

基于知识表示的联合问答模型

刘小龙 韩芳 王直杰

东华大学信息科学与技术学院 上海 201620

(13122331373@163.com)

摘要 基于知识库的问答系统旨在通过解析用户的自然语言问句直接在知识库中提取出答案。目前,大多数知识库问答模型都遵循实体检测和关系识别这两个步骤,但是此类方法忽略了知识库本身所蕴含的结构信息以及这两个步骤之间的联系。文中提出了一种基于知识表示的联合问答模型。首先应用知识表示模型将知识库中的实体与关系映射到低维的向量空间,然后通过神经网络将问句也嵌入相同的向量空间,同时检测出问句中的实体,并在此向量空间内度量知识库三元组与问句的语义相似度,从而实现将知识库嵌入和多任务学习引入知识库问答。实验结果表明,所提模型可以极大地提高训练速度,在实体检测和关系识别任务上的准确率达到了主流水平,证明了知识库嵌入及多任务学习可以提升知识库问答任务的性能。

关键词: 知识库问答;知识库嵌入;多任务学习

中图法分类号 TP311

Joint Question Answering Model Based on Knowledge Representation

LIU Xiao-long, HAN Fang and WANG Zhi-jie

School of Information Science and Technology, Donghua University, Shanghai 201620, China

Abstract Question answering system based on knowledge base aims to extract answers directly from the knowledge base by parsing users' natural language question sentences. Currently, most knowledge based question answering models follow the two steps of entity detection and relationship recognition, but such methods ignore the structural information contained in the knowledge base and the connection between the two tasks. In this paper, a joint question answering model based on knowledge representation is proposed. First, the knowledge representation model is used to map the entities and relationships in the knowledge base to a low-dimensional vector space, then the question sentences are embedded into the same vector space through neural network, and the entities in the question sentences are detected at the same time. The semantic similarity between knowledge base triples and question sentences is measured in the vector space, so that knowledge base embedding and multi-task learning are introduced into the task of knowledge based question answering. The experimental results show that the proposed model can greatly improve the training speed, and the accuracies of entity detection and relationship recognition task reach the mainstream level. It is proved that knowledge embedding and multi-task learning can improve the performance of knowledge based question answering task.

Keywords Knowledge base question answering, Knowledge base embedding, Multi-task learning

1 引言

近年来,随着科学技术的发展,出现了一些开放领域的大型知识库,如 YAGO^[1], Freebase^[2], NELL^[3] 和 DBpedia^[4], 这些知识库常用三元组的形式来存储事实 $\{(h, r, t)\}$, h 表示头实体, r 表示关系, t 表示尾实体。研究人员也在积极探索如何有效利用这些知识库来解决实际问题。多种精巧的结构化查询语言可用于提取知识库中的数据,如 SPARQL, 但是这种方式对于不懂查询语言语法和知识库词汇的普通用户来

说十分不友好,而知识库问答(Knowledge Based Question Answering, KBQA)可以让用户直接使用自然语言与知识库进行交互,这种方式受到了越来越多的关注。

目前基于知识库问答的主流方法分为 3 种:基于语义分析的方法、基于信息检索的方法和基于深度学习的方法^[5]。基于语义分析的方法主要学习句子的语法信息,从而将句子解析成另一种富含语义信息的形式,但是这种方法需要大量人工设计的逻辑表达式,当知识库规模非常大时不是很实用;基于信息检索的方法首先将句子转换成有效的查询语句,在

到稿日期:2020-06-01 返修日期:2020-07-29

基金项目:国家自然科学基金(11972115);中央高校基本科研业务费专项资金;东华大学“励志计划”(18D210402)

This work was supported by the National Natural Science Foundation of China(11972115), Special Funds for Basic Research Business Expenses of Central Colleges and Universities and “Inspirational Plan” of Donghua University(18D210402).

通信作者:韩芳(yadianhan@dhu.edu.cn)

知识库中检索出一系列候选答案,然后通过设计更加精细化的检测方法锁定答案;随着深度学习的蓬勃发展,出现了基于深度学习的方法,此类方法将文本表示成低维的稠密向量,使得传统自然语言处理中的语义鸿沟现象可以通过低维稠密向量间的数值计算得到一定程度的改善。本文主要研究基于深度学习的知识库问答。

当前基于深度学习的主流知识库问答方法^[6-10]主要包含两个步骤:实体检测和关系识别。首先通过命名实体识别技术将问句中的头实体检测出来,将其作为候选实体在知识库中匹配出子图,然后将所有与候选实体相关联的关系与原问句通过神经网络做相似度计算并对结果排序,从而得到答案。Hakimov 等^[11]使用一个标准的 LSTM(Long Short-Term Memory)序列标注模型对问题进行标注;Zhao 等^[12]通过计算候选实体与检测实体的共现概率来度量两者之间的语义相似性,从而更精确地对知识库中的实体进行召回;Abolghasemi 等^[13]提出了一种基于实例的方法来预测问题中的关系。但是,此类流水线方法忽略了两项基本任务之间的联系以及可能导致的错误传播问题,并且也没有利用知识库本身的结构信息,而这些信息对于捕获完整的实体和关系语义信息有着很大的帮助。另外,匹配出的子图有时会非常庞大,进行排序时需将其全部输入神经网络中进行计算,这意味着计算开销非常大。

基于以上分析,本文针对简单类型的知识库问答提出了一种基于知识库嵌入的联合训练模型,利用知识库本身以及实体检测和关系识别两项任务之间的联系来提高问答的准确率。具体来说,首先通过 TransE 模型对知识库进行预训练,得到每个实体和关系的向量表示。联合训练模型同时包含实体检测和实体/关系表示模块,两个模块共享双向门控循环单元(Gate Recurrent Unit,GRU)^[14]编码层,其目的是同时考虑输入字符的前后文;另一方面,双向 GRU 编码层通过实体检测任务可以学到输入问句的潜在语义信息,在减少参数的同时有助于实体/关系表示。由于本文方法在召回排序阶段只涉及到向量间距离的并行计算,因此相比已有方法其在速度上有了进一步的提升。

本文使用公开数据集(Simple Question)^[15]来验证所提模型。实验结果表明,所提模型在答案检索任务的准确率上达到了主流的水平,并且验证了联合训练和知识表示学习对于知识库问答任务在模型训练效率以及答案检索准确率方面的提升作用。本文的主要贡献如下:

- (1)通过知识库嵌入和实体/关系表示学习,将问句和知识库中的实体/关系嵌入相同维度的空间;
- (2)验证了知识表示学习方法有助于提升知识库问答的准确度;
- (3)将多任务学习引入知识库问答,与以往的知识库问答模型相比,本文模型不仅实现了端对端的问答,还降低了模型的参数,进一步简化了网络结构,大大提升了训练速度。

2 基于知识表示的联合问答模型

本节将介绍本文的任务以及提出的知识库问答模型,主要分为两个部分:1)知识库嵌入模型;2)实体检测和实体/关

系表示的联合学习模型。具体来说,首先利用 TransE 模型对知识库中的三元组 (e_h, r, e_t) 进行预训练,得到每个实体和关系的低维向量表示 (e, r) ,然后利用联合学习模型,以问句为输入来完成的任务,任务 1 得到问句中的实体标识,以便在后续查找中确定子图,缩小检索范围;任务 2 获得与 TransE 模型中的预训练向量同维度的实体/关系向量 $\tilde{e}/\tilde{r}$,通过打分函数对候选实体和关系进行排序,最后确定尾实体。

2.1 知识库嵌入模型

知识表示学习也称为知识库嵌入,其主要目的是对知识库中的实体和关系进行表示学习,进而在低维向量空间中高效计算实体与关系之间的语义联系。相比传统的基于独热表示的方法,可以有效缓解数据稀疏的问题。

本次实验采用的知识表示模型是 TransE 模型。在 TransE 模型中,对于知识库中的每个三元组 (e_h, r, e_t) 的向量表示 (e_h, r, e_t) ,TransE 将 e_t 看作是 e_h 基于 r 的一种平移。因此,对于每个三元组,TransE 模型希望:

$$e_h + r \approx e_t$$
 (1)

TransE 模型定义了如下所示的损失函数:

$$f_r(e_h, e_t) = \|e_h + r - e_t\|_2$$
 (2)

在训练过程中,TransE 模型采用最大间隔方法来增强知识表示的区分能力,定义了如下所示的目标函数:

$$L = \sum_{(h,r,t) \in S} \sum_{(h',r',t') \in S'} \max(0, f_r(e_h, e_t) + \gamma - f_r(e_{h'}, e_{t'}))$$
 (3)

其中, S 是原知识库中合法的三元组集合, S' 是在原来的 S 中随机替换掉头、尾实体或者关系所产生的负样本集合, γ 为一个常量。

2.2 实体检测和实体/关系表示的联合学习模型

以一个问句为输入时,本文的联合学习模型可以同时检测出问句中的实体部分和学习到问句的实体/关系向量表示,模型框架如图 1 所示。该模型首先将问句映射为预训练词向量,进入双向 GRU 进行特征提取,然后将双向 GRU 的输出向量进行拼接,分别送入实体检测模块(Entity Detection Module)和实体/关系向量表示模块(Entity/Relation Representation Module)中,在实体检测模块中将此输出向量映射为问句中对应的实体与非实体,在实体/关系向量表示模块中将此输出向量映射为问句对应的实体与关系的向量表示。




图 1 基于知识表示的联合问答模型

Fig. 1 Joint question answering model based on knowledge representation

2.2.1 实体检测模块

实体检测模块主要负责检测出问句中可能属于实体的部分,从而确定知识库中待检索的子图。当知识库中的数据量特别庞大时,提高实体检测模块准确率对于整个模型的运行效率的提升有着巨大的帮助。

首先将问句中的每个单词做词嵌入并转换为向量 $\{w_i\}$, $i=1,\dots,V$, V 为字典大小,其次将其送入双向 GRU 中的网络,将双向 GRU 每个单元的隐层输出拼接起来得到 $\mathbf{h}_i = [\vec{\mathbf{h}}_i; \overleftarrow{\mathbf{h}}_i]$, 并在此应用注意力机制得到加权之后的隐层向量,然后输入一个全连接层,最后应用 softmax 激活函数得到向量 $\mathbf{v}_i$, 其对应属于不同实体类别的概率值。

假设问句中的实体都是连续的,若上一步得到的结果是离散的,则需要把它们连接起来作为实体,并且在确定知识库检索子图时,还需要将知识库中所有含有问句实体检测结果字段的实体作为候选实体。

2.2.2 实体/关系向量表示模块

为了充分利用知识库本身的结构信息来提升问答的准确率,本文设计了实体/关系向量表示模块,直接将双向 GRU 的隐层输出经过全连接层映射到与知识库预训练向量同维度的空间中。

在训练时,本文同样采用多任务训练的方式,问句经过模型的实体/关系向量表示模块进行特征提取,可以得到其关系向量表示 $(\tilde{\mathbf{e}}, \tilde{\mathbf{r}})$, 结合问句在知识库中对应的实体/关系向量 $(\mathbf{e}, \mathbf{r})$, 在训练时设计实体表示的损失函数为:

$$Loss = \|\tilde{\mathbf{e}} - \mathbf{e}\|_2$$

(4)

关系表示模块的损失函数与实体表示模块的损失函数类似,并采用 Adam 优化算法进行参数更新。

2.3 答案检索

在答案检索部分,本文设计了多个度量标准来筛选最后的答案。具体来说,对于每一个问句 q , 经过嵌入之后输入联合学习模型得到实体检测结果和实体/关系表示向量 $(\tilde{\mathbf{e}}, \tilde{\mathbf{r}})$, 再利用实体检测模块所得的结果字段 e_h 按照字符匹配的方式从知识库中筛选出所有包含此字段的实体,将其加入头实体候选集合 C , 针对集合 C 中的每个头实体 $e_i (i=1, 2, \dots)$ 所在的三元组及其预训练向量表示 $(\mathbf{h}_i, \mathbf{r}_i, \mathbf{t}_i)$, 采用式(5)来计算答案的匹配程度。

$$Scores(\mathbf{h}_i, \mathbf{r}_i, \mathbf{t}_i) = Rate(e_h, e_i) - (\alpha_1 \|\tilde{\mathbf{e}} - \mathbf{h}_i\|_2 + \alpha_2 \|\tilde{\mathbf{r}} - \mathbf{r}_i\|_2 + \alpha_3 \|\tilde{\mathbf{e}} + \tilde{\mathbf{r}} - \mathbf{h}_i - \mathbf{r}\|_2)$$

(5)

其中, $Rate(e_h, e_i)$ 表示 e_h, e_i 的字符匹配分数, $\alpha_1, \alpha_2, \alpha_3$ 是常量。考虑到一个头实体和关系可能对应多个尾实体,此处使用头尾实体的向量表示之和来代替尾实体的表示,向量之间的相似性采用欧氏距离来度量。完整的算法流程如算法 1 所示。

算法 1 基于知识表示的知识库联合问答模型框架

输入: 知识库 G 及其向量表示 $\mathbf{G}$, 问句训练集 Q , 新的问句 q

输出: 头实体 h^* , 关系 r^*

/* 训练实体检测模块: */

1. for Q_i in Q do

2. 将问题 Q_i 输入网络,并将其实体标记作为标签进行训练;

3. 更新网络参数;

/* 训练实体/关系向量表示模块: */

4. for Q_i in Q do

5. 将问题 Q_i 输入网络,并将其在 G 中对应的实体/关系向量 $(\mathbf{e}, \mathbf{r})$ 作为标签进行训练;

6. 更新网络参数以最小化损失函数式(4);

/* 问答阶段: */

7. 将问句 q 输入实体检测模块获得实体字段 e_h , 并根据字符匹配在知识库中匹配出候选头实体集合 C ;

8. 将问句 q 输入实体/关系向量表示模块,获得其实体/关系的向量表示 $(\tilde{\mathbf{e}}, \tilde{\mathbf{r}})$;

9. 对于集合 C 中的所有候选头实体所在的三元组及其预训练向量表示 $(\mathbf{h}_i, \mathbf{r}_i, \mathbf{t}_i)$, 利用式(5)计算出得分最高的实体与关系 h^*, r^* .

总的来说,本文提出的基于知识表示的联合问答模型有以下优点:1)通过利用知识表示中保留的结构和关系信息,模型可以更好地处理同名实体与同名关系的冲突问题;2)由于应用了多任务学习的策略,模型可以同时执行实体检测、实体/关系向量表示这几个子任务,提高了训练效率,且各个任务之间能相互补充;3)模型可以推广至不同的知识嵌入算法,因此可以通过更复杂的知识库嵌入算法来进一步提升模型的性能。

3 实验结果及分析

3.1 数据集介绍

本节首先介绍了 Freebase 以及本文所用到的数据集 FB2M 和 SimpleQuestions。

Freebase 是一个由元数据组成的大型合作知识库,内容主要来自其社区成员。Freebase 中的条目都采用结构化数据形式,整个 Freebase 可以看作是一张大图,每个节点都使用 type/object 来定义,边用 type/link 来定义。每个条目称为一个 Topic,一个 Topic 往往有很多属性,例如某一个人有姓名、性别、出生日期等属性。每个条目可用一个三元组来表示(头实体、关系、尾实体),如“姚明的职业是篮球运动员”可以表示为(姚明,职业,篮球运动员)。Freebase 中的每个实体都有唯一的 ID,称为 MID。

FB2M 是 Freebase 的一个子集,其所包含的实体和关系数如表 1 所列。由于 Freebase 的 API 已经关闭,因此本文采用一个整理好的实体名集合¹⁾来建立 MID 及其实体名的映射。

表 1 实验数据集

Table 1 Experimental dataset

	FB2M	Simple Questions
Training	14 174 246	75 910
Validation	n/a	10 845
Test	n/a	21 687
Entities	6 701	1 837
Predicates	1 963 130	131 681

SimpleQuestions 包含 10 万个以上的简单问题,每个问题都对应于 Freebase 中的一个三元组,因此建立问题与答案

¹⁾ <https://github.com/zihangdai/CFO>

²⁾ <https://pypi.org/project/Fuzzy>

的映射。本文假定所有的问题只要准确地确定了其中的头实体和关系,就可以找出正确答案。

3.2 模型设置

在知识库嵌入部分,本文采用 TransE 算法将知识库中的实体表示为 250 维的向量;在问句嵌入部分采用了 Glove^[16] 预训练模型,将问句的每个单词嵌入到 300 维的向量空间中;在答案检索的字符匹配部分使用了 Fuzzy²⁾。模型基于 Pytorch 实现,并采用 Adam 算法进行参数更新。实验使用 Linux 操作系统,CPU 型号为 Intel i7-6700HQ @ 2.6 GHz,GPU 型号为 NVIDIA GeForce GTX 1080。

3.3 实验结果

本文与近年来提出的基于 SimpleQuestion 数据集的知识库问答方法进行了对比,结果如表 2 所列。

表 2 SimpleQuestions 数据集上的结果

Table 2 Results on SimpleQuestions dataset

Methods	Precision/%	Improvement
Bordes et al. ^[15]	62.7	+20%
Yin et al. ^[17]	68.3	+10.2%
Golub et al. ^[18]	70.9	+6.2%
Lukovnikov et al. ^[6]	71.2	+5.7%
Bao et al. ^[7]	72.8	+3.4%
Ours	75.3	—

一些实验成果^[8,17]有着更高的准确率,因为它们均利用了谷歌的 API 和其他研究的结果,可以在很大程度上避免错误实体的出现。但是,此 API 已经关闭,本文工作是完全建立在没有引入外部知识的前提下的。由表 2 可以得出以下结论:1)以往知识库问答的工作大多都是基于实体检测和关系识别的流水线方法,而本文提出的联合训练模型成功地将这两个步骤整合到了一起;2)与 Huang 等^[19]提出的方法相比,本文在同样的机器上用更少的参数量实现了与其几乎一样的准确率,且用时缩短了一半,验证了联合学习模型的轻量级和高效率;3)本文模型相比以往的模型在准确度上有不同程度的提高,达到了主流水平。

3.4 详细分析

3.4.1 不同知识库嵌入模型对实验结果的影响

为了验证知识库嵌入对知识库问答准确度的提升作用,本文随机生成了知识库中的实体和关系向量。为了验证不同的知识库嵌入模型对实验结果的影响,本文采用另外两种知识库嵌入模型 TransH^[20]和 TransR^[21],这两种模型都是针对 TransE 模型在一对多、多对一、多对多等复杂关系类型的数据上建模效果不佳的改进算法。延续 TransE 将关系看作头实体到尾实体的“翻译”过程,其主张在不同关系下的实体拥有不同的表示;TransR 进一步拓展了 TransH,将关系和实体放在不同的向量空间中,然后将实体向量映射到关系向量空间中以完成“翻译”过程。

本实验应用不同知识库嵌入模型的结果如表 3 所列。

表 3 应用不同知识库嵌入模型的结果

Table 3 Results of applying different knowledge base embedding models

	Precision/%
No Knowledge Embedding	71.1
TrasnE	75.3
TransH	74.6
TransR	75.1

由表 3 所列的实验数据可以得出以下结论:1)知识库嵌入的加入确实能够提高知识库问答的准确率;2)不同的知识库嵌入模型对于知识库问答表现的提升略有不同,再次验证了 TransE 模型简单且有效。

3.4.2 不同度量指标对答案筛选的影响

为了验证式(5)中不同指标对答案筛选的影响,我们在保留 $Rate(e_t, e_i)$ 项的基础上,对后续的 3 项分别予以剔除或保留再进行实验。实验结果如表 4 所列。

表 4 采用不同度量指标的准确率

Table 4 Accuracy with different metrics

	Precision/%
$\alpha_1 \ \tilde{e} - h_i \ _2$	0.185
$\alpha_2 \ \tilde{r} - r_i \ _2$	0.711
$\alpha_3 \ \tilde{e} + \tilde{r} - h_i - r_i \ _2$	0.729
$\alpha_1 \ \tilde{e} - h_i \ _2 + \alpha_2 \ \tilde{r} - r_i \ _2$	0.752
$\alpha_1 \ \tilde{e} - h_i \ _2 + \alpha_3 \ \tilde{e} + \tilde{r} - h_i - r_i \ _2$	0.698
$\alpha_2 \ \tilde{r} - r_i \ _2 + \alpha_3 \ \tilde{e} + \tilde{r} - h_i - r_i \ _2$	0.751

从表 4 中的数据可以看出,关系度量项 $\| \tilde{r} - r_i \|_2$ 的保留对于结果的提升帮助最大,说明问句的关系表示 $\tilde{r}$ 在联合学习模型中充当着最重要的角色,另外实体度量项 $\| \tilde{e} - h_i \|_2$ 可以对尾实体度量项 $\| \tilde{e} + \tilde{r} - h_i - r_i \|_2$ 起到很好的补充作用。

结束语 本文将知识表示学习和多任务训练引入知识库问答,将知识库中的实体和关系均映射到低维向量空间中,通过联合学习模型同时得到问句中的实体部分以及实体/关系的向量表示,并在低维向量空间中通过多项指标来度量语义相似度。实验结果表明,本文提出的联合学习模型以更轻量级的结构达到了主流的水平。

下一步的工作将继续探索如何才能更好地捕获问句与知识库中三元组的语义相关度,从而寻找到更好的知识表示学习方法。但是,现有方法可能无法保证问句与三元组向量表示的每一维的特征相同。针对同一词语的不同表达方式,可考虑引入同义词典的方式来缓解语言的歧义。

参 考 文 献

[1] FABIAN M S,GJERGJI K,GERHARD W. Yago:A core of semantic knowledge unifying wordnet and wikipedia[C]// Proceedings of the 16th International World Wide Web Conference. New York:ACM Press,2007:697-706.

[2] BOLLACKER K,EVANS C,PARITOSH P,et al. Freebase;a collaboratively created graph database for structuring human knowledge[C]//Proceedings of the 2008 ACM SIGMOD International Conference on Management of Data. New York:ACM Press,2008:1247-1250.

[3] CARLSON A,BETTERIDGE J,KISIEL B,et al. Toward an architecture for never-ending language learning[C]// Proceedings of Twenty-Fourth AAAI Conference on Artificial Intelligence. Menlo Park:AAAI Press,2010:1306-1313.

[4] LEHMANN J,ISELER J,JAKOB M,et al. DBpedia a large-scale, multilingual knowledge base extracted from Wikipedia [J]. Semantic Web,2015,6(2):167-195.

[5] 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. New York: Association for Computing Machinery Press, 2009: 976-984.
- [6] LUKOVNIKOV D, FISCHER A, LEHMANN J, et al. Neural network-based question answering over knowledge graphs on word and character level[C]//Proceedings of the 26th International World Wide Web Conference. New York: ACM Press, 2017:1211-1220.
- [7] BAO J, DUAN N, YAN Z, et al. Constraint-based question answering with knowledge graph[C]//Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics. Stroudsburg: ACL Press, 2016:2503-2514.
- [8] 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. Stroudsburg: ACL Press, 2016:800-810.
- [9] HE X, GOLUB D. Character-level question answering with attention[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL Press, 2016:1598-1607.
- [10] FAN M, FENG Y, SUN M, et al. Multi-task neural learning architecture for end-to-end identification of helpful reviews[C]//Proceedings of the 2018 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining. New York: IEEE Press, 2018:343-350.
- [11] HAKIMOV S, JEBBARA S, CIMIANO P. Evaluating Architectural Choices for Deep Learning Approaches for Question Answering Over Knowledge Bases [C] // Proceedings of the 2019 IEEE 13th International Conference on Semantic Computing. New York: IEEE Press, 2019:110-113.
- [12] ZHAO W B, CHUNG T, GOYAL A, et al. Simple Question Answering with Subgraph Ranking and Joint-Scoring[C]//Proceedings of Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Stroudsburg: ACL Press, 2019:324-334.
- [13] ABOLGHASEMI A, MOMTAZI S. Neural Relation Prediction for Simple Question Answering over Knowledge Graph[J]. arXiv, 2002. 07715v3, 2020.
- [14] CHO K, VAN MERRIËNBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL Press, 2014:1724-1734.
- [15] BORDES A, USUNIER N, CHOPRA S, et al. Large-scale simple question answering with memory networks[J]. Computer Science, 2015, 7(2):256-265.
- [16] PENNINGTON J, SOCHER R, MANNING C D. Glove: Global vectors for word representation[C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL Press, 2014:1532-1543.
- [17] YIN W, YU M, XIANG B, et al. Simple question answering by attentive convolutional neural network [C] // Proceedings of COLING 2016, the 26th International Conference on Computational Linguistics. Stroudsburg: ACL Press, 2016:1746-1756.
- [18] GOLUB D, HE X. Character-level question answering with attention[C]//Proceedings of the 2016 Conference on Empirical Methods in Natural Language Processing. Stroudsburg: ACL Press, 2016:1598-1607.
- [19] HUANG X, ZHANG J, LI D, et al. Knowledge graph embedding based question answering [C] // Proceedings of the Twelfth ACM International Conference on Web Search and Data Mining. New York: ACM Press, 2019:105-113.
- [20] WANG Z, ZHANG J, FENG J, et al. Knowledge graph embedding by translating on hyperplanes [C] // Proceedings of the Twenty-Eighth AAAI Conference on Artificial Intelligence. Stroudsburg: ACL Press, 2014:1112-1119.
- [21] LIN Y, LIU Z, SUN M, et al. Learning entity and relation embeddings for knowledge graph completion[C]//Proceedings of the Twenty Ninth AAAI Conference on Artificial Intelligence. Stroudsburg: ACL Press, 2015:2181-2187.



LIU Xiao-long, born in 1994, postgraduate. His main research interests include natural language process and knowledge based question answering.



HAN Fang, born in 1981, Ph.D, professor, Ph.D supervisor. Her main research interests include intelligence system and neurodynamics.