



基于预训练语言模型的中文知识图谱问答系统



王鑫雷, 李帅驰, 杨志豪, 林鸿飞, 王健 (大连理工大学, 计算机科学与技术学院)

论文摘要

近年来, 预训练语言模型在英文知识图谱问答研究中取得了令人瞩目的成绩。该文将预训练语言模型应用到中文知识图谱问答研究中, 并通过实验结果分析不同模型及不同预训练语言模型的性能, 验证了 ERNIE(Enhanced Representation from Knowledge Integration)语言模型更适合完成中文问答任务。同时, 该文提出一套高效的流水线方法, 在实体提及识别、实体链接、关系匹配子任务上提出新的框架来提升识别匹配结果, 并在 CCKS2019-CKBQA 测试集上达到了 69.9%的 F1 值。最终基于该文方法在 web 端实现了知识图谱的问答系统展示, 可回答大量开放域问题。

论文简介

该文基于不同预训练模型, 设计了一套知识问答的流水线系统。将系统模块化为实体提及识别、实体链接、关系匹配模块。同时基于问句类型分类, 将复杂问句的两种类型迭代化回答。

算法原理

1. 实体提及识别: 分词 (实体链接词典、分词词典、领域词典)
基于语言模型的实体识别
属性识别 (正则式、时间属性、模糊匹配)
2. 实体链接: 实体提及特征
实体特征
3. 关系匹配: 基于语言模型的关系匹配模型
4. 桥接及答案检索: 多实体桥接结合字数重叠解决部分多实体复杂问题


实验仿真

表1 数据集划分

问题类型	训练集 (条)	验证集 (条)	测试集 (条)
单实体单关系	1159	476	455
单实体多关系	682	156	140
多实体	357	134	171
总数	2298	766	766

系统模型

模型如图, 包含以下五个模块: 问题分类、实体提及识别、实体链接、关系匹配、桥接及答案检索。



模型	F1 值
Siamase	49.7%
BERT-match	64.6%
XLNet-match	64.9%
RoBERTa-match	65.0%
ERNIE-match	65.5%
ERNIE-match+桥接	67.8%
ERNIE-match+桥接+字面匹配	69.9%

表2 问答系统的 F1 值



系统图网站页面

论文结论

该文通过实验验证 ERNIE 语言模型更适合应用在中文图谱问答任务中。同时在实体提及识别、实体链接、关系匹配子任务上提出的新框架有助于高效精确的识别匹配结果。并通过在 CCKS2019-CKBQA 测试集上的结果验证方法的有效性, 最后基于本文方法实现了问答系统展示。后续工作考虑对复杂问题进行语义解析, 并融入知识图谱的全局信息增强问答性能。

