看出,在模型中加入问题类型并针对问题重要词加入外部知识,对篇章采用层级表示有效提高了阅读理解模型的性能,Rouge-L 值比 Baseline 提升了 8.2%,Bleu-4 值提升了 7.0%。通过对比实验结果可得:

- 在加强问题理解方面,HowNet 比字典释义更有效,说明将 HowNet 义原知识融入到词表示学习过程中,能够有效提升词表示效果,保留词的语义信息;
- 添加相应问题类型可以增强对答案标识,对答案的选取有一定指导作用;
- 对篇章进行层级表示,可以加强对篇章的理解,明显提高阅读理解模型性能,并且篇章层级表示比加入外部知识对阅读理解模型影响更大;
- 同时加强问题和篇章理解,更有助于模型对阅读理解问题的解答;
- 将答案预测和问题类型预测子任务共同优化,进一步加强了模型性能。

3.2.2 篇章建模时不同句子编码方式

为了比较基于不同句子编码方式得到的篇章表示对阅读理解模型性能的影响,本文设置了两组对比实验,分别为:①LSTM(Max):选取通过双向 LSTM 得到的句子拼接矩阵所有词对应维度上的最大值作为句子的表示。②LSTM(Average):选取矩阵所有词对应维度上的均值作为句子的表示。实验对比结果如表 3 所示。

表 3 对句子采用不同编码方式的实验结果(%)

模型	Rouge-L	Bleu-4
Baseline	37.1	32.7
LSTM(Max)	41.4	33.6
LSTM(Average)	43.4	36.3

从实验结果可以看出,“LSTM(Average)”编码方式的实验结果较好,取均值作为句子的表示可以更好地保留句子语义信息。从整个实验结果来看,采取有效的句子编码方式对篇章进行层级表示,可提高模型解答描述类问题的性能。

3.2.3 问题类型识别

对问题分类实验结果如表 4、表 5 所示。

表 4 问题类型总体识别结果(%)

Precision	Recall	F_1
88.4	85.9	87.1

表 5 问题类型识别结果

问题类型	Precision	Recall	F_1
方法	91.6	88.3	89.9
对比	98.4	85.9	91.7
步骤	74.3	68.2	71.1
原因	87.1	78.8	82.7
评价	92.8	97.1	94.9
影响	91.3	88.7	90.5
简述	79.2	80.3	79.9
解释	90.0	92.4	91.2
攻略	96.1	96.1	96.1
其他	83.3	82.9	83.1

从表 5 可以看出,对比类、攻略类问题准确率达到 95%以上,而步骤类、简述类问题准确率较低。分析数据发现对比类、攻略类问题较有标志性,其一般都包含“区别”“攻略”“技巧”等词,问句比较规范,而步骤类、简述类问题涉及方面较多,问题中没有比较固定的词,且较多情况下不出现疑问词,如“激光祛斑后的保养?”,增加了识别问题类型的难度。

4 总结

本文提出了一种将字典释义、HowNet 义原融入问题理解中对篇章使用层级表示,并将问题类型预测和问题答案预测任务共同优化的阅读理解方法。实验表明,我们所提方法可以提高机器阅读理解的性能。但是,本文理解问题角度较单一,对问题的理解仍不全面,而且只是对篇章进行表示,并没有将问题类型与篇章指示词的关系建模。所以在今后的研究中,我们会把外部知识和问题本身的理解相结合,即将外部知识与问题主题、问题焦点、问题重要词权重相结合,多角度理解问题,在建模时引入问题类型与篇章指示词的关系,并对抽取的答案进行一些后处理,进一步提升机器阅读理解的性能。

参考文献

- [1] Mudrakarta P K, Taly A, Sundararajan M, et al. Did the model understand the question? [C]//Proceedings of the ACL, 2018.
- [2] Matthew Richardson, J C Christopher Burges, Erin Renshaw. MCTest: A challenge dataset for the open-domain machine comprehension of text[C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing(EMNLP), 2013: 193-203.
- [3] Hermann K M, Kočiský, Tomáš, Grefenstette E, et al. Teaching machines to read and comprehend[J]. arXiv: 1506.03340v3, 2015.
- [4] Pranav Rajpurkar, Jian Zhang, Konstantin Lopyrev, et al. SQuAD: 100,000+ questions for machine comprehension of text[C]//Proceedings of the Conference on Empirical Methods in Natural Language Processing, 2016: 2383-2392.
- [5] Payal Bajaj, Daniel Campos, Nick Craswell, et al. MS MARCO: A human generated machine reading comprehension dataset[J]. arXiv: 1611.09268, 2016
- [6] Wei He, Kai Liu, Jing Liu, et al. DuReader: A Chinese machine reading comprehension dataset from real-world applications[J]. arXiv: 1711.05073v4, 2017.
- [7] Kadlec R, Schmid M, Bajgar O, et al. Text understanding with the attention sum reader network[C]//Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics, 2016: 908-918.
- [8] 刘飞龙, 郝文宇, 陈刚, 等. 基于双线性函数注意力 Bi-LSTM 模型的机器阅读理解[J]. 计算机科学, 2017 (S1): 102-106, 132.
- [9] 梁小波, 任飞亮, 刘永康, 等. N-Reader: 基于双层 Self-attention 的机器阅读理解模型[J]. 中文信息学报, 2018, 32(10): 134-141.
- [10] Dell Zhang, Lee Wee. Question classification using support vector machines[C]//Proceedings of the 26th ACM SIGIR, 2003, 29(6): 26-32.
- [11] 文勘, 张宇, 刘挺, 等. 基于句法结构分析的中文问题分类[J]. 中文信息学报, 2006, 20(2): 35-41.
- [12] 陈永平, 杨思春, 毛万胜, 等. 中文问答系统中基于主题和焦点的问题理解[J]. 计算机系统应用, 2011, 20(6): 58-62.
- [13] Francisco Guzmán, Shafiq Joty, Lluís Màrquez, et al. Using discourse structure improves machine translation evaluation[C]//Proceedings of the Association for Computational Linguistics, 2014: 687-698.
- [14] Du-yu Tang, Bing Qin, Ting Liu. Document modeling with gated recurrent neural network for sentiment classification [C]//Proceedings of the EMNLP, 2015: 1422-1432.
- [15] Karthik Narasimhan, Regian Barzilay. Machine comprehension with discourse relations[C]//Proceedings of the 53rd Annual Meeting of the Association for Computational Linguistics and the 7th International Joint Conference on Natural Language Processing, 2015: 1253-1262.
- [16] Zellers R, Choi Y. Zero-shot activity recognition with verb attribute induction [C]//Proceedings of the EMNLP, 2017: 946-958.
- [17] 谭红叶, 刘蓓, 王元龙. 基于 QU-NNs 的阅读理解描述类问题的解答[J]. 中文信息学报, 2019, 33(3): 127-134.



谭红叶(1971—),通信作者,博士,副教授,主要研究领域为中文信息处理、信息检索。
E-mail: hytan_2006@126.com



刘蓓(1994—),硕士研究生,主要研究领域为中文信息处理。
E-mail: Liu_b0109@163.com



李宣影(1994—),硕士研究生,主要研究领域为中文信息处理。
E-mail: l_xuan811@163.com