

# 基于知识的自然语言问答

冯岩松

fengyansong@pku.edu.cn

北京大学

# 主要内容

① 背景

② 传统解决方案

③ 基于深度学习的解决方案

④ 新视角

⑤ 小结

# 问答: 提问—回答

人工智能领域经典任务

自然语言问句 — 回答

# 问答: 提问—回答

人工智能领域经典任务

自然语言问句 — 回答

- (可能) 衡量计算机系统的智能化水平
- 应用场景广泛
- 形式多种多样
- 难!

# 问答: 提问—回答

## 人工智能领域经典任务

### 自然语言问句 — 回答

- (可能) 衡量计算机系统的智能化水平
  - 应用场景广泛
  - 形式多种多样
  - 难!
- 
- **Q:** 美国第一位黑人总统是谁?
  - **A:** 巴拉克·奥巴马

# 问答: 提问—回答

## 人工智能领域经典任务

### 自然语言问句 — 回答

- (可能) 衡量计算机系统的智能化水平
  - 应用场景广泛
  - 形式多种多样
  - 难!
- 
- **Q:** 什么时候跟美国打?
  - **A:** 额, 1950年朝鲜啊……

# 问答: 提问—回答

## 人工智能领域经典任务

### 自然语言问句 — 回答

- (可能) 衡量计算机系统的智能化水平
  - 应用场景广泛
  - 形式多种多样
  - 难!
- 
- **Q:** 宫保鸡丁怎么做?
  - **A:** 爆炒鸡脯丁，加花生米和葱段……

# 问答: 提问—回答

## 人工智能领域经典任务

### 自然语言问句 — 回答

- (可能) 衡量计算机系统的智能化水平
- 应用场景广泛
- 形式多种多样
- 难!

• Q: 天上为什么会下雨?

• A: 等我搜一下.....:-((

# 问答: 提问—回答

## 人工智能领域经典任务

### 自然语言问句 — 回答

- (可能) 衡量计算机系统的智能化水平
  - 应用场景广泛
  - 形式多种多样
  - 难!
- 
- Q: 作者想表达对故乡的什么情感?
  - A: .....

# 问答: 提问—回答

## 人工智能领域经典任务

### 自然语言问句 — 回答

- (可能) 衡量计算机系统的智能化水平
  - 应用场景广泛
  - 形式多种多样
  - 难!
- 
- **Q:** 最近自然语言处理流行什么?
  - **A:** 你是说BERT? 还是ELMo? 还是.....Sesame Street!

# 问答: 提问—回答

## 人工智能领域经典任务

### 自然语言问句 — 回答

- (可能) 衡量计算机系统的智能化水平
- 应用场景广泛
- 形式多种多样
- 难!

- Q: 吃了吗?
- A: 唉, 跟没吃一样啊.....

## 检索关键词

战狼2 导演



Web

Images

Videos

翻译成中文

关闭取词

检测到您输入了中文或拼音，试试切换到国内版？搜中文结果更准确 >

1,260,000 RESULTS

[《战狼2》导演特辑 硬汉吴京变身全能铁人\\_战狼2\\_电影\\_](#)

...

<https://v.qq.com/x/cover/wi8e2p5kirdaf3j/e0501cerget.html> [Translate this page](#)

《战狼2》的故事讲述了正经历人生最低谷的冷锋，原想在海上漂泊了此一生，却卷入了一场非洲国家的叛乱。本可以安全撤离 ...

[《战狼2》导演特辑\\_腾讯视频 - v.qq.com](#)

<https://v.qq.com/x/page/v05376hi5zc.html> [Translate this page](#)

pc客户端连续签到 5天送vip pc客户端 免费蓝光播放 pc客户端 3倍流畅播放 pc客户端 提前一小时追剧 pc客户端 自动更新下载剧集



## 自然语言问题

战狼2的导演是谁



Web

Images

Videos

Academic

Dict

Maps

21,500,000 RESULTS

Any time ▾

战狼2导演

吴京

[去必应网典查看更多](#)

[电影《战狼》导演是谁？ - 百度知道 - 全球 ...](#)

[Translate this page](#)

电影《战狼》导演是谁？《战狼》是由吴京执导的现代军事战争片，影片由吴京、余男、倪大红、斯科特·阿金斯、周晓鸥等领衔主演。该影片属于国内首部3D动作 ...

<https://zhidao.baidu.com/question/433362828824152284.html> ▾ 2016-2-1

[战狼2临时加价的女演员徐嘉雯是谁 徐嘉雯 ...](#)

[Translate this page](#)

## 自然语言问题

战狼2的导演是谁

[网页](#)[新闻](#)[贴吧](#)[知道](#)[音乐](#)[图片](#)[视频](#)[地图](#)[文库](#)[更多»](#)

百度为您找到相关结果约5,430,000个

▼ 搜索工具



战狼II导演：

吴京

吴京，1974年4月3日出生于北京，中国内地男演员、导演。毕业于北京体育大学。1989年进入北京市武术队。1994年获得全国武术比赛精英赛枪术、对练冠军。1998年主演电视剧《... 详情>》

来自百度百科 | 报错

# 问答

## 稍微复杂的自然语言问题

biggest river in china

Sign in  

Web Images Videos 翻译成中文 关闭取词

已为您默认开启词翻译，将鼠标移动到单词上稍作停留，即可获取中文翻译。

213,000,000 RESULTS Any time ▾



China · Longest river

# Yangtze

Yangtze River is the largest and longest river in China, even in Asia. Over 6,300 kilometres long, the mighty Yangtze is the largest and longest river in China, surpassed only by the Nile of Africa and the Amazon of South America.

[The Longest Rivers in China - Top China Travel](#)  
[www.topchinatravel.com/china-guide/the-longest-rivers-in-china.htm](http://www.topchinatravel.com/china-guide/the-longest-rivers-in-china.htm)

## Yangtze River

The Yangtze, known in China as the Cháng Jiāng or the Yángzì Jiāng, is the longest river in Asia and the third-longest in the world. The river is the longest in the world to flow entirely within one country. It drains one-fifth of the land area of the People's Repub... +



 [Wikipedia](#)

Length: 3,915 miles (6,300 km)  
Basin area: 698,266 sq miles (1.81 million km<sup>2</sup>)  
Discharge: 1,065,312 ft<sup>3</sup>/s (30,166 m<sup>3</sup>/s)  
Location: [China](#)  
Mouth: [East China Sea](#)  
Source: [Qinghai](#)

# 问答

## 稍微复杂的自然语言问题

中国第四长的河

[网页](#)[新闻](#)[贴吧](#)[知道](#)[音乐](#)[图片](#)[视频](#)[地图](#)[文库](#)[更多»](#)

百度为您找到相关结果约34,800,000个

搜索工具



中国第四长的河：

**珠江** (境内长度:2214千米)

珠江，又名粤江。因流经海珠岛而得名。是东、西、北三江及下游三角洲诸河的总称，发源于云贵高原乌蒙山系马雄山，流经中国中西部六省区及越南北部，在下游从八个入海口注... [详情»](#)

来自百度百科 | 报错

# 问答

## 再复杂一些

战狼系列的导演是谁



网页 新闻 贴吧 知道 音乐 图片 视频 地图 文库 更多»

百度为您找到相关结果约3,960,000个

搜索工具

### [电影《战狼》导演是谁?\\_百度知道](#)

2个回答 - 最新回答: 2015年04月09日 - 27人觉得有用

最佳答案: **《战狼》**是由吴京执导的现代军事战争片,影片由吴京,余男、倪大红、斯科特·阿金斯、周晓鸥等领衔主演。该影片属于国内首部3D动作战争电影,历...>>> ...

[更多关于战狼系列的导演是谁的问题>>](#)

[zhidao.baidu.com/link?url=...<span>...</span>](http://zhidao.baidu.com/link?url=...) - 百度快照

### [两部《战狼》的导演是谁\\_百度知道](#)

4个回答 - 最新回答: 2017年08月10日

最佳答案: 一二两部的**导演都是**吴京。只是,大家都没想到这部会火成这样。

[更多关于战狼系列的导演是谁的问题>>](#)

[zhidao.baidu.com/link?url=...<span>...</span>](http://zhidao.baidu.com/link?url=...) - 百度快照

# 问答

## 再复杂一些

战狼系列的导演是谁



网页 新闻 贴吧 知道 音乐 图片 视频 地图 文库 更多»

百度为您找到相关结果约3,960,000个

搜索工具

### 电影《战狼》导演是谁\_百度知道

2个回答 - 最新回答: 2015年04月09日 - 27人觉得有用

最佳答案: 《战狼》是由吴京执导的现代军事战争片,影片由吴京,余男、倪大红、斯科特·阿金斯、周晓鸥等领衔主演。该影片属于国内首部3D动作战争电影,历...>>> ...

[更多关于战狼系列的导演是谁的问题>>](#)

[zhidao.baidu.com/link?... ▾](http://zhidao.baidu.com/link?...) - 百度快照

### 两部《战狼》的导演是谁\_百度知道

4个回答 - 最新回答: 2017年08月10日

最佳答案: 一二两部的导演都是吴京。只是,大家都没想到这部会火成这样。

[更多关于战狼系列的导演是谁的问题>>](#)

[zhidao.baidu.com/link?... ▾](http://zhidao.baidu.com/link?...) - 百度快照

- 语义分析
- 多源知识

# 更多问答

- 聊天
- 客服
- 个人助理
- 智能家居

# 更多问答

- 聊天
- 客服
- 个人助理
- 智能家居
- IBM Watson



# 更多问答

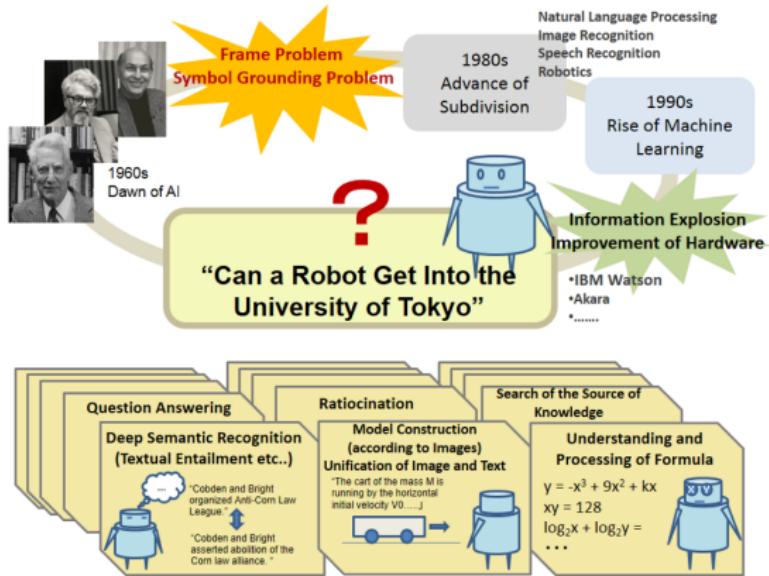
- 聊天
- 客服
- 个人助理
- 智能家居
- IBM Watson
- 参加考试:  
**AI2, Todai, 863**
  - ▶ 小学: 数学, ...
  - ▶ 中学: 自然科学,  
数学, ...
  - ▶ 高考:



# 更多问答

- 聊天
- 客服
- 个人助理
- 智能家居
- IBM Watson
- 参加考试:  
**AI2, Todai, 863**

- ▶ 小学: 数学, ...
- ▶ 中学: 自然科学, 数学, ...
- ▶ 高考: **数学, 语文, 历史, 地理, ...**



# 更多问答

- 聊天
- 客服
- 个人助理
- 智能家居
- IBM Watson
- 参加考试:  
**AI2, Todai, 863**
  - ▶ 小学: 数学, ...
  - ▶ 中学: 自然科学, 数学, ...
  - ▶ 高考: **数学, 语文, 历史, 地理, ...**



# 更多问答

- 聊天
- 客服
- 个人助理
- 智能家居
- IBM Watson
- 参加考试:  
**AI2, Todai, 863**
  - ▶ 小学: 数学, ...
  - ▶ 中学: 自然科学, 数学, ...
  - ▶ 高考: 数学, 语文, 历史, 地理, ...
  - ▶ 医师资格考试
  - ▶ 司法考试

# 问答领域

- 检索类问答
  - ▶ 搜索引擎
  - ▶ 社区问答
  - ▶ FAQ
- 知识类问答
  - ▶ 知识库问答
  - ▶ 常识知识问答
- 交互类问答
  - ▶ 聊天
  - ▶ 任务式对话
- 机器阅读/理解

# 问答领域

- 检索类问答
  - ▶ 搜索引擎
  - ▶ 社区问答
  - ▶ FAQ
- 知识类问答
  - ▶ 知识库问答
  - ▶ 常识知识问答
- 交互类问答
  - ▶ 聊天
  - ▶ 任务式对话
- 机器阅读/理解
- 一问一答
- 多轮问答

# 问答领域

- 检索类问答
  - ▶ 搜索引擎
  - ▶ 社区问答
  - ▶ FAQ
- 知识类问答
  - ▶ 知识库问答
  - ▶ 常识知识问答
- 交互类问答
  - ▶ 聊天
  - ▶ 任务式对话
- 机器阅读/理解
- 一问一答
- 多轮问答

# 问答领域

- 检索类问答
  - ▶ 搜索引擎
  - ▶ 社区问答
  - ▶ FAQ
- 知识类问答
  - ▶ 知识库问答
  - ▶ 常识知识问答
- 交互类问答
  - ▶ 聊天
  - ▶ 任务式对话
- 机器阅读/理解
- 一问一答
- 多轮问答

# 梳理一下

Template-based QA  
Expert System

IR-based QA

Community QA

KB-based QA

1960

BaseBall

LUNAR

MACSYMA

SHRDLE

1990

MASQUE  
TREC

Text REtrieval Conference (TREC)  
to encourage research & information retrieval  
from large text collections



2000

START

YAHOO!  
ANSWERS  
BETA

ask.  
answer.  
discover.



# 知识问答

任务

利用知识回答自然语言问题

# 知识问答

## 任务

利用知识回答自然语言问题

- 输入：自然语言问句
- 资源：结构化知识库
- 输出：答案

<主体, 关系, 客体 >

<费城, 位于, 美国 >

.....

# 知识问答

## 任务

利用知识回答自然语言问题

- 输入： 自然语言问句
- 资源： 结构化知识库，文本知识，表格，结构化/半结构化记录，.....
- 输出： 答案

<主体, 关系, 客体 >

<费城, 位于, 美国 >

.....

费城, 美国东部重要的工业城市, .....

# 任务框架



Theatrical release poster

Directed by	Christopher Nolan
Produced by	Emma Thomas Christopher Nolan Lynda Obst
Written by	Jonathan Nolan Christopher Nolan
Starring	Matthew McConaughey Anne Hathaway Jessica Chastain Bill Irwin Ellen Burstyn Michael Caine

What else did the director of the movie Interstellar direct ?

select ?y

```
[ fb:m:0fkf28      fb:object.type      fb:film.film
  fb:m:0fkf28  fb:film.film.directed_by  ?x
  ?x            fb:film.director.film    ?y
  ?y            fb:object.type          fb:film.film ]
```



Inception,  
*The Dark Knight Rises*  
*The Dark Knight*  
*Batman Begins*  
....

# 任务框架

What else did the director of the movie Interstellar direct ?

Convert to  
a Query

select ?y

```
[ fb:m.0fkf28      fb:object.type      fb:film.film
    fb:m.0fkf28  fb:film.film.directed_by  ?x
    ?x            fb:film.director.film   ?y
    ?y            fb:object.type        fb:film.film ]
```

Query over  
KBs

Freebase

DBpedia

*Inception,*  
*The Dark Knight Rises*  
*The Dark Knight*  
*Batman Begins*  
....

# 早期工作

- **Baseball** : 有关棒球比赛的问答 [Green et al., 1961]
  - ▶ How many games did the Yankees play in July?
- **LUNAR**: 有关科研数据的问答 [Woods, 1973]
  - ▶ How many samples contain Titanium?
- 订机票、地理知识、找工作.....
  - ▶ ATIS, GeoQuery, JOBS ...

# 早期工作

- **Baseball**: 有关棒球比赛的问答 [Green et al., 1961]
  - ▶ How many games did the Yankees play in July?
- **LUNAR**: 有关科研数据的问答 [Woods, 1973]
  - ▶ How many samples contain Titanium?
- 订机票、地理知识、找工作.....

## 存在的问题

- 面向特定领域
- 知识库规模有限:
  - ▶ 数百个实体、几十种关系、数千个三元组
- 规则驱动！依赖手工设计的模板或规则来解析问题:
  - ▶ 仅覆盖有限的表述方式；对复杂问题支持不足
- 难以应付开放域:
  - ▶ 成千上万的实体、关系；上亿三元组
  - ▶ 多种知识资源：KB、文本、表格，.....

更多实体、更多关系



# 常见数据集

- [Free917](#)
  - ▶ 使用Freebase
  - ▶ 917个问题,标注了逻辑表达式
- [WebQuestions](#)
  - ▶ 使用Freebase
  - ▶ 5,819个问题,通过Google Suggest API爬取
  - ▶ 利用 Amazon Mechanical Turk 服务得到答案,一个问题可能存在多个答案
  - ▶ 利用 Average F1 评价
  - ▶ [WebQuestionsSP](#): WebQuestions with SPARQL annotations
- [QALD](#)
  - ▶ 知识库问答评测, QALD:Question Answering over Linked Data
  - ▶ 使用 DBpedia
  - ▶ 每年100个问题左右
  - ▶ Hybrid Track: DBpedia不足以完整回答问题,必须依靠文本信息
- [Simple Questions](#)
  - ▶ 108,442个简单问题,附带一条Freebase 三元组作为答案

# 常见数据集

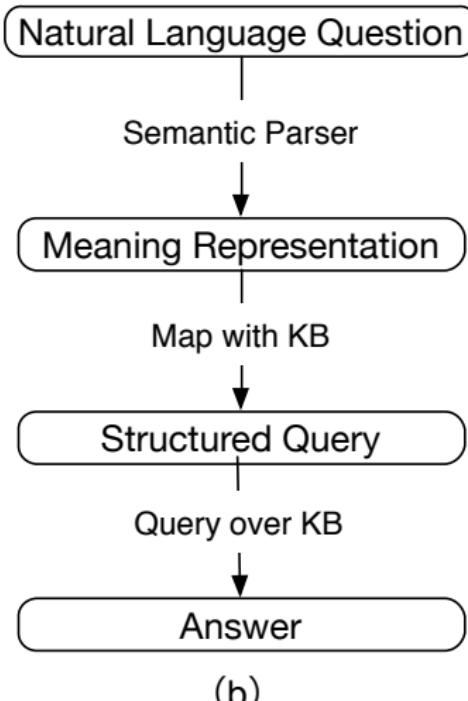
数据集	规模	数据形式	其他
ATIS	5410	问答对	
JOBS	640	问题+结构化查询	
GeoQuery	880	问答对+逻辑表达式	
QALD Series	150-300/年	问答对+结构化查询	
Free9117	917	问答对+逻辑表达式	
WebQuestions	3782/2037	问答对	
WebQuestionsSP	3098/1639	问答对+结构化查询	
SimpleQuestions	108,442	问答对	
ComplexQuestions	2,100	问答对	
WikiMovies	100k	问答对	
MSParse	100k	问题+逻辑表达式	
GraphQuestions	5166	问题+结构化查询	
LcQuAD	5k	问题+结构化查询	
LcQuAD 2.0	30k	问题+结构化查询	

Table: 知识问答任务种的典型数据集

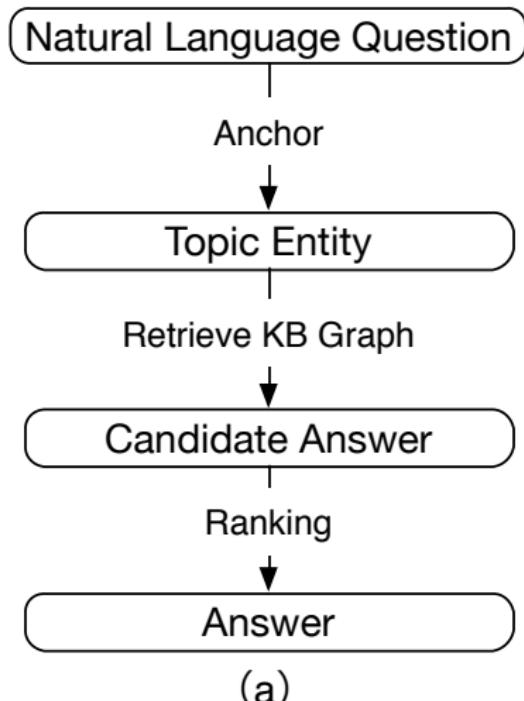
# A Tale of Two Streams

语义分析 (SP)

信息抽取 (IE)



(b)



(a)

# 现有知识问答技术

- 语义分析 (SP)

- ▶ 语义分析: (P)CCG - Zettlemoyer&Collins (2005, 2007), Kwiatkowski et al. (2013), Cai et al. (2013), Reddy et al. (2014), ...
- ▶ 传统句法分析: PCFG/SDP - Berant et al.(2013), Xu et al.(2015)...
- ▶ 文本复述: Paraphrase - Berant et al.(2014), Dong et al. (2017)

- 信息抽取 (IE)

- ▶ 接近传统检索式问答框架  
★ 寻找候选、筛选最佳 → 精挑细选
- ▶ Yao et al.(2014, 2015), Dong et al. (2015), ...

# 现有知识问答技术

- 语义分析 (SP)

- ▶ 语义分析: (P)CCG - Zettlemoyer&Collins (2005, 2007), Kwiatkowski et al. (2013), Cai et al. (2013), Reddy et al. (2014), ...
- ▶ 传统句法分析: PCFG/SDP - Berant et al.(2013), Xu et al.(2015)...
- ▶ 文本复述: Paraphrase - Berant et al.(2014), Dong et al. (2017)

- 信息抽取 (IE)

- ▶ 接近传统检索式问答框架  
★ 寻找候选、筛选最佳 → 精挑细选
- ▶ Yao et al.(2014, 2015), Dong et al. (2015), ...

- 各有千秋

- ▶ SP: **结构准确, 扩展能力欠缺**
- ▶ IE: **适应性好, 问题语义理解不足**

# 现有知识问答技术

- 语义分析 (SP)

- ▶ 语义分析: (P)CCG - Zettlemoyer&Collins (2005, 2007), Kwiatkowski et al. (2013), Cai et al. (2013), Reddy et al. (2014), ...
- ▶ 传统句法分析: PCFG/SDP - Berant et al.(2013), Xu et al.(2015)...
- ▶ 文本复述: Paraphrase - Berant et al.(2014), Dong et al. (2017)
- ▶ 神经网络!

- 信息抽取 (IE)

- ▶ 接近传统检索式问答框架  
★ 寻找候选、筛选最佳 → 精挑细选
- ▶ Yao et al.(2014, 2015), Dong et al. (2015), ...
- ▶ 神经网络!

- 各有千秋

- ▶ SP: 结构准确, 扩展能力欠缺
- ▶ IE: 适应性好, 问题语义理解不足

# 技术挑战

- 如何恰当地表示问题的语义
  - ▶ 丰富的提问方式, 复杂的提问意图
- 如何利用(大规模)(开放域)知识库元素来表示问题的语义
  - ▶ 大规模、开放域
- 需要什么样的知识来解答问题?
  - ▶ 知识的多样化
- 如何让模型真正可用?
  - ▶ 探索落地

# 技术挑战

- 如何恰当地表示问题的语义
  - ▶ 丰富的提问方式, 复杂的提问意图 → 语义表示、语义分析
- 如何利用(大规模)(开放域)知识库元素来表示问题的语义
  - ▶ 大规模、开放域
- 需要什么样的知识来解答问题?
  - ▶ 知识的多样化
- 如何让模型真正可用?
  - ▶ 探索落地

# 技术挑战

- 如何恰当地表示问题的语义
  - ▶ 丰富的提问方式, 复杂的提问意图 → 语义表示、语义分析
- 如何利用(大规模)(开放域)知识库元素来表示问题的语义
  - ▶ 大规模、开放域 → 知识库映射
- 需要什么样的知识来解答问题?
  - ▶ 知识的多样化
- 如何让模型真正可用?
  - ▶ 探索落地

# 技术挑战

- 如何恰当地表示问题的语义
  - ▶ 丰富的提问方式, 复杂的提问意图 → 语义表示、语义分析
- 如何利用(大规模)(开放域)知识库元素来表示问题的语义
  - ▶ 大规模、开放域 → 知识库映射 → 实体链接、关系抽取
- 需要什么样的知识来解答问题?
  - ▶ 知识的多样化
- 如何让模型真正可用?
  - ▶ 探索落地

# 技术挑战

- 如何恰当地表示问题的语义
  - ▶ 丰富的提问方式, 复杂的提问意图 → 语义表示、语义分析
- 如何利用(大规模)(开放域)知识库元素来表示问题的语义
  - ▶ 大规模、开放域 → 知识库映射 → 实体链接、关系抽取
- 需要什么样的知识来解答问题?
  - ▶ 知识的多样化 → 知识融合
- 如何让模型真正可用?
  - ▶ 探索落地 → 可解释性、鲁棒性

# 技术挑战

- 如何恰当地表示问题的语义
  - ▶ 丰富的提问方式, 复杂的提问意图 → 语义表示、语义分析
- 如何利用(大规模)(开放域)知识库元素来表示问题的语义
  - ▶ 大规模、开放域 → 知识库映射 → 实体链接、关系抽取
- 需要什么样的知识来解答问题?
  - ▶ 知识的多样化 → 知识融合
- 如何让模型真正可用?
  - ▶ 探索落地 → 可解释性、鲁棒性
- 传统方法的尽头?
  - ▶ 优势: 语义表示能力强
  - ▶ 瓶颈: 数据规模膨胀
- 深度学习方法的春天?
  - ▶ 优势: 处理大规模知识及语料, 有效利用噪声数据
  - ▶ 劣势: 语义表达、符号计算能力有限 ...

# 技术挑战

- 如何恰当地表示问题的语义
  - ▶ 丰富的提问方式, 复杂的提问意图 → 语义表示、语义分析
- 如何利用(大规模)(开放域)知识库元素来表示问题的语义
  - ▶ 大规模、开放域 → 知识库映射 → 实体链接、关系抽取
- 需要什么样的知识来解答问题?
  - ▶ 知识的多样化 → 知识融合
- 如何让模型真正可用?
  - ▶ 探索落地 → 可解释性、鲁棒性
- 传统方法的尽头?
  - ▶ 优势: 语义表示能力强
  - ▶ 瓶颈: 数据规模膨胀 → 任务规模激增、优质训练数据有限、对稀有类型/新类型束手无策
- 深度学习方法的春天?
  - ▶ 优势: 处理大规模知识及语料, 有效利用噪声数据
  - ▶ 劣势: 语义表达、符号计算能力有限 ...

# 技术挑战

- 如何恰当地表示问题的语义
  - ▶ 丰富的提问方式, 复杂的提问意图 → 语义表示、语义分析
- 如何利用(大规模)(开放域)知识库元素来表示问题的语义
  - ▶ 大规模、开放域 → 知识库映射 → 实体链接、关系抽取
- 需要什么样的知识来解答问题?
  - ▶ 知识的多样化 → 知识融合
- 如何让模型真正可用?
  - ▶ 探索落地 → 可解释性、鲁棒性
- 传统方法的尽头?
  - ▶ 优势: 语义表示能力强
  - ▶ 瓶颈: 数据规模膨胀 → 任务规模激增、优质训练数据有限、对稀有类型/新类型束手无策
- 深度学习方法的春天?
  - ▶ 优势: 处理大规模知识及语料, 有效利用噪声数据
  - ▶ 劣势: 语义表达、符号计算能力有限 ... → 扩大数据、模型规模? GPT-3那种?

# 本节内容

① 背景

② 传统解决方案

- 语义分析类方法
- 信息抽取类方法

③ 基于深度学习的解决方案

④ 新视角

⑤ 小结

# 语义分析类方法

## 语义分析 (SP)

Natural Language Question

Semantic Parser

Meaning Representation

Map with KB

Structured Query

Query over KB

Answer

(b)

- 语义表示
- Grounding with 知识库

# 语义分析

## 语义分析

### 利用形式化方法表示问题语义

- 一步到位
- 两步实现

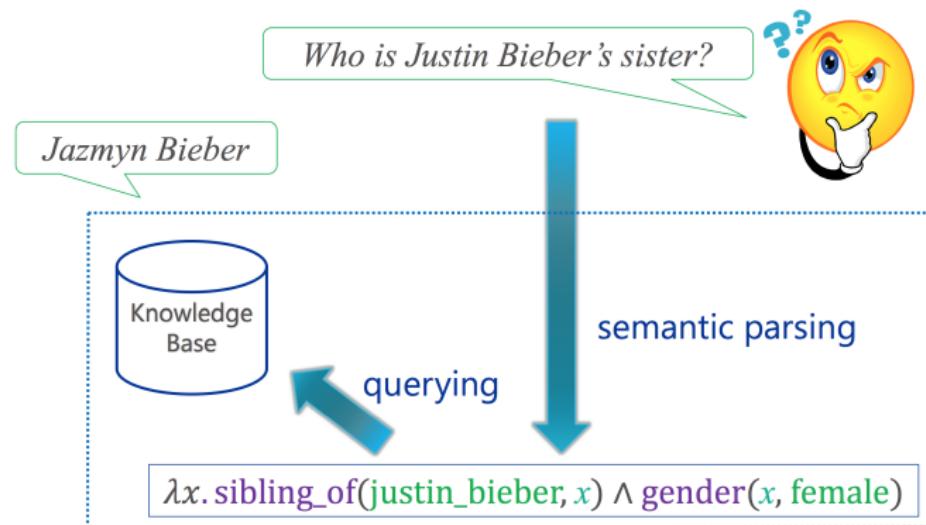
# 语义分析

## 语义分析

### 利用形式化方法表示问题语义

- 一步到位

- ▶ 直接获得与给定知识库相关的语义表示



[Kwiatkowski et al., 2013, Yih and Ma, 2016]

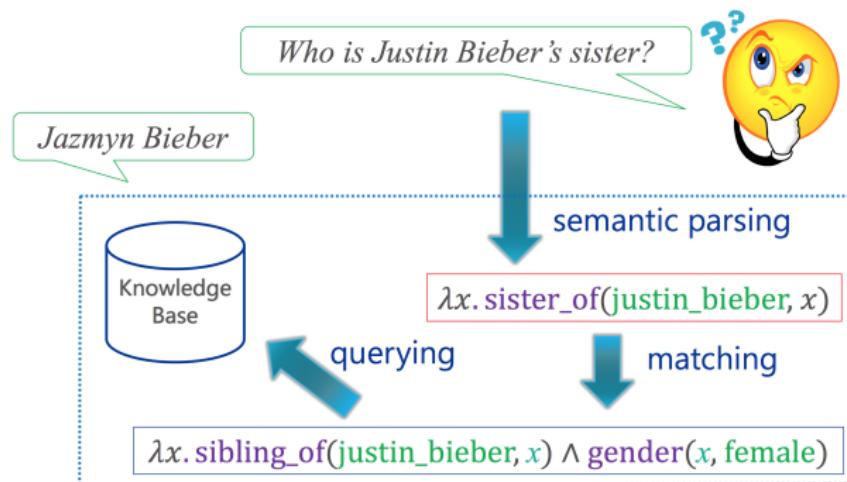
# 语义分析

## 语义分析

### 利用形式化方法表示问题语义

- 一步到位
- 两步实现

► 先通用语义表示，再与具体知识库映射



[Kwiatkowski et al., 2013, Yih and Ma, 2016]

# 语义分析

## 语义分析

### 利用形式化方法表示问题语义

- 一步到位
- 两步实现

## 语义表示

- $\lambda$ -Calculus:  $\lambda x. sibling\_of(justin\_bieber, x) \wedge gender(x, female)$
- Lambda Dependency-based Compositional Semantics ( $\lambda$ -DCS)  
*SisterOf.Justin\_Bieber*
- 借助现有句法、语法分析技术, 如 PCFG, CCG, Dependency structure, Phrase Dependency Graph, ...
- Query Graph
- ...

# 语义表示: $\lambda$ -Calculus

- constants
  - ▶ entities, numbers, functions
- logical connectors
  - ▶  $\vee, \wedge, \rightarrow, \neg$
- quantification
  - ▶  $\exists, \forall$
- additional quantifiers
  - ▶ argmax, argmin, ...

What states border Texas?

$\lambda x.state(x) \wedge borders(x, \text{texas})$

What is the largest state?

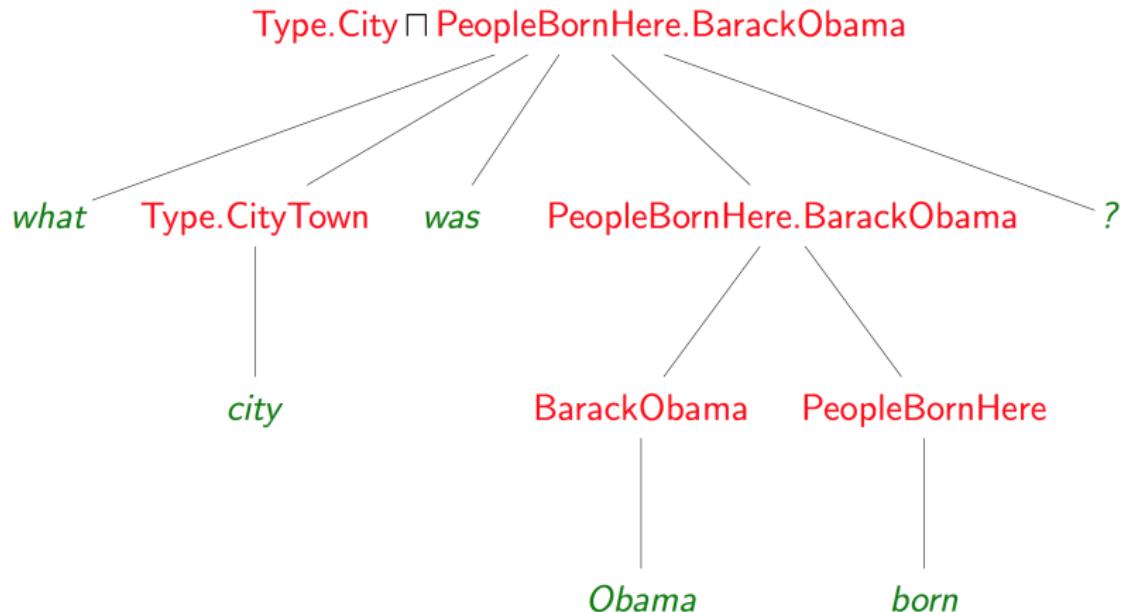
$\text{arg max}(\lambda x.state(x), \lambda x.size(x))$

- **variable:** *x*
- **function:** *state()*, *borders(, )*, *size()*
- **entity:** *texas*
- **quantifier:** *arg max*

# 语义表示: $\lambda$ -DCS

## Lambda Dependency-based Compositional Semantics [Liang, 2011]

- 更简洁、易用
- 组成: 实体、关系、Join/Intersection 操作

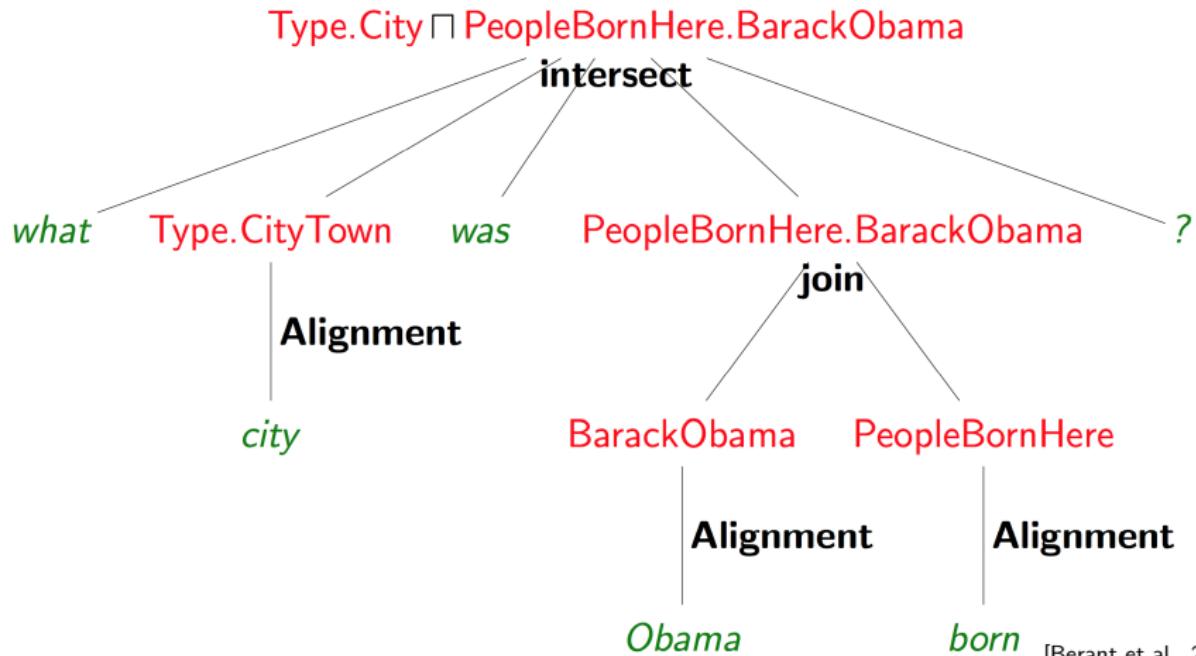


[Berant et al., 2013]

# 语义表示: $\lambda$ -DCS

## Lambda Dependency-based Compositional Semantics [Liang, 2011]

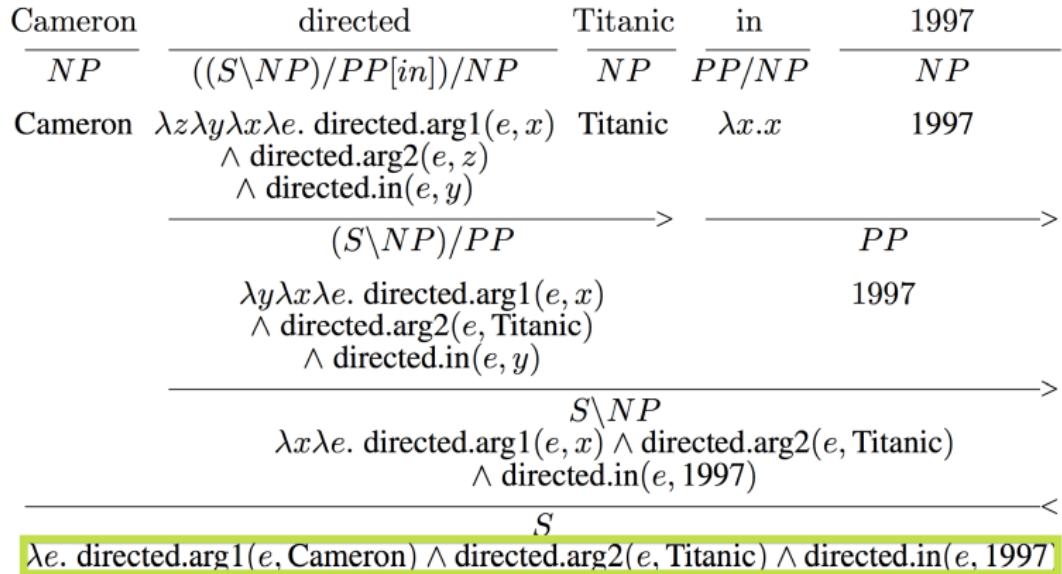
- 更简洁、易用
- 组成: 实体、关系、Join/Intersection 操作



# 语义表示: CCG

- 组合范畴语法 (Combinatory Categorial Grammar)

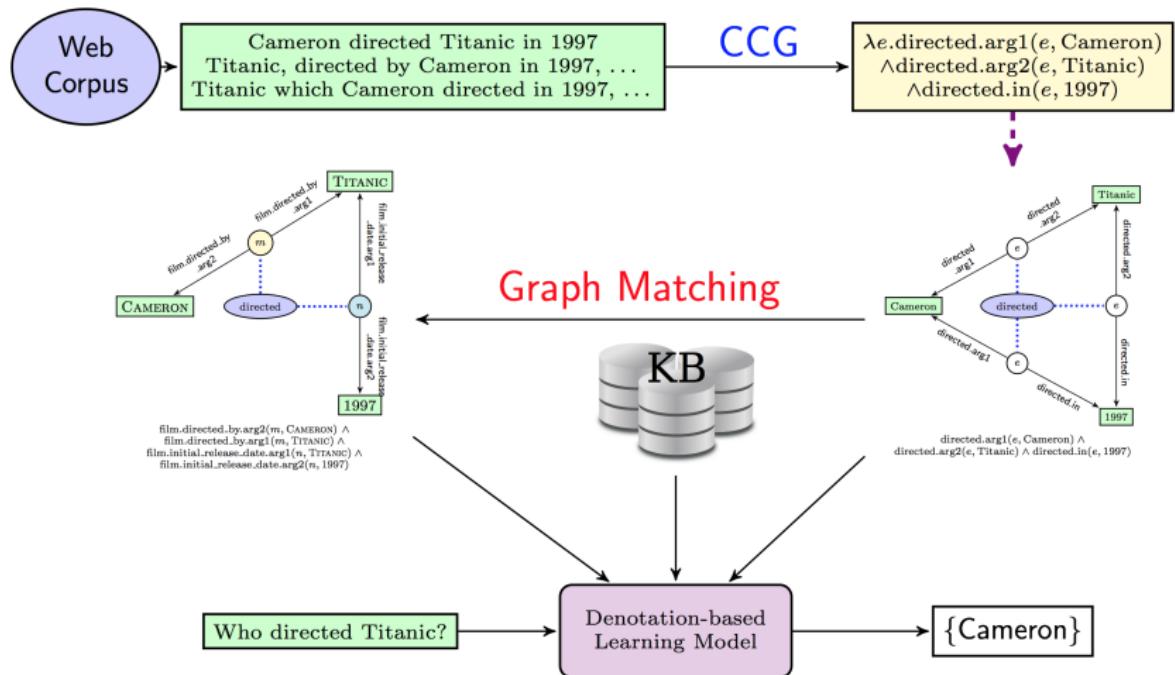
Cameron directed Titanic in 1997



[Reddy et al., 2015]

# 语义表示: CCG

- 组合范畴语法 (Combinatory Categorial Grammar)



# 语义表示: Simple Query Graph

注意: 绝大多数事实类问题只涉及实体的属性或关系

⇒ 疑问词、实体及关系组成的查询图

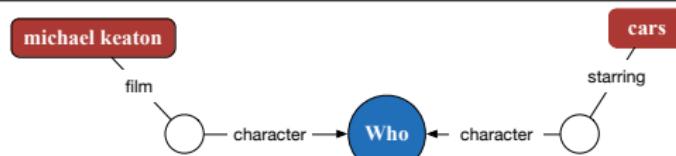
⇒ 实体与关系抽取联合优化

- Who does Michael Keaton play in Cars?

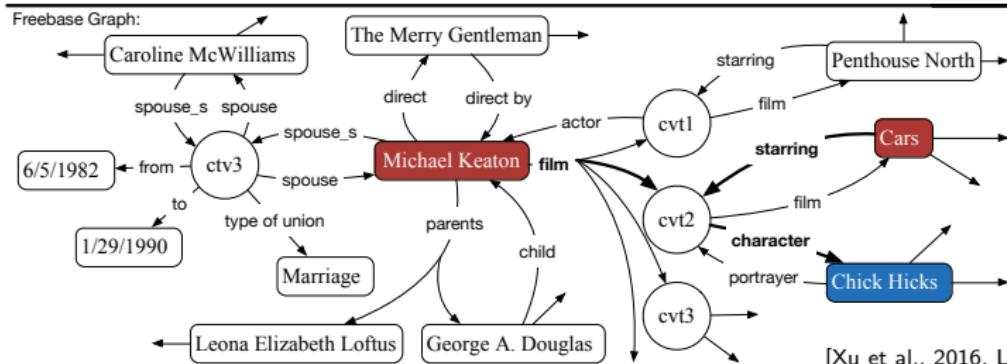
Question:

**Who does michael keaton play in cars**

Star Graph:



Freebase Graph:



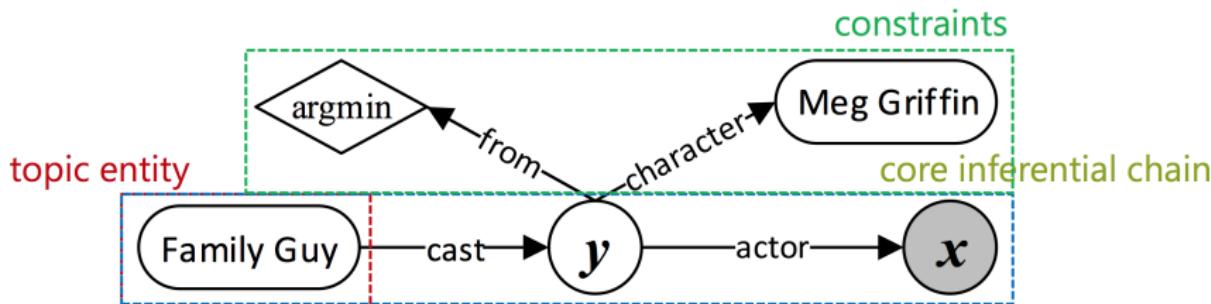
[Xu et al., 2016, Lai et al., 2014]

# 语义表示: Query Graph

- 借助于知识图谱中的子图结构以及实体链接

Who first voiced Meg on Family Guy?  $\Rightarrow$

$$\lambda x. \exists y. cast(FamilyGuy, y) \vee actor(y, x) \vee character(y, MegGriffin)$$



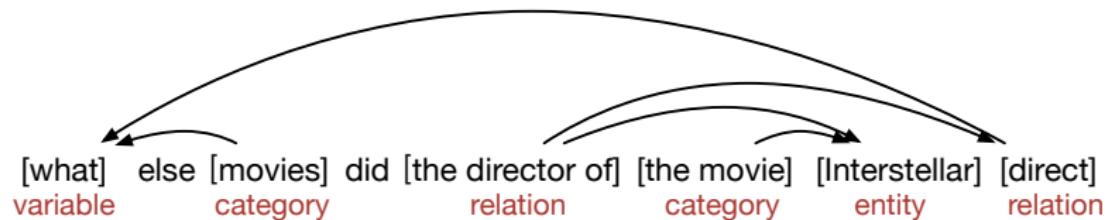
- 直接有效: 疑问词、实体、关系及额外限制节点组成的查询图

[Yih et al., 2015]

# 语义表示: Phrase Dependency Graph

在两步语义表示方法中

- ① 独立于某个具体知识库的语义结构表示

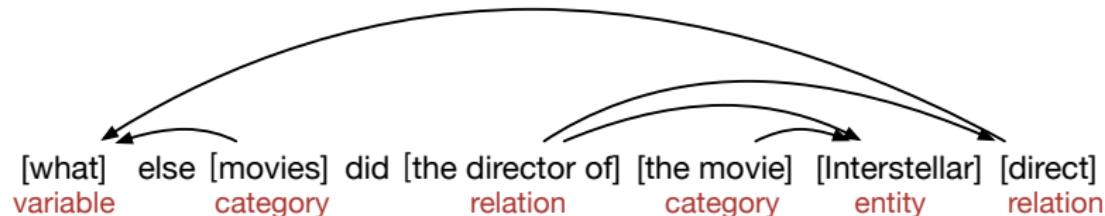


[Xu et al., 2014]

# 语义表示: Phrase Dependency Graph

在两步语义表示方法中

- ① 独立于某个具体知识库的语义结构表示



- ② 灵活映射到具体的知识库中



```
select ?y
[ fb:m.0fkf28      fb:object.type      fb:film.film
  fb:m.0fkf28      fb:film.film.directed_by    ?x
                ?x          fb:film.director.film    ?y
                ?y          fb:object.type      fb:film.film ]
```



```
select ?y
[ ns:Interstellar      dbo:type      dbo:film
  ns:Interstellar      dbo:director    ?x
                ?x          dbo:director    ?x
                ?x          dbo:type      dbo:film ]
```

[Xu et al., 2014]

例如

What else movies did the director of the movie Interstellar direct ?

例如

What else movies did the director of the movie Interstellar direct ?

① 短语检测 及与具体知识库无关的短语分类

Variable (V), Category (C), Entity (E) and Relation (R)

例如

What else movies did the director of the movie Interstellar direct ?

① 短语检测 及与具体知识库无关的短语分类

Variable (V), Category (C), Entity (E) and Relation (R)

[what] else [movies] did [the director of] [the movie] [Interstellar] [direct]

V-B	C-B	R-B	R-I	R-I	C-B	C-I	E-B	R-B
variable	category	relation	category	entity	relation			

例如

What else movies did the director of the movie Interstellar direct ?

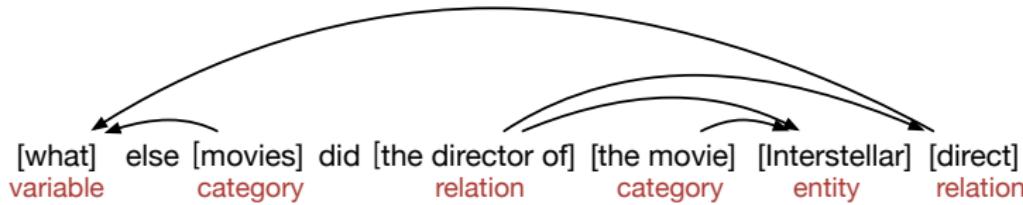
① 短语检测 及与具体知识库无关的短语分类

Variable (V), Category (C), Entity (E) and Relation (R)

[what] else [movies] did [the director of] [the movie] [Interstellar] [direct]

V-B	C-B	R-B	R-I	R-I	C-B	C-I	E-B	R-B
variable	category	relation	category	entity	entity	relation		

② 短语依存图解析



实体短语 – 关系短语, 实体短语 – 类别短语, 关系短语 – 关系短语

例如

What else movies did the director of the movie Interstellar direct ?

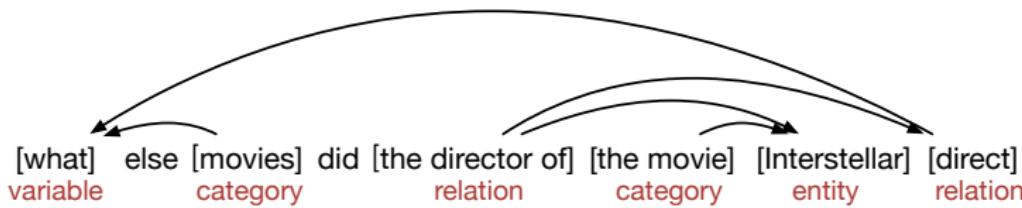
① 短语检测 及与具体知识库无关的短语分类

Variable (V), Category (C), Entity (E) and Relation (R)

[what] else [movies] did [the director of] [the movie] [Interstellar] [direct]

V-B	C-B	R-B	R-I	R-I	C-B	C-I	E-B	R-B
variable	category	relation	category	entity	entity	relation		

② 短语依存图解析

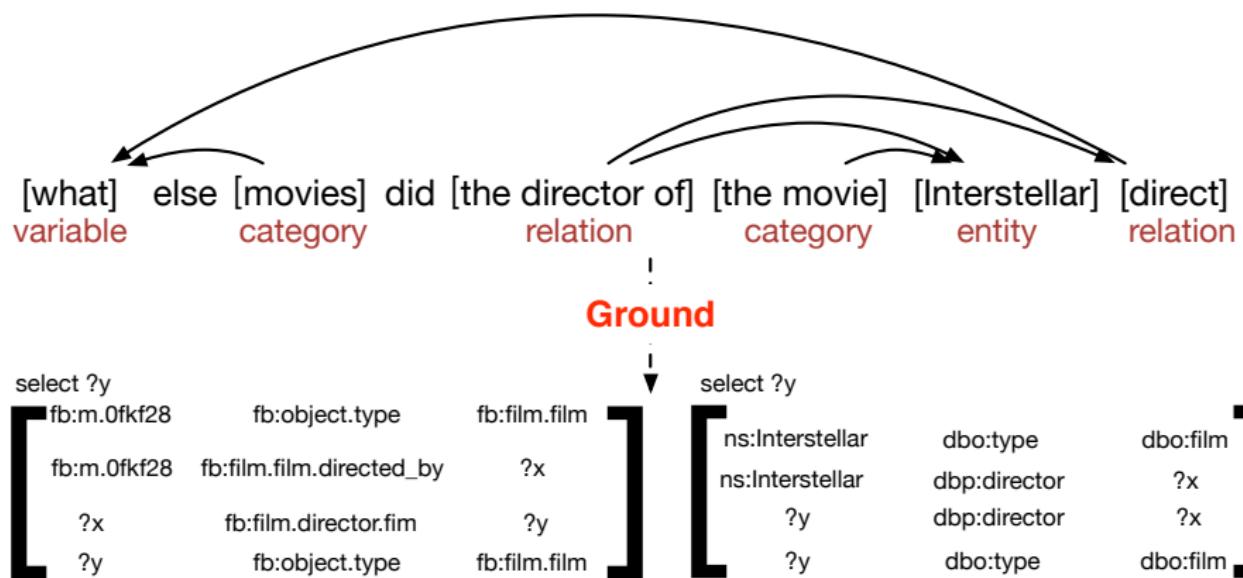


实体短语 – 关系短语, 实体短语 – 类别短语, 关系短语 – 关系短语

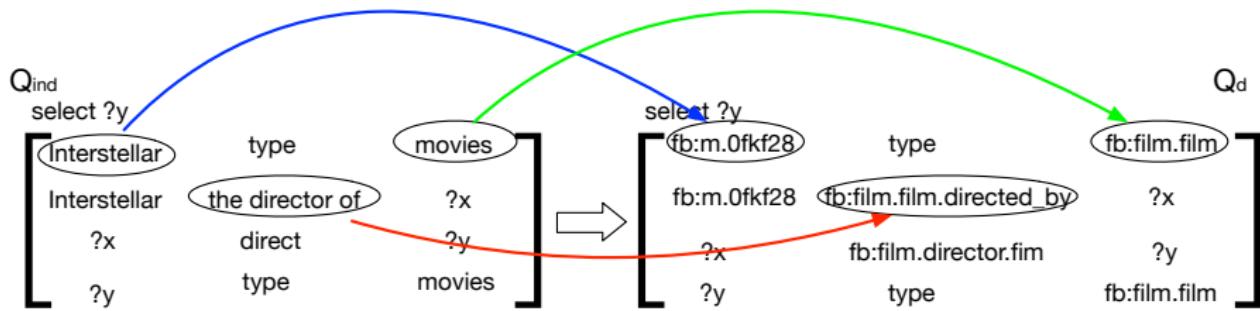
结构感知机足已!

# 短语依存图与知识库映射

Grounding: 从短语依存图 (PDG) 到可执行的结构化查询



# 与知识库的Grounding



- 面向知识库的**实体链接**
- 面向知识库的**概念匹配**
- 面向知识库的**关系抽取**

## 实体链接

### 实体链接

- 核心实体 (topic entity) 决定成败
- 费城 ⇒ 费城 (城市), 费城 (电影), 费城 (街道), ...
- 缺乏足够上下文, 命名实体边界模糊
- 充分利用现有资源 (Heng Ji's EDL reading list)

## 实体链接, 关系抽取

### 实体链接

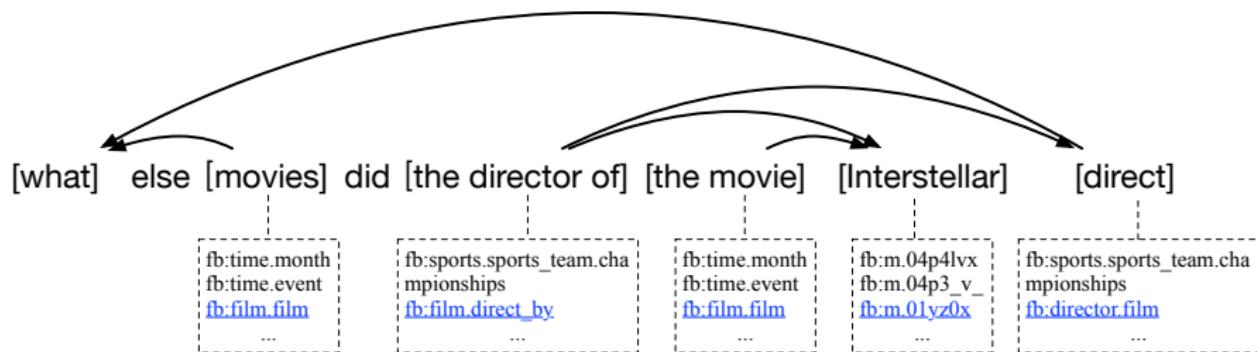
- 核心实体 (topic entity) 决定成败
- 费城 ⇒ 费城 (城市), 费城 (电影), 费城 (街道), ...
- 缺乏足够上下文, 命名实体边界模糊
- 充分利用现有资源 (Heng Ji's EDL reading list)

### 关系抽取/匹配

- 上下文有限, 表达方式灵活多样, 与知识库表述不匹配, 候选关系众多, 错误传递, ...
- 复杂关系, 如N-ary关系, 事件, 或者 Freebase中的CVT节点
- 多管齐下: **关系抽取, 通过实体/类别猜测, 联合消解, ...**

# Grounding

- 各元素与知识库的映射是独立进行的
- 最终结果仍可能存在错误累积



- 寻找全局最优解  $\Rightarrow$  (搜索空间过大 !)
- 经验性寻找局部最优解  $\Rightarrow$  (如, 基于全流程特征的Reranking)

[Xu et al., 2016a]

# 本节内容

① 背景

② 传统解决方案

- 语义分析类方法
- 信息抽取类方法

③ 基于深度学习的解决方案

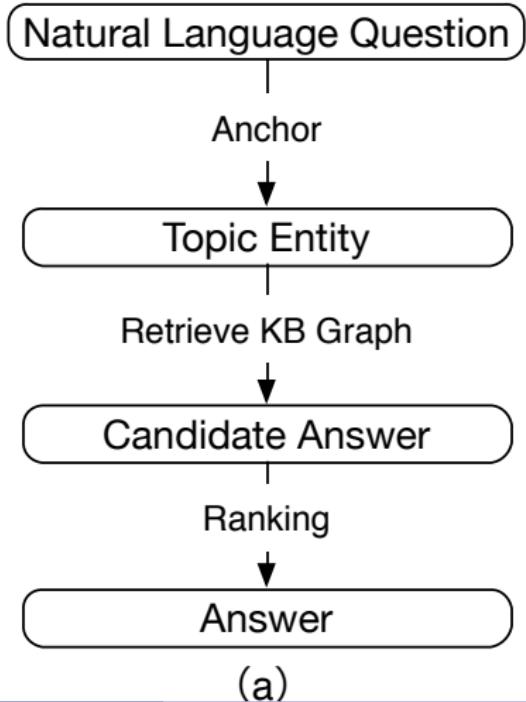
④ 新视角

⑤ 小结

# A Tale of Two Streams

信息抽取 (IE)

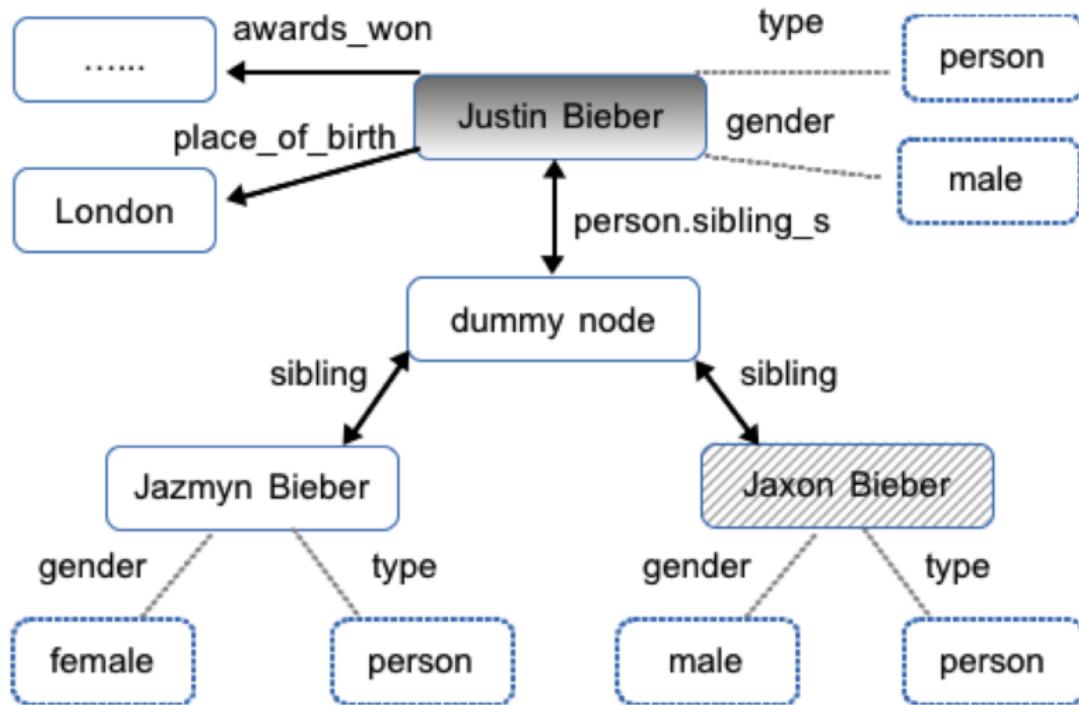
- 确定中心实体（搜索范围）
- 匹配, 筛选, 排序, .....



(a)

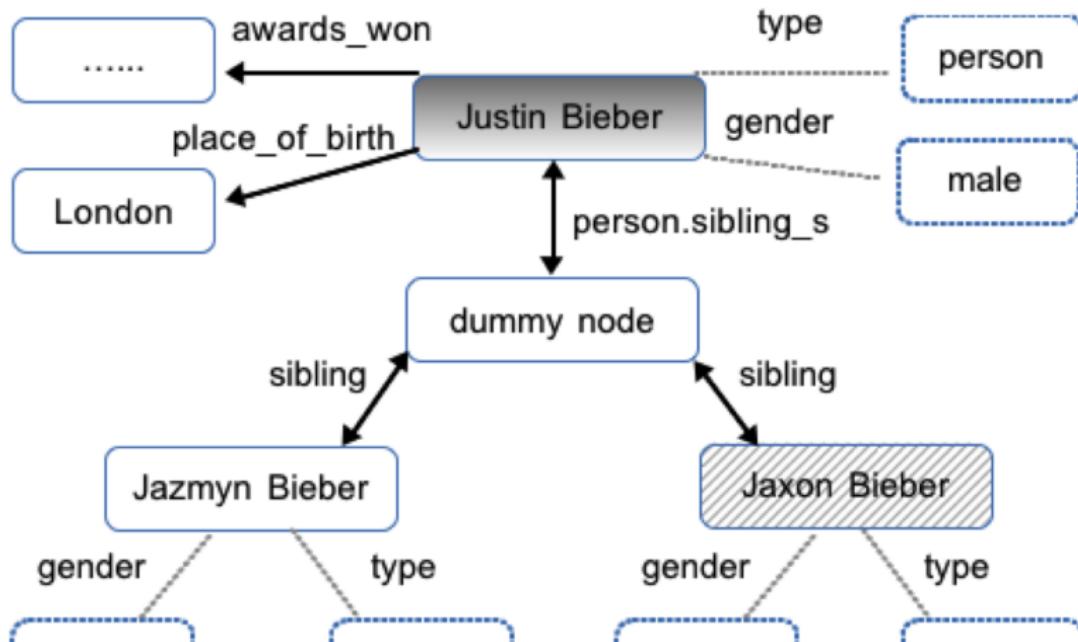
who is the brother of Justin Bieber?

[Yao et al., 2014]

who is the brother of **Justin Bieber**?

who is the brother of **Justin Bieber**?

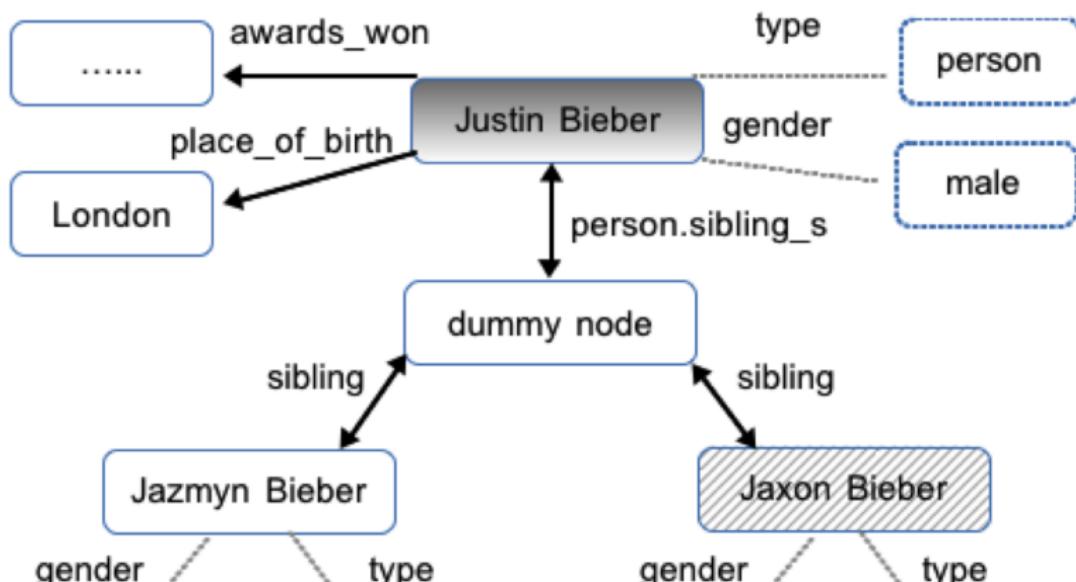
## Freebase Topic Graph



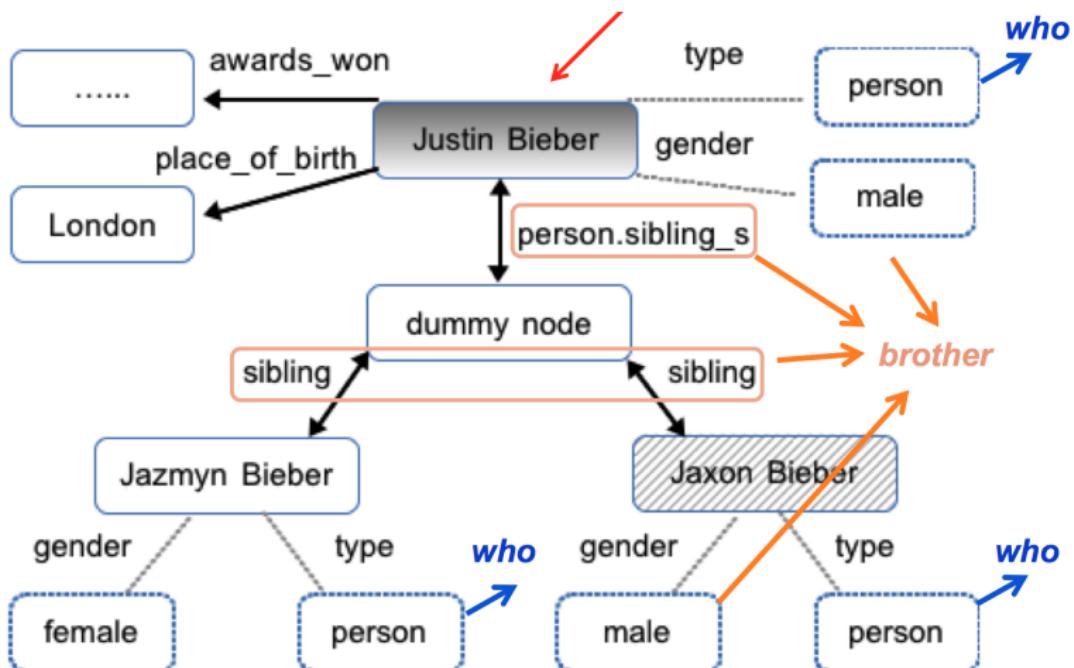
who is the brother of **Justin Bieber**?

## Freebase Topic Graph

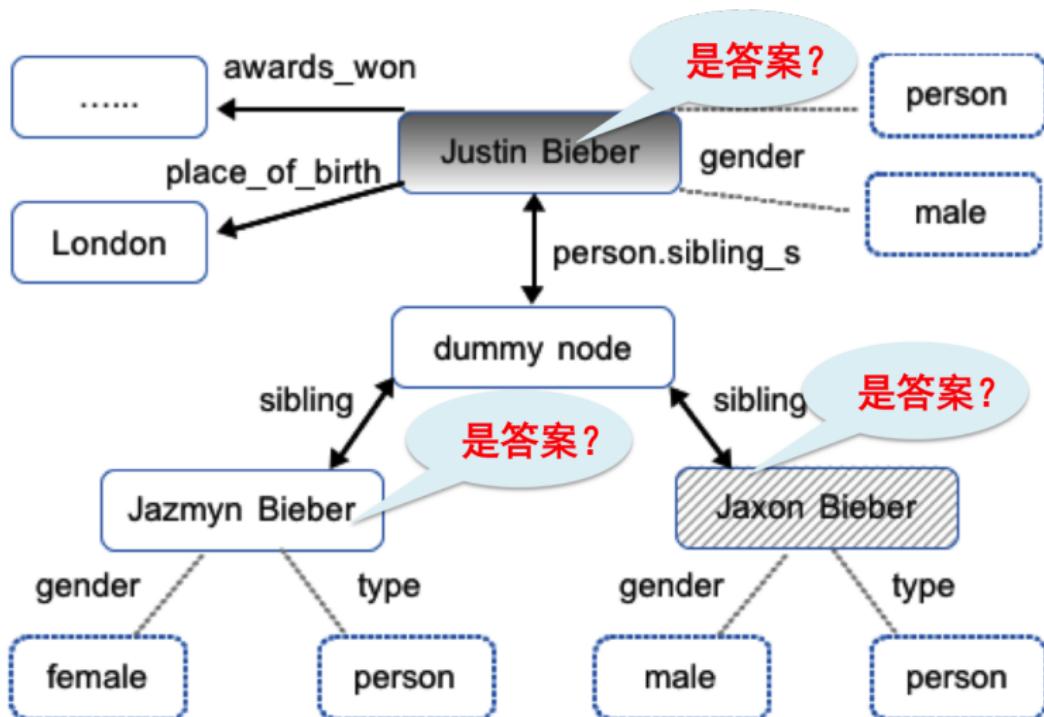
答案就在这里！



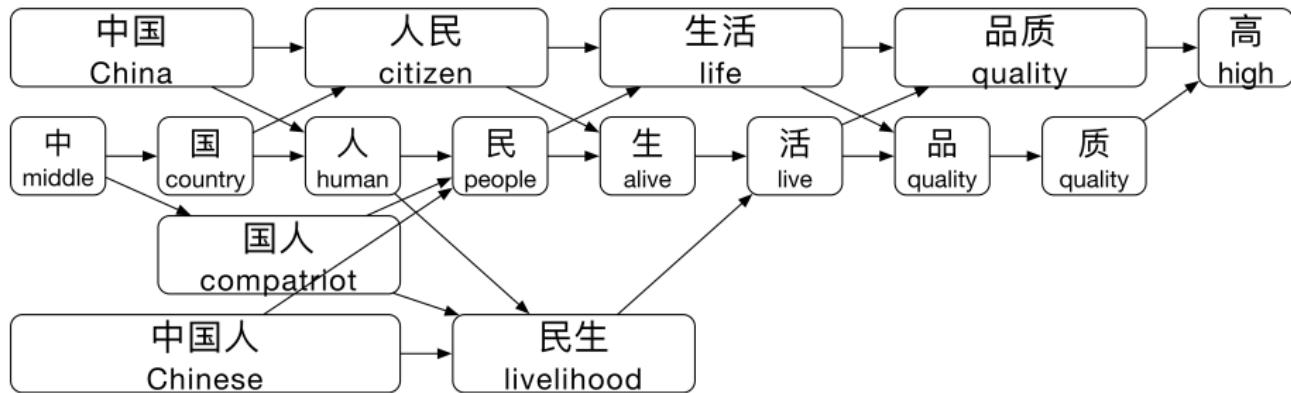
# who is the brother of **Justin Bieber**?



[Yao et al., 2014]

who is the brother of **Justin Bieber**?

# 处理中文时

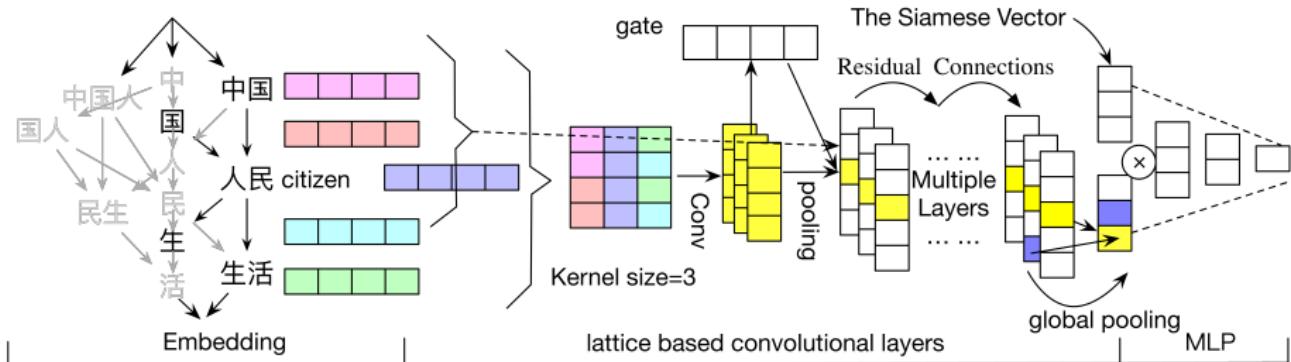


## Matching

- 错误传递 (分词、命名实体识别)
- 同义但存在表述差异
- 不同长度

[Lai et al., 2019]

# 处理中文时



## Matching

- 词格 (lattice of characters)
- 同时在不同尺度上考虑
- 考虑不连续的匹配

[Lai et al., 2019]

# 优势与劣势

## 优势

- 框架灵活、实用
- 易于融合多种线索
- 容易与其他方法/框架结合
- 适用多种类型资源

## 劣势

- 依赖特征工程
- 易受错误传递影响
- 不擅长处理语义组合
- 难以处理推理问题

# 本节内容

① 背景

② 传统解决方案

③ 基于深度学习的解决方案

- 背景

- 对现有模块的改进
- Neural End-to-End 框架

④ 新视角

⑤ 小结

# 将深度学习方法应用于知识问答

## 改善现有模块

- 关系抽取

- ▶ 语义分析类方法为主
- ▶ [Yih et al., 2015], [Xu et al., 2016a, 2016b], [Zhang et al., 2015], [Yu et al., 2017], ...

- 候选评分

- ▶ 信息抽取类方法为主
- ▶ [Yih et al., 2014], [Dong et al., 2015], [Hao et al., 2017], ...

## Neural End-to-End 框架

- 多数遵循**信息抽取类**框架
- Embedding Everything
  - ▶ [Bordes et al., 2015], [Hao et al., 2017], ...
- Memory Networks
  - ▶ [Bordes et al., 2015], [Miller et al., 2016], [Xu et al., 2019] ...
- Graph Networks
  - ▶ [Sun et al., 2018], ...
- **语义分析类**框架
  - ▶ [Liang et al., 2017], [Xu et al., 2019], [Hua et al., 2020]...

# 将深度学习方法应用于知识问答

## 改善现有模块

- **关系抽取**

- ▶ 语义分析类方法为主
- ▶ [Yih et al., 2015], [Xu et al., 2016a, 2016b], [Zhang et al., 2015], [Yu et al., 2017], ...

- **候选评分**

- ▶ 信息抽取类方法为主
- ▶ [Yih et al., 2014], [Dong et al., 2015], [Hao et al., 2017], ...

## Neural End-to-End 框架

- 多数遵循**信息抽取类**框架
- **Embedding Everything**
  - ▶ [Bordes et al., 2015], [Hao et al., 2017], ...
- **Memory Networks**
  - ▶ [Bordes et al., 2015], [Miller et al., 2016], [Xu et al., 2019] ...
- **Graph Networks**
  - ▶ [Sun et al., 2018], ...
- **语义分析类**框架
  - ▶ [Liang et al., 2017], [Xu et al., 2019], [Hua et al., 2020] ...
- **新应用**

# 本节内容

① 背景

② 传统解决方案

③ 基于深度学习的解决方案

- 背景
- 对现有模块的改进
- Neural End-to-End 框架

④ 新视角

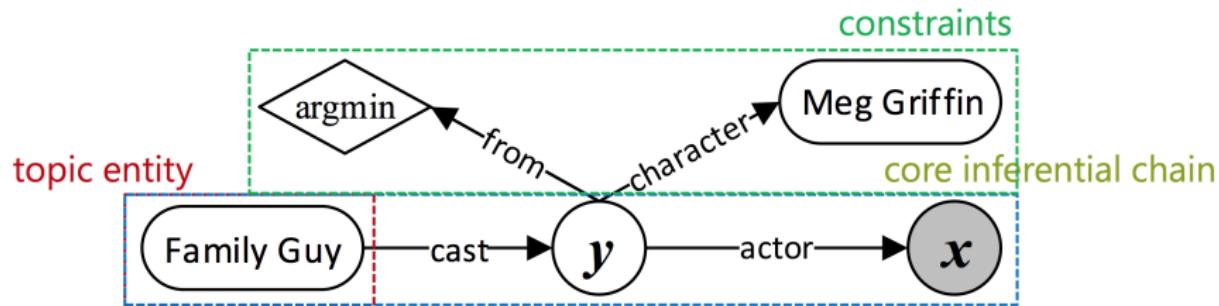
⑤ 小结

# STAGG: Staged Query Graph Generation

通过搜索，逐步构建查询图 (Query Graph)

Who first voiced Meg on Family Guy?  $\Rightarrow$

$\lambda x. \exists y. cast(FamilyGuy, y) \vee actor(y, x) \vee character(y, MegGriffin)$



- Query Graph 介于与知识库无关的语义表示与结构化查询 (SPARQL, SQL, ...) 之间
- 深度学习方法帮助提高关系识别
- 联合优化

[Yih et al., 2015]

## Linking Topic Entity

Who first voiced **Meg** on **Family Guy** ?

# Linking Topic Entity

Who first voiced Meg on Family Guy ?

- 使用高可靠性的实体链接工具  
[Yang and Chang, 2015] S-MART: Novel Tree-based Structured Learning Algorithms Applied to Tweet Entity Linking, ACL 2015
- 保留 Top 10 作为后续模块的候选输入
  - ▶ Family Guy
  - ▶ Meg Griffin
  - ▶ ...

# Identifying Core Inferential Chain

Who first voiced Meg on Family Guy ?

Who/x ←———— Family Guy

{cast-actor, cast-character, writer-start, genre, ...}

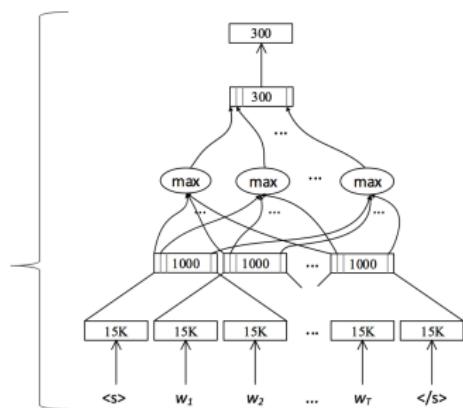
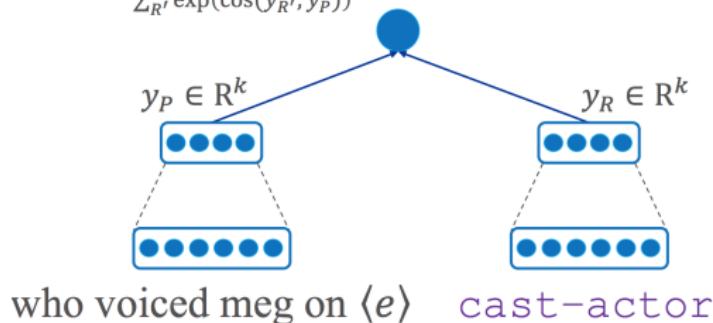
# Identifying Core Inferential Chain

Who first voiced Meg on Family Guy ?

Who/x ← Family Guy

- 基于卷积神经网络(CNN)的关系抽取  
Deep Convolutional Neural Networks [Shen et al., 2014]

$$P(R|P) = \frac{\exp(\cos(y_R, y_P))}{\sum_{R'} \exp(\cos(y_{R'}, y_P))}$$

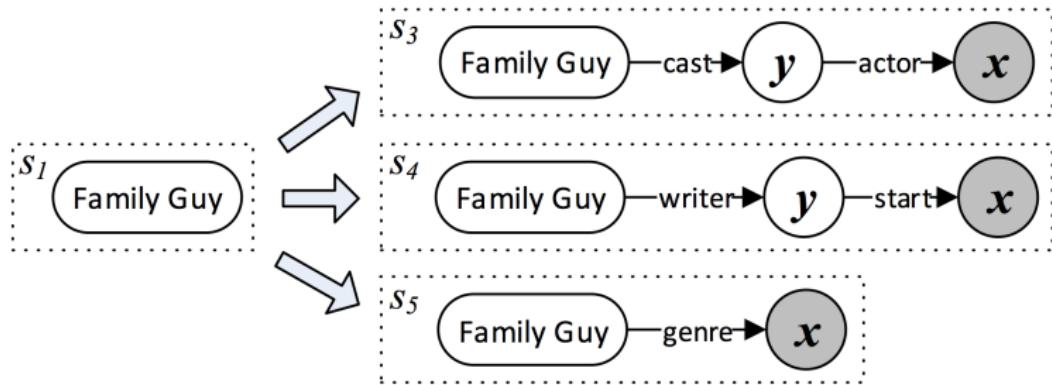


# Identifying Core Inferential Chain

Who first voiced Meg on Family Guy ?

Who/x ←———— Family Guy

- 基于卷积神经网络(CNN)的关系抽取  
Deep Convolutional Neural Networks [Shen et al., 2014]
- 考虑两种可能的候选关系
  - ▶ Topic Entity周围一步的邻居 ( $y$ 非CVT类型)
  - ▶ Topic Entity周围两步的邻居 ( $y$ 为CVT类型)



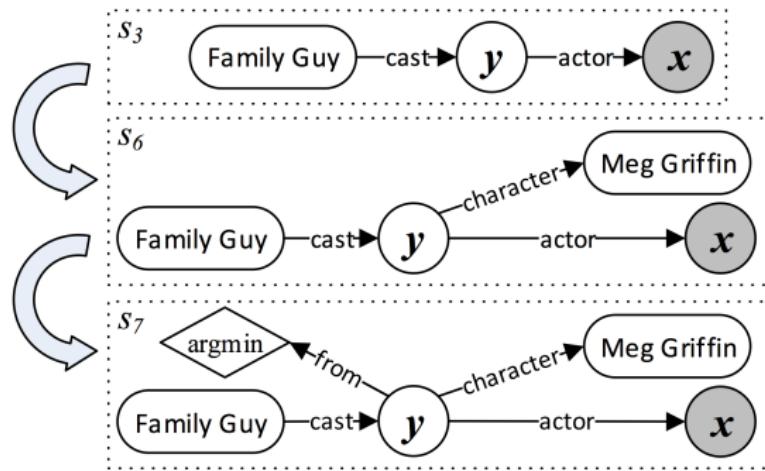
## Argument Constraints

Who first voiced Meg on **Family Guy** ?

# Argument Constraints

## Who first voiced Meg on Family Guy ?

- 逐步加入限制节点
  - 加入 **Meg**,  $\Rightarrow \text{character}(y, \text{MegGriffin})$
  - 加入 **first**,  $\Rightarrow \arg \min$
- 限制节点候选: 实体, 约束性关键词
  - 依赖规则产生限制节点



- 以排序为目标
  - ▶ Log Linear Model
  - ▶ 正确的Query Graph 得分更高
  - ▶ 可利用中间步骤获得大量训练数据
- 汇总全流程的各种特征、中间得分
  - ▶ 实体链接得分
  - ▶ 关系抽取得分
  - ▶ 约束类关键词匹配得分
  - ▶ ...

- 以排序为目标
  - ▶ Log Linear Model
  - ▶ 正确的Query Graph 得分更高
  - ▶ 可利用中间步骤获得大量训练数据
- 汇总全流程的各种特征、中间得分
  - ▶ 实体链接得分
  - ▶ **关系抽取**得分
  - ▶ 约束类关键词匹配得分
  - ▶ ...

提高关系抽取性能

# 知识问答中的关系抽取

## 挑战

- 大规模知识库中通常包含上万种关系
- 通常只能收集到噪声训练数据

# 关系抽取

Who first voiced Meg on Family Guy ?

Who/x ← cast-actor Family Guy

## 任务定义

给定句子  $S$ , 及一对名词或名词短语 (如, 命名实体等)  $e_1$  和  $e_2$ , 该任务目标是确定  $e_1$  和  $e_2$  存在何种类型的语义关系.

# 关系抽取

Who first voiced Meg on Family Guy ?

Who/x ← cast-actor      Family Guy

## 任务定义

给定句子  $S$ , 及一对名词或名词短语 (如, 命名实体等)  $e_1$  和  $e_2$ , 该任务目标是确定  $e_1$  和  $e_2$  存在何种类型的语义关系.

- 传统方法依赖特征工程抽取特征
  - ▶ 词法特征, 如, POS, WordNet, FrameNet 特征等
  - ▶ 句法特征, 如句法结构特征等
  - ▶ 分类器, 优化, .....

# 关系抽取



## 任务定义

给定句子  $S$ , 及一对名词或名词短语 (如, 命名实体等)  $e_1$  和  $e_2$ , 该任务目标是确定  $e_1$  和  $e_2$  存在何种类型的语义关系.

- 传统方法依赖特征工程抽取特征
  - ▶ 词法特征, 如, POS, WordNet, FrameNet特征等
  - ▶ 句法特征, 如句法结构特征等
  - ▶ 分类器, 优化, .....
- 深度学习方法则希望摆脱特征工程
  - ▶ 各种神经网络结构 (CNN, RNN, ...)
  - ▶ 利用词向量及网络结构刻画词法特征和句子级特征

# 神经网络模型

- 卷积神经网络模型 [Zeng et al., 2014], [Xu et al., 2015a], ...
- 递归神经网络模型 [Socher et al., 2012]
- 循环神经网络模型 [Xu et al., 2015b], ...
- 依存结构 [Liu et al., 2015], [Xu et al., 2015a] [Xu et al., 2015b], ...
- Ranking CNN [dos Santos et al., 2015]
- 负样本采样机制 [Xu et al., 2015a]
- 层次化残差网络 [Yu et al., 2017]

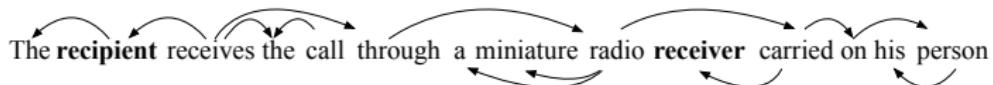
# 利用依存结构

The **recipient** receives the call through a miniature radio **receiver** carried on his person

receiver	Instrument-Agency	<b>recipient</b>	receiver ← carried → radio ← through ← receives → recipient
----------	-------------------	------------------	---

# 利用依存结构

The **recipient** receives the call through a miniature radio **receiver** carried on his person



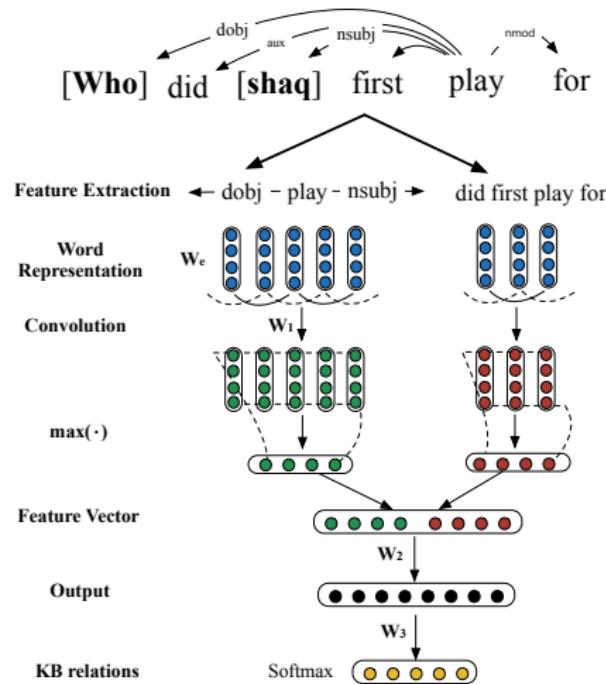
receiver	Instrument-Agency	recipient	recipient ← carried → radio ← through ← receives → recipient
----------	-------------------	-----------	--

两个名词短语在依存结构上的最短路径

- 提供丰富的语义信息
- 可减轻复杂句法结构带来的困扰
- 具有很好的抗噪声性能

# Multi-Channel Convolutional Neural Networks

利用 multi-channel convolutional neural networks (MCCNNs) 同时从词串本身和依存结构上的最短路径中学习鲁棒的关系表达 [Xu et al., 2015]



关系识别准确率:

- Naive Bayes Model: 30.2%
- depLCNN: 45.9%

关系识别准确率:

- Naive Bayes Model: 30.2%
- depLCNN: 45.9% 显著提高!

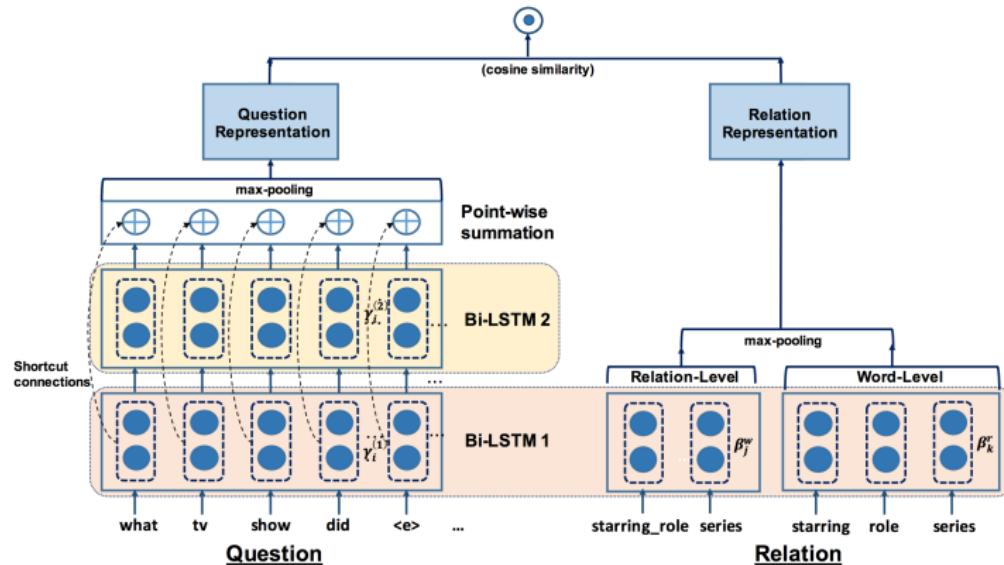
关系识别准确率:

- Naive Bayes Model: 30.2%
- depLCNN: 45.9% 显著提高!
- 与实体类别等多种线索结合后可大幅度提高问句语义表示精度

# 简单问题

针对简单问题的关系表述与知识库谓词的语义匹配/关系检测:

- 82.53% on WebQuestionsSP
- 93.3% on SimpleQuestions



[Yu et al., 2017]

# 来自DL的改进

## 已有的工作

- 关系识别/抽取
- 多来源特征的候选评分
- ...

# 来自DL的改进

## 已有的工作

- 关系识别/抽取
- 多来源特征的候选评分
- ...

但是，

- DL的应用仍是对子模块的改进
- 大多仍以语义分析框架为核心
- 少部分改进在信息抽取框架

# 来自DL的改进

## 已有的工作

- 关系识别/抽取
- 多来源特征的候选评分
- ...

但是，

- DL的应用仍是对子模块的改进
- 大多仍以语义分析框架为核心
- 少部分改进在信息抽取框架

Anything New ?

# 本节内容

① 背景

② 传统解决方案

③ 基于深度学习的解决方案

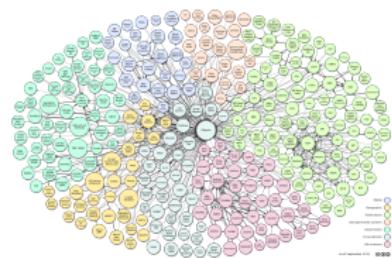
- 背景
- 对现有模块的改进
- Neural End-to-End 框架

④ 新视角

⑤ 小结

# End-to-End

Who first voiced Meg  
on Family Guy?



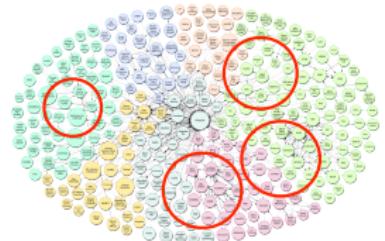
# End-to-End

Who first voiced Meg  
on Family Guy?

↓ Embedding

← Matching →

1	0	...			1
---	---	-----	--	--	---



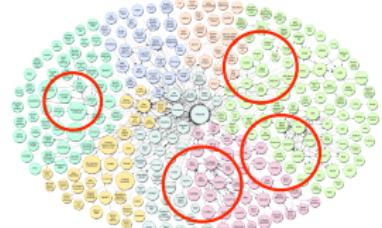
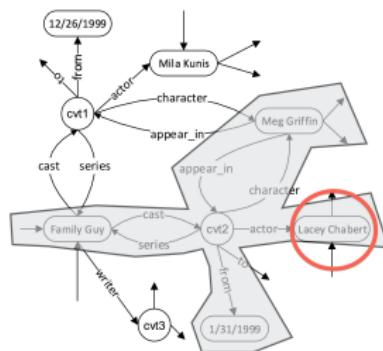
# End-to-End

Who first voiced Meg  
on Family Guy?

↓ Embedding

1	0	...			1
---	---	-----	--	--	---

## Lacey Chabert



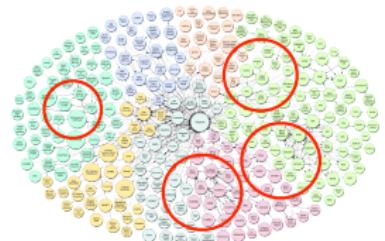
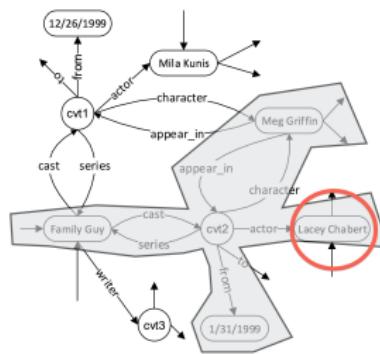
# End-to-End

Who first voiced Meg on Family Guy?

↓ Embedding

1 0 ... | | | 1

## Lacey Chabert



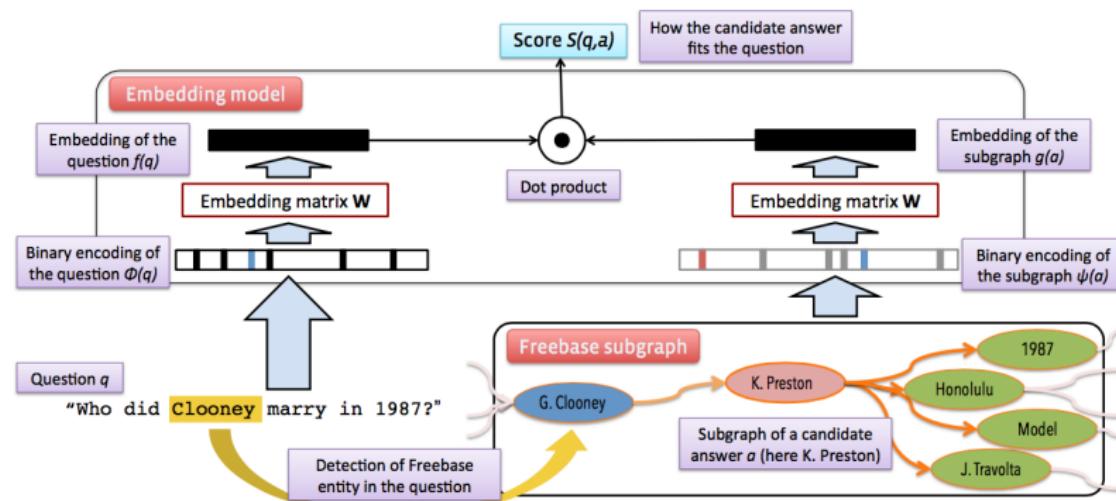
主要基于信息抽取类框架

# Simple Matching

- 只处理单关系的简单问句
- 典型的信息抽取框架
  - ① 候选生成: Topic Entity 一跳范围内
  - ② 排序选择最优
  - ③ 多任务优化: 文本复述

# Simple Matching

- 只处理单关系的简单问句
- 典型的信息抽取框架
  - 候选生成: Topic Entity 一跳范围内
  - 排序选择最优
  - 多任务优化: 文本复述
  - 候选答案的上下文
  - 候选答案到Topic Entity的上下文

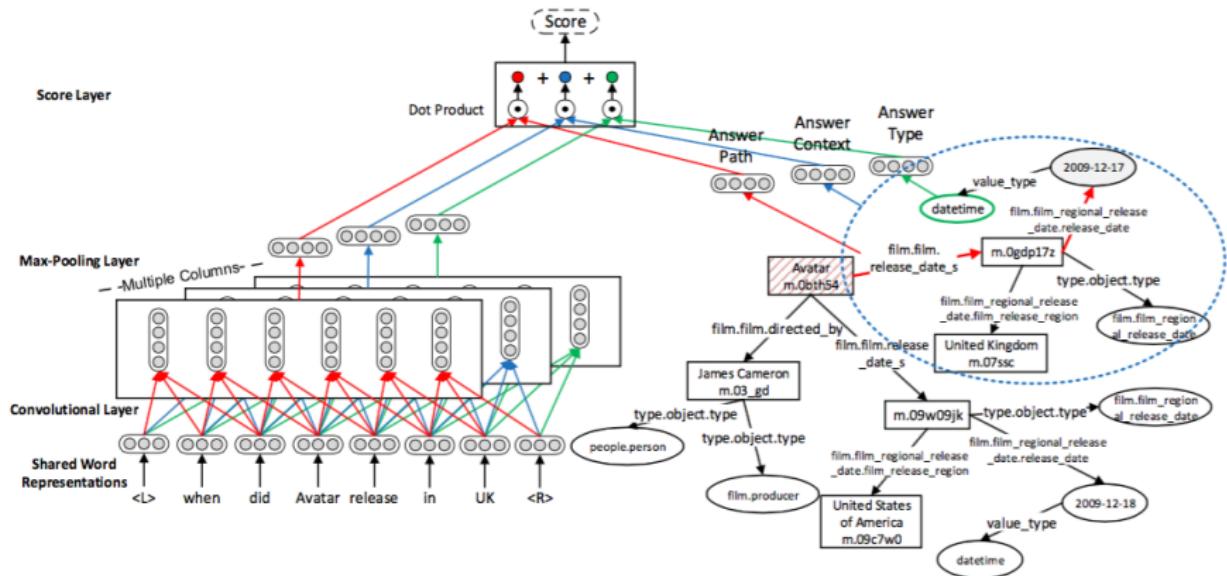


# Multi-Column CNNs

- 典型的信息抽取框架
- 利用 Multi-Column CNNs 抽象问题的不同侧面
  - ▶ Type, Context, Relation
- 利用知识库从不同侧面刻画候选答案
  - ▶ Type, Context, Path

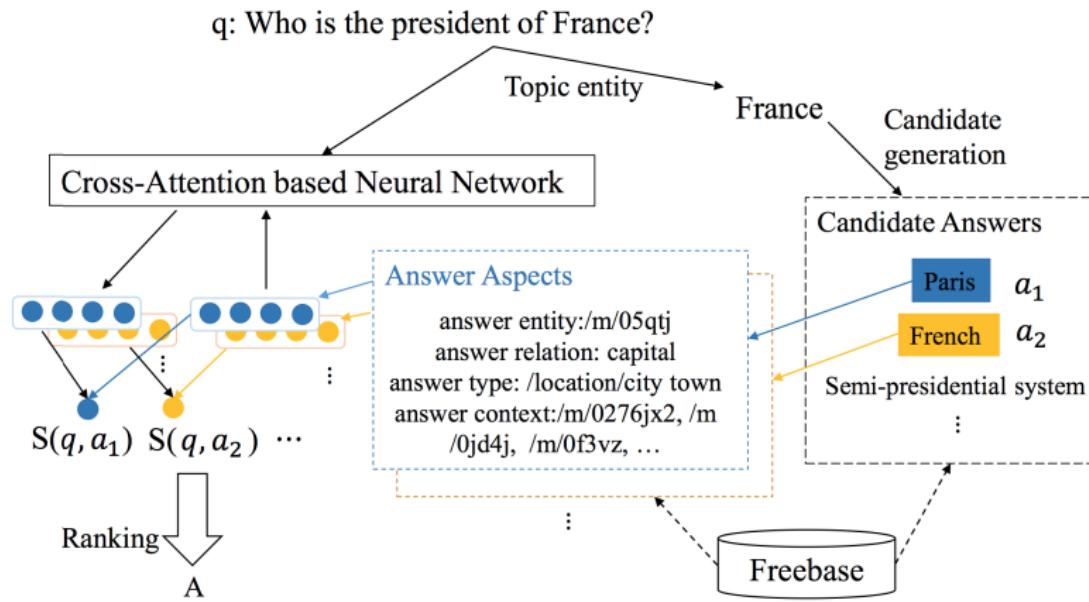
# Multi-Column CNNs

- 典型的信息抽取框架
- 利用 Multi-Column CNNs 抽象问题的不同侧面
  - ▶ Type, Context, Relation
- 利用知识库从不同侧面刻画候选答案
  - ▶ Type, Context, Path



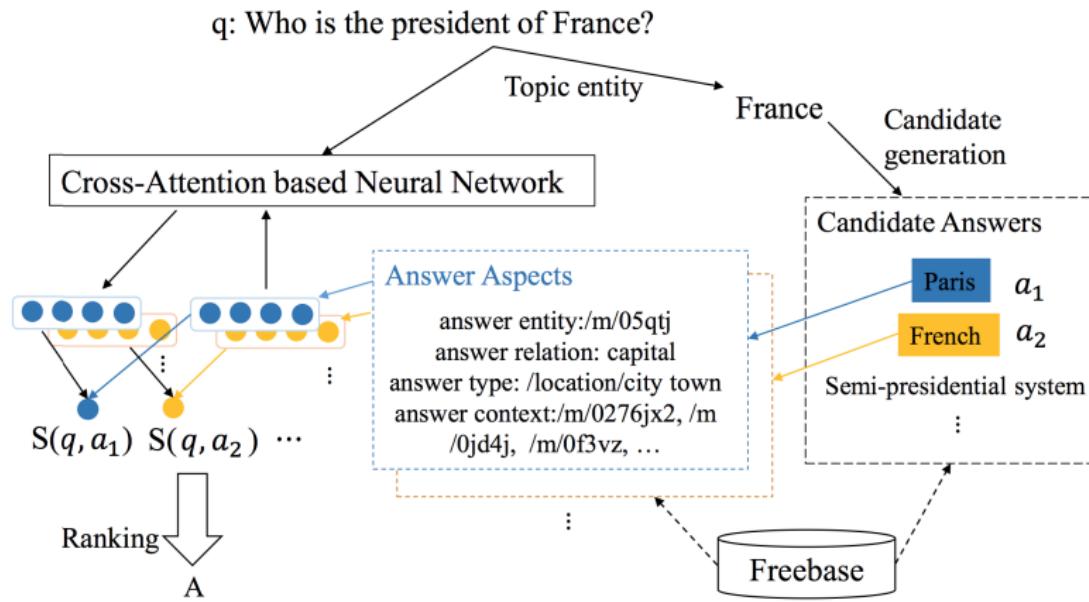
# Attention + Global Knowledge

- 问句语义表示过于简单
- 对实体名称等的训练数据不足
  - ▶ Cross-Attention 刻画问句表述与答案之间关联
  - ▶ 多任务学习: TransE



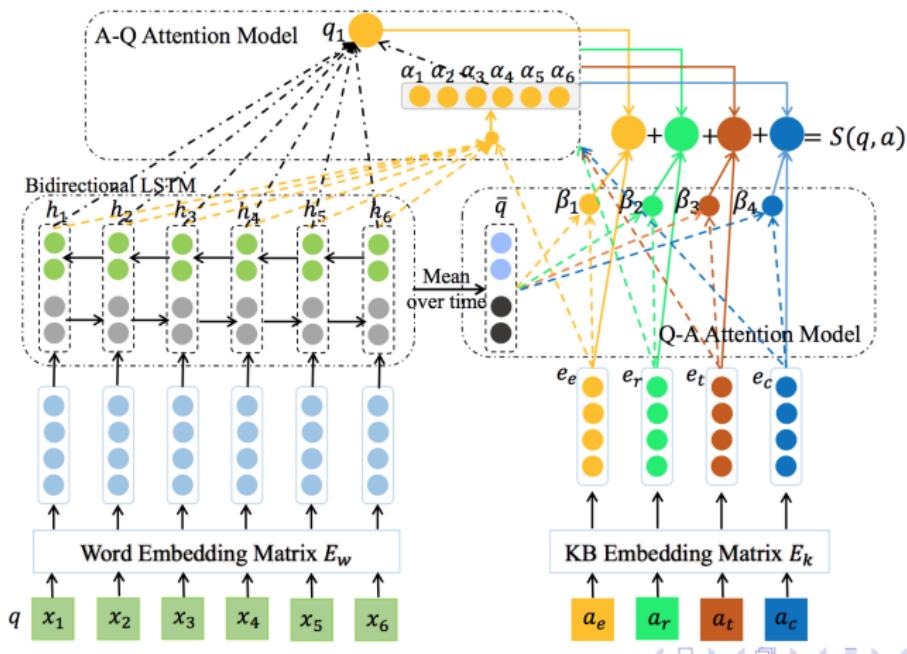
# Attention + Global Knowledge

- 问句语义表示过于简单
- 对实体名称等的训练数据不足
  - ▶ Cross-Attention 刻画问句表述与答案之间关联
  - ▶ 多任务学习: TransE



# Attention + Global Knowledge

- 问句语义表示过于简单
- 对实体名称等的训练数据不足
  - ▶ Cross-Attention 刻画问句表述与答案之间关联
  - ▶ 多任务学习: TransE



# Memory Networks

- Memory Networks 在问答领域的最初尝试
- 面向简单问题: 只需一条知识即可回答

## 记忆单元

- 每个单元存储一条知识三元组
- 词袋模式

## 自然语言问题

- 词袋模式
- 问题与存储单元简单计算 (借助权值矩阵)

# Memory Networks

- Memory Networks 在问答领域的最初尝试
- 面向简单问题: 只需一条知识即可回答

## 记忆单元

- 每个单元存储一条知识三元组
- 词袋模式

## 自然语言问题

- 词袋模式
- 问题与存储单元简单计算 (借助权值矩阵)

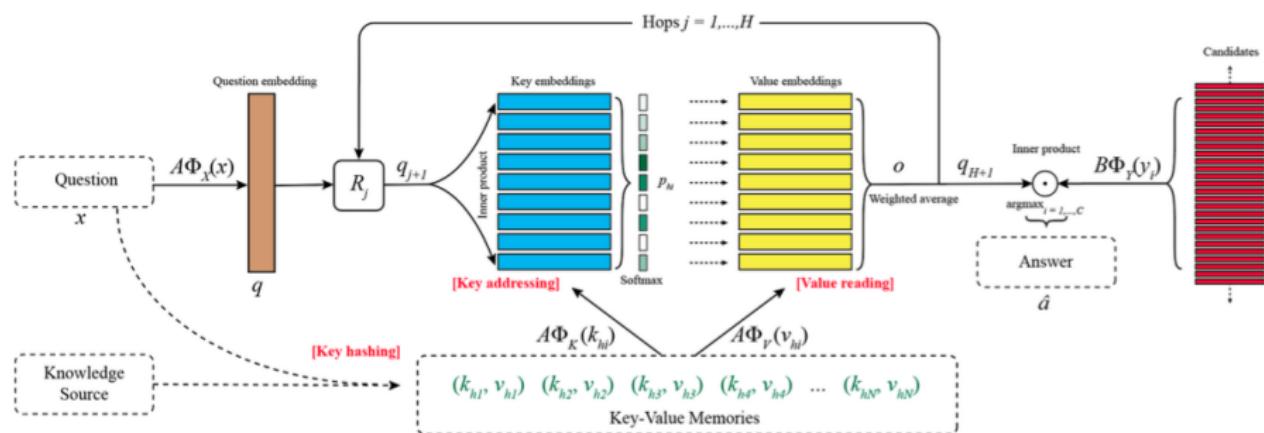
## Memory Networks 的有效性验证

# Key-Value Memory Networks

- 记忆单元为 Key-Value 形式, 如<主体+关系, 客体>
- 访问时, Query 与存储单元的 Key 计算相关度
- 检索得到的Value 用来更新 Query 或者 与Memory匹配得到结果
- 可多次访问 Memory

# Key-Value Memory Networks

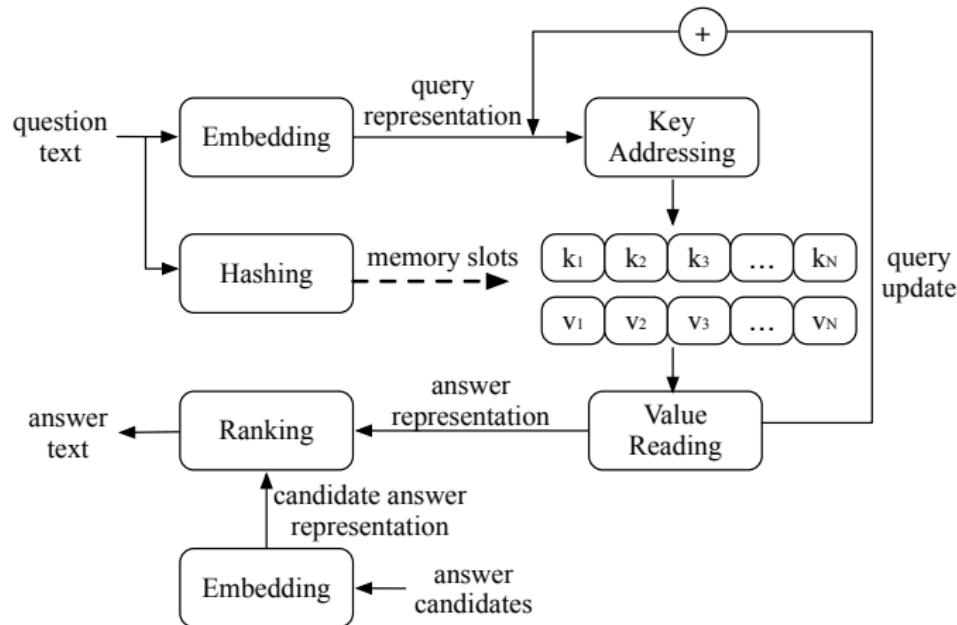
- 记忆单元为 Key-Value 形式, 如<主体+关系, 客体>
- 访问时, Query 与存储单元的 Key 计算相关度
- 检索得到的Value 用来更新 Query 或者与Memory匹配得到结果
- 可多次访问 Memory



# 多次访问 Memory

⇒ 支持浅层推理: 语义组合!

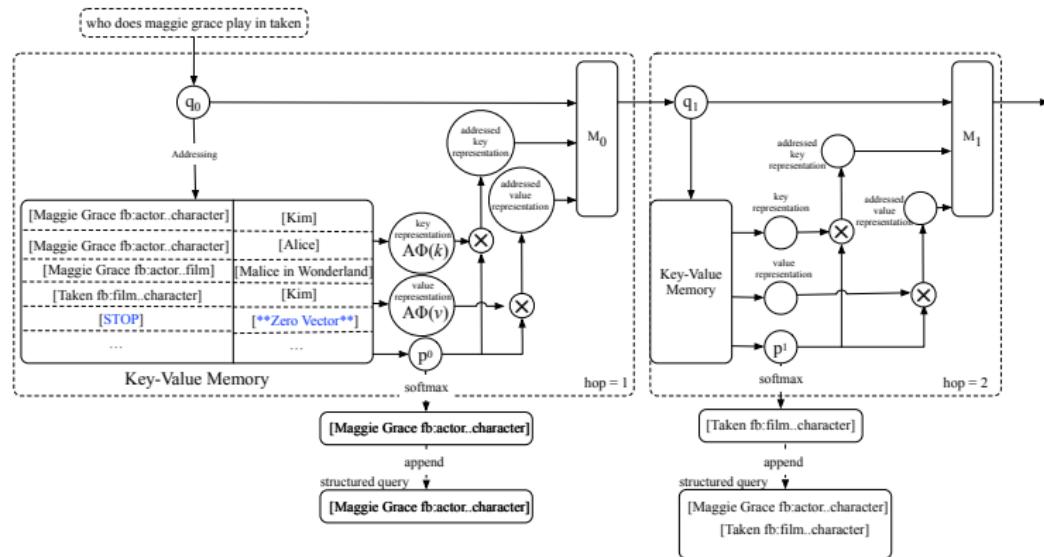
- 访问多少次才合适?
- 如何让每次访问都能收到预期效果?



## 多次访问 Memory

⇒ 支持浅层推理：语义组合！

- 访问多少次才合适?  $\Rightarrow$  需要合理的停止机制
  - 如何让每次访问都能收到预期效果?  $\Rightarrow$  需要恰当的 Query 更新机制



# Neural Symbolic Machines

语义分析类型: 学习查询步骤 (符号系统)

# Neural Symbolic Machines

语义分析类型: 学习查询步骤 (符号系统)

- 期望: 问题 → 查询 → 答案

# Neural Symbolic Machines

语义分析类型: 学习查询步骤 (符号系统)

- 期望: 问题 → 查询 → 答案 !!只有间接语料: 问题 → 答案

# Neural Symbolic Machines

语义分析类型: 学习查询步骤 (符号系统)

- 期望: 问题 → 查询 → 答案 !只有间接语料: 问题 → 答案
- Seq2Seq with Key-Variable Memory: 问题 → 查询命令

# Neural Symbolic Machines

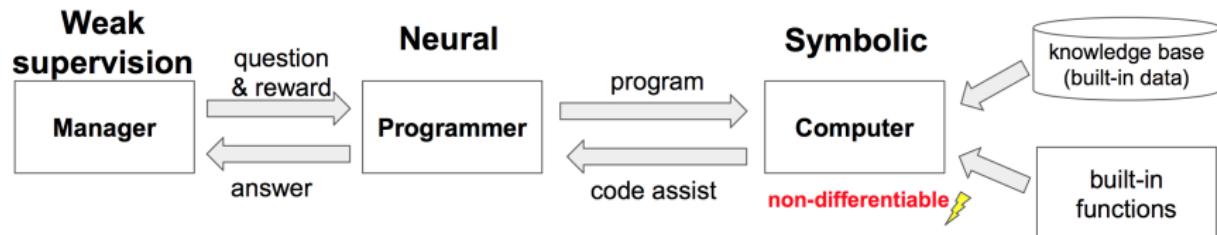
语义分析类型: 学习查询步骤 (符号系统)

- 期望: 问题 → 查询 → 答案 !只有间接语料: 问题 → 答案
- Seq2Seq with Key-Variable Memory: 问题 → 查询命令 → 结果

# Neural Symbolic Machines

语义分析类型: 学习查询步骤 (符号系统)

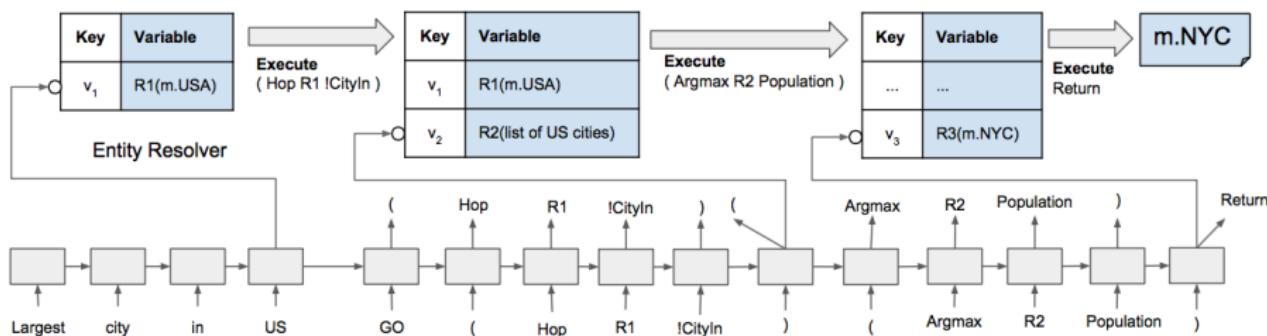
- 期望: 问题 → 查询 → 答案 !!只有间接语料: 问题 → 答案
- Seq2Seq with Key-Variable Memory: 问题 → 查询命令 → 结果
- 需支持生成 查询语句, 函数
- 弱监督框架存在问题: Non-Differentiable



# Neural Symbolic Machines

语义分析类型: 学习查询步骤 (符号系统)

- 期望: 问题  $\rightarrow$  查询  $\rightarrow$  答案 !只有间接语料: 问题  $\rightarrow$  答案
- Seq2Seq with Key-Variable Memory: 问题  $\rightarrow$  查询命令  $\rightarrow$  结果
- 需支持生成 查询语句, 函数
- 弱监督框架存在问题: Non-Differentiable
- 训练策略: REINFORCE 和 Augmented REINFORCE
- 效果出众: 函数解决了部分语义组合的问题



# 语义组合

## 挑战！

- 简单: 单关系、单实体
- 简单 + 类别
- N-ary
- 并列多关系
- 多关系组合
- 排序
- 时序
- 其他

[Talmor et al., 2017]

# 语义组合

## 挑战！

- 简单: 单关系、单实体
- 简单 + 类别
- N-ary
- 并列多关系
- 多关系组合
- 排序
- 时序
- 其他

(浅层)推理更困难

[Talmor et al., 2017]

# 本节内容

① 背景

② 传统解决方案

③ 基于深度学习的解决方案

④ 新视角

- 应对复杂问题
- 深度学习方法的新场景

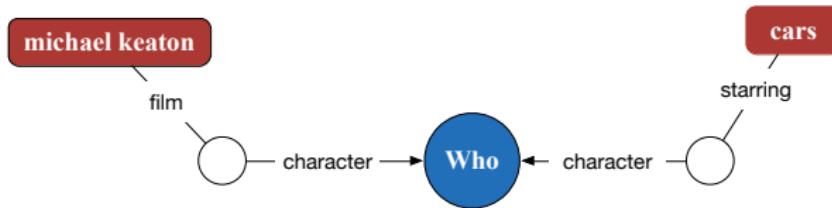
⑤ 小结

# 回顾：基于实体-关系的问答技术

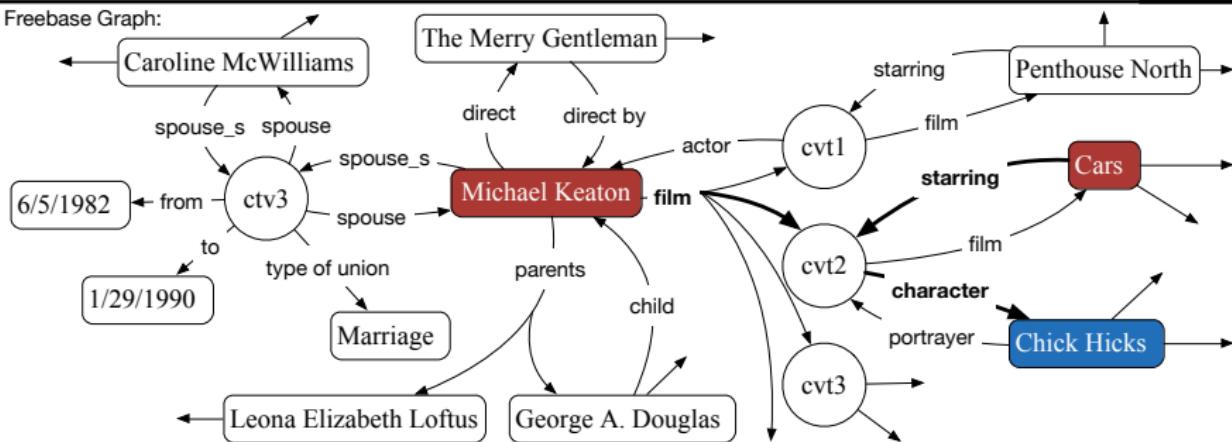
Question:

**Who does michael keaton play in cars**

Star Graph:



Freebase Graph:



# 结构化知识库足够了吗?

不那么容易的问题:

- what mountain is the **highest** in north america
- who did shaq **first** play for
- who is shaq's **father**

# 结构化知识库足够了吗?

不那么容易的问题:

- what mountain is the **highest** in north america
- who did shaq **first** play for
- who is shaq's **father**

函数式约束, 复杂语义组合, **Sub-lexicon, ...**

# 结构化知识库足够了吗？

不那么容易的问题：

- what mountain is the **highest** in north america
- who did shaq **first** play for
- who is shaq's **father**

## Shaquille O'Neal

From Wikipedia, the free encyclopedia

(Redirected from [Shaq](#))

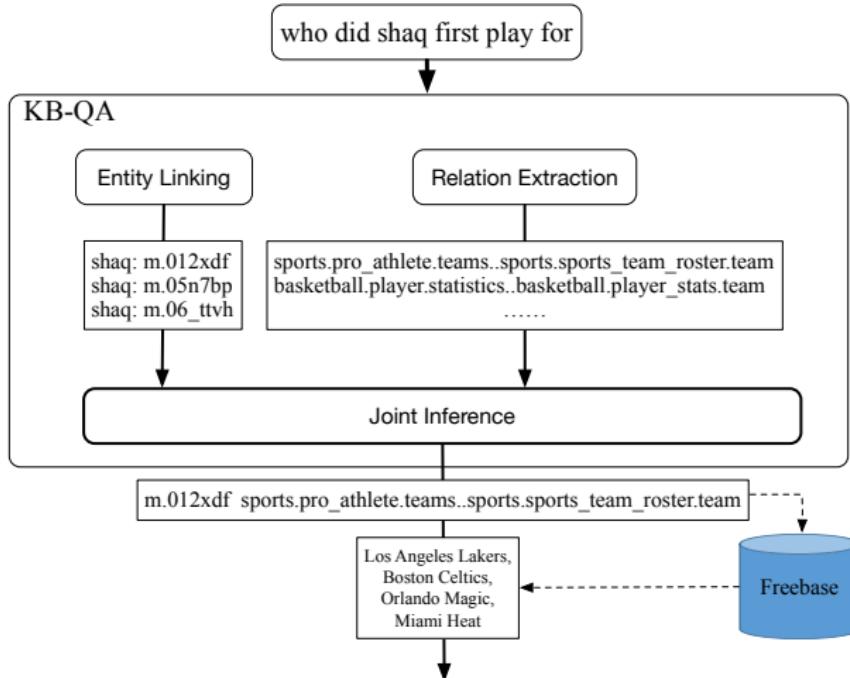
"*Shaquille*" redirects here. For other uses, see [Shaquille \(disambiguation\)](#).

Shaquille Rashawn O'Neal (*/ʃeɪkɪl/ sha-KEEL*; born March 6, 1972), nicknamed **Shaq** (*/ʃæk/ SHAK*), is an American retired professional [basketball](#) player who is currently an analyst on the television program [Inside the NBA](#). Listed at 7 ft 1 in (2.16 m) tall<sup>[1]</sup> and weighing 325 pounds (147 kg), he was one of the heaviest players ever to play in the NBA. O'Neal played for six teams throughout his 19-year NBA career.

Following his career at [Louisiana State University](#), O'Neal was drafted by the [Orlando Magic](#) with the **first overall pick** in the [1992 NBA draft](#). He quickly became one of the best [centers](#) in the league, winning [Rookie of the Year](#) in [1992–93](#) and later leading his team to the [1995 NBA Finals](#). After four years with the Magic, O'Neal signed as a [free agent](#) with the [Los Angeles Lakers](#). They won **three consecutive championships** in [2000](#), [2001](#), and [2002](#). Amid [tension](#) between O'Neal and Kobe Bryant, O'Neal was traded to the [Miami Heat](#) in [2004](#), and his fourth NBA championship followed in [2006](#). Midway through the [2007–2008](#) season he was traded to the [Phoenix Suns](#). After a season-and-a-half with the Suns, O'Neal was traded to the [Cleveland Cavaliers](#) in the [2009–10](#) season.<sup>[2]</sup> O'Neal played for the [Boston Celtics](#) in the [2010–11](#) season before retiring.<sup>[3]</sup>

# 结构化知识库之外

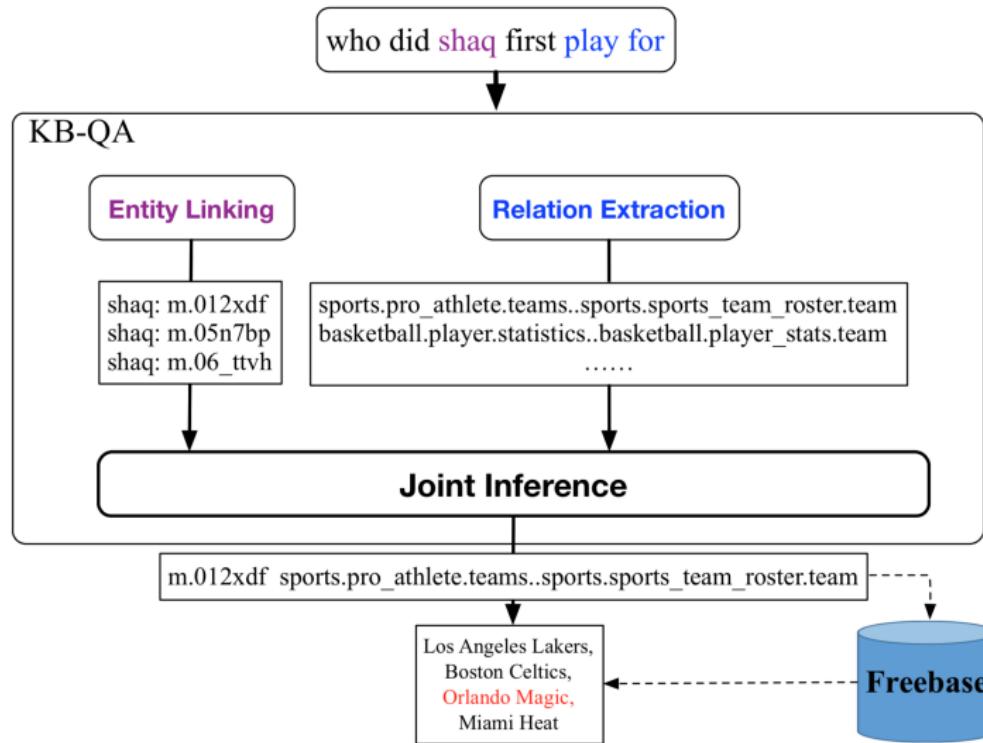
单独依靠知识库也许是不够的 → 实体与关系的联合消解



- Joint Entity Linking & Relation Extraction (ranking problem)

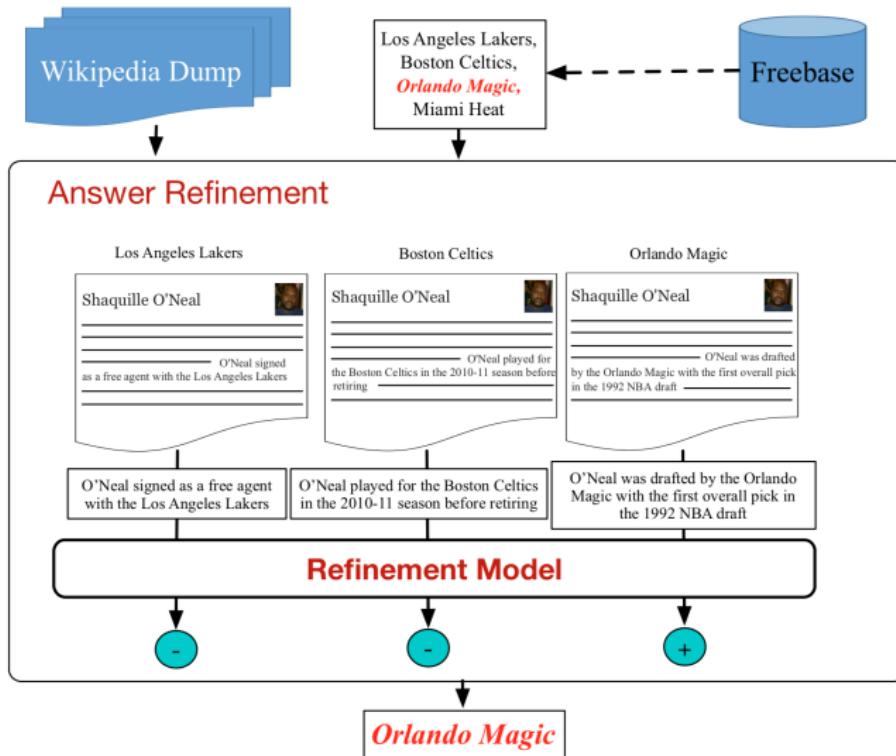
# 结构化知识库之外：文本的作用

单独依靠知识库也许是不够的 → 利用维基正文清洗候选答案



# 结构化知识库之外：文本的作用

单独依靠知识库也许是不够的 → 利用维基正文清洗候选答案



# 样例

## Question & Answers

1. what is the largest nation in europe

Before: Kazakhstan, Turkey, Russia, ...

After: Russia

2. which country in europe has the largest land area

Before: Georgia, France, Russia, ...

After: Russian Empire, Russia

3. what year did ray allen join the nba

Before: 2007, 2003, 1996, 1993, 2012

After: 1996

4. who is emma stone father

Before: Jeff Stone, Krista Stone

After: Jeff Stone

5. where did john steinbeck go to college

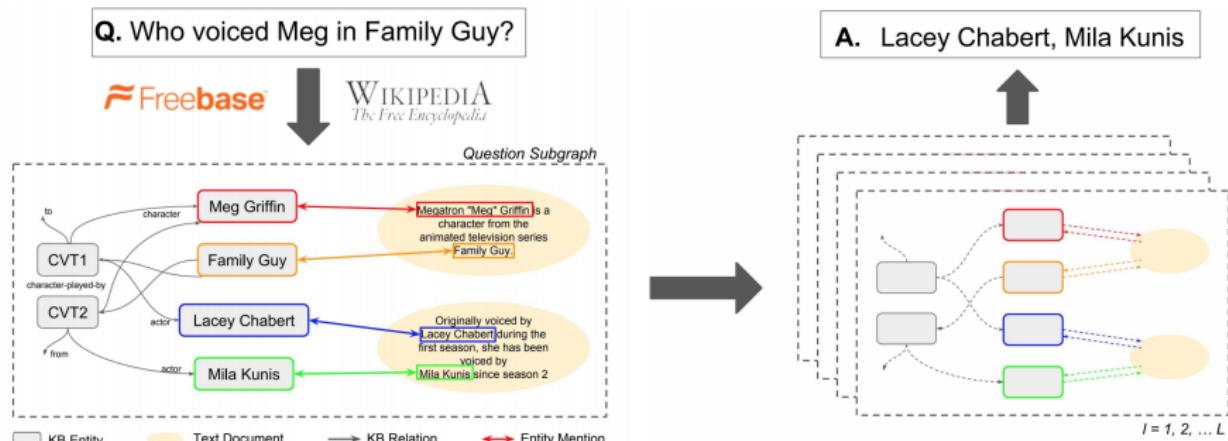
Before: Salinas High School, Stanford University

After: Stanford University

# Craft-Net

将问题与候选知识库子图链接，判断候选答案

- Personalized PageRank
- Graph Convolutional Neural Networks

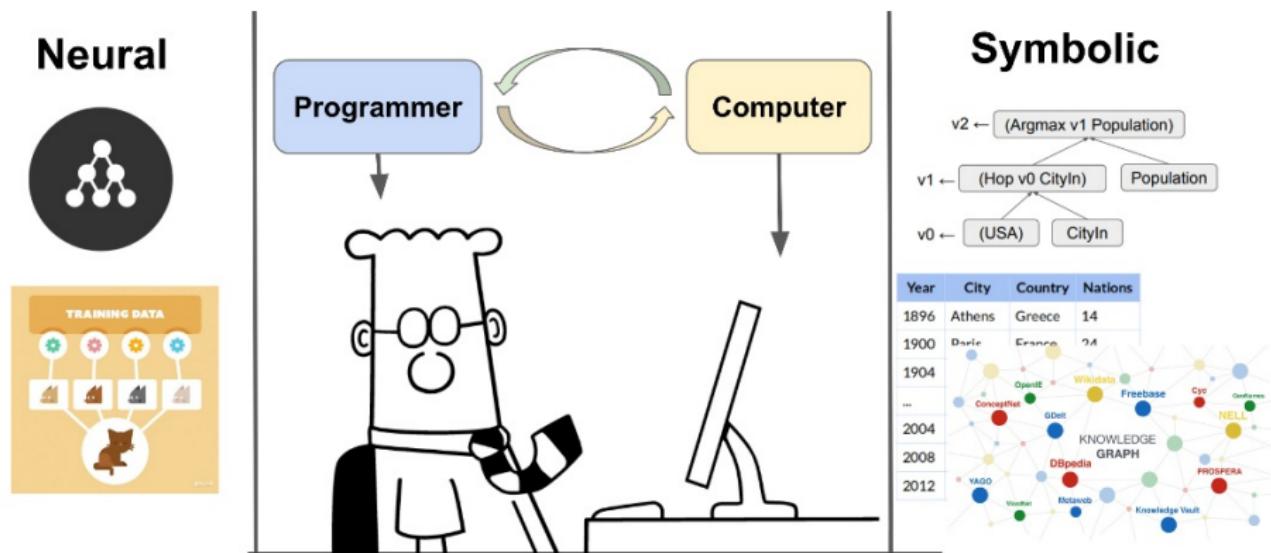


[Sun et al., 2018]

# Enhanced NSM with Meta-Learning

Neural Symbolic Machines: 学习如何生成查询步骤

- pseudo-oracle sequence
- properly rewarding → **Reinforcement Learning + Meta Learning**
- few-shot learning

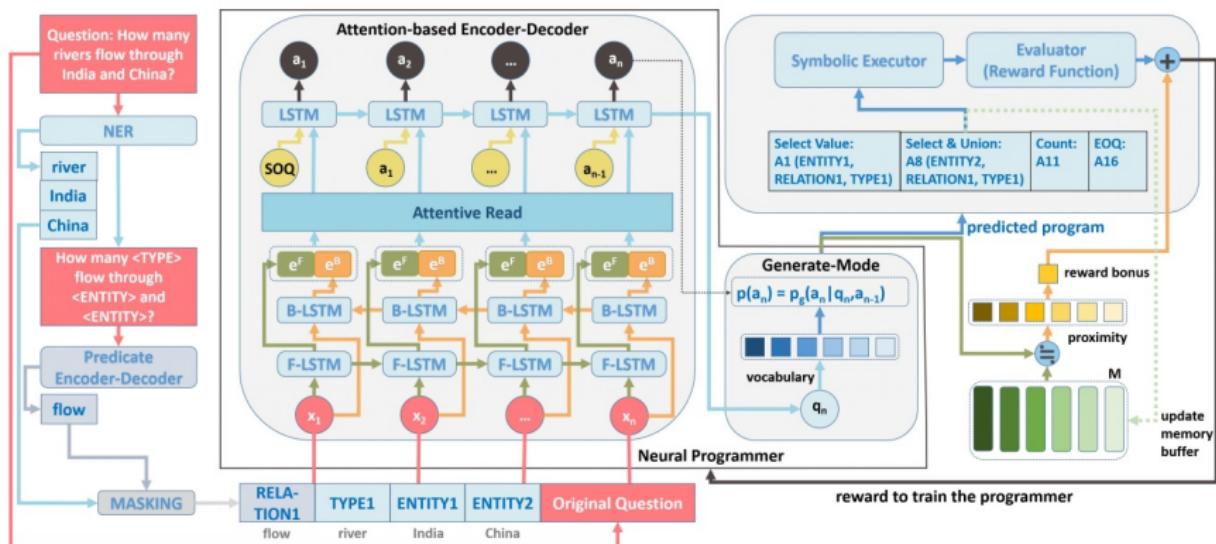


[Hua et al., 2020]

# Enhanced NSM with Meta-Learning

Neural Symbolic Machines: 学习如何生成查询步骤

- pseudo-oracle sequence
- properly rewarding → **Reinforcement Learning + Meta Learning**
- few-shot learning



[Hua et al., 2020]

# 本节内容

① 背景

② 传统解决方案

③ 基于深度学习的解决方案

④ 新视角

- 应对复杂问题
- 深度学习方法的新场景

⑤ 小结

# 生成自然的回复

## 新任务

输入: 事实类自然语言问题  
输出: **生成自然语言回答**

# 生成自然的回复

## 新任务

输入: 事实类自然语言问题  
输出: **生成自然语言回答**

## 期望

- 回答正确
- 表述自然

# 生成自然的回复

## 新任务

输入: 事实类自然语言问题  
输出: 生成自然语言回答

## 期望

- 回答正确 ⇒ 答案正确
- 表述自然
- 融入到对话等实际应用场景中

# 生成自然的回复

## 新任务

输入: 事实类自然语言问题  
输出: 生成自然语言回答

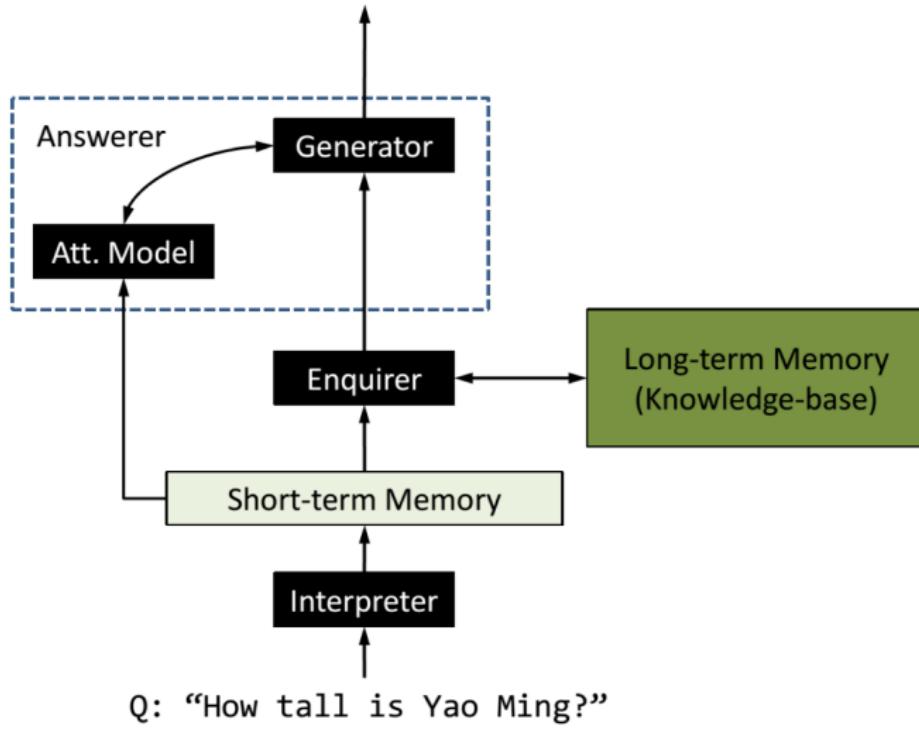
## 期望

- 回答正确 ⇒ 答案正确
- 表述自然 ⇒ 短语? 句子? ...
- 融入到对话等实际应用场景中

# GenQA

## Encoder-Decoder框架

A: “He is **2.29m** and visible from space.”

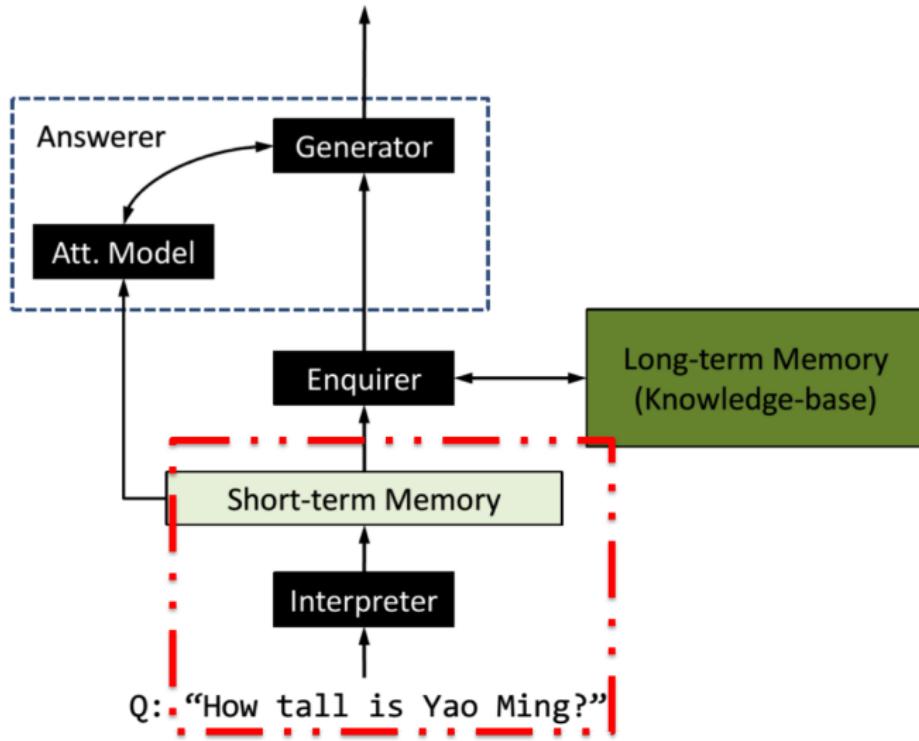


[Yin et al., 2016]

GenQA

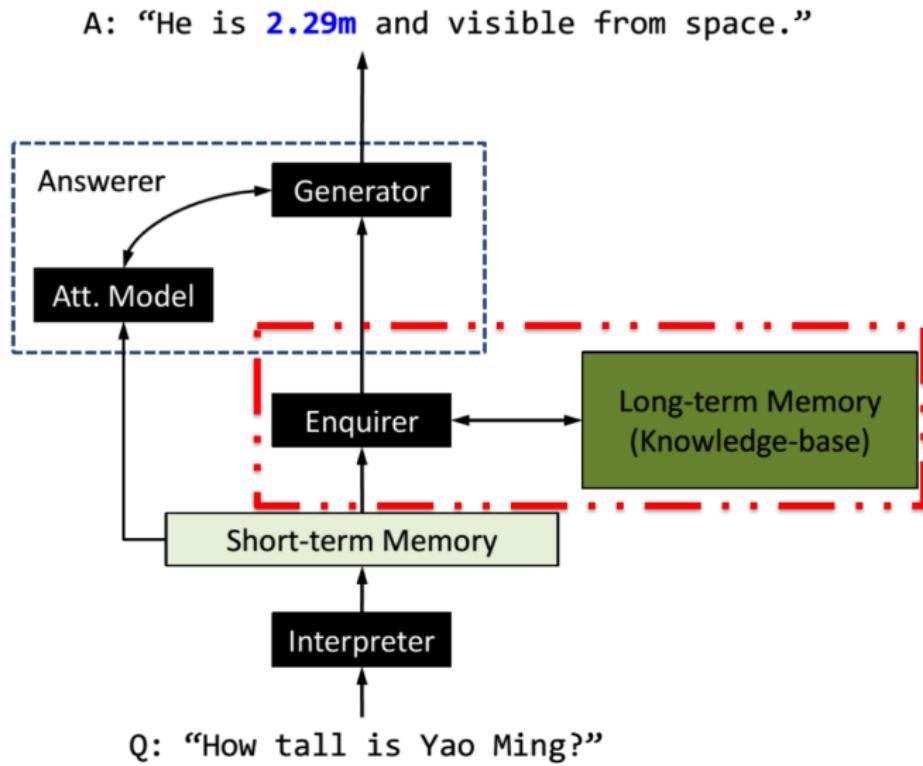
**Encoder-Decoder框架**：读入并表示问题

A: "He is **2.29m** and visible from space."



# GenQA

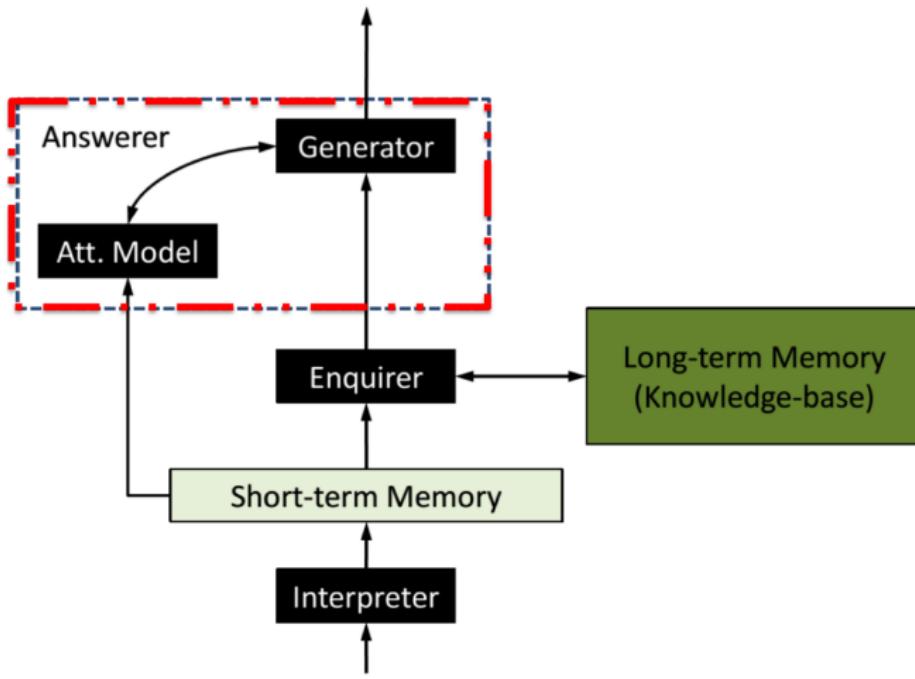
Encoder-Decoder框架：查询知识库，获取结果三元组



# GenQA

## Encoder-Decoder框架 : 生成自然语言回复

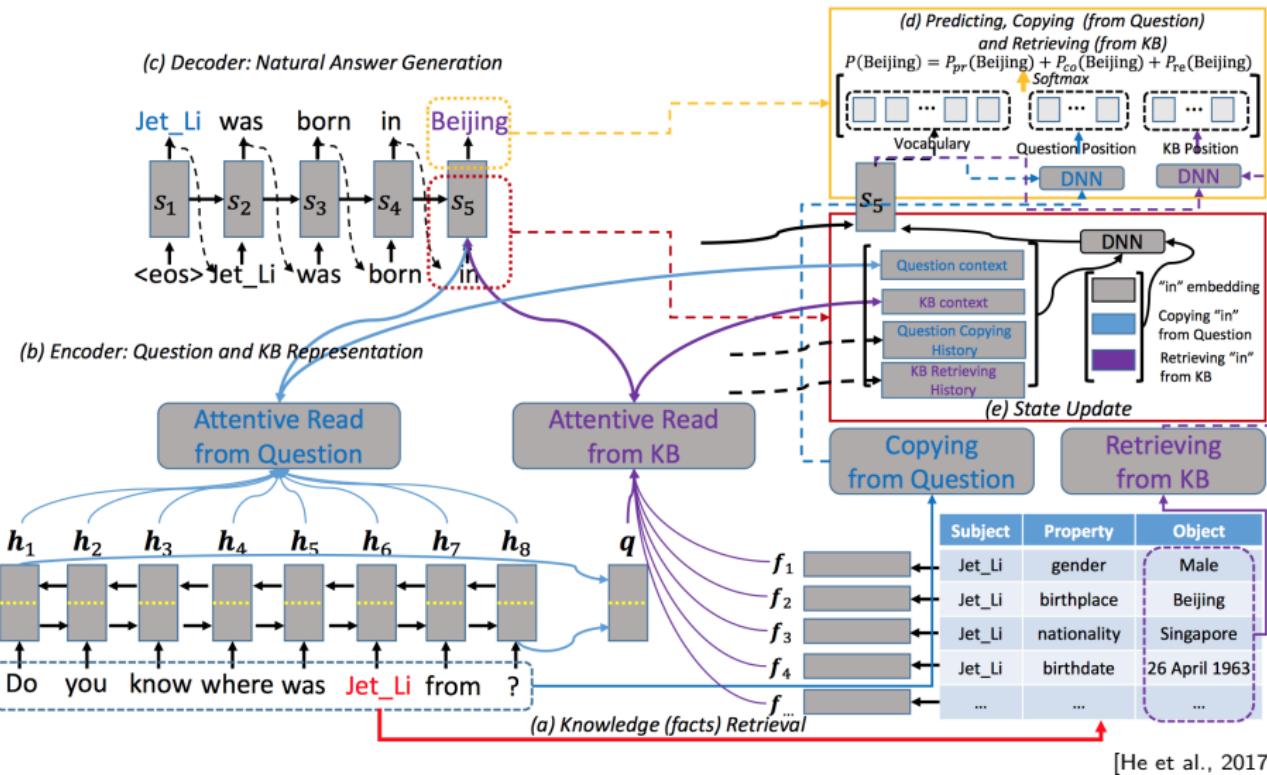
A: "He is **2.29m** and visible from space."



Q: "How tall is Yao Ming?"

# COREQA

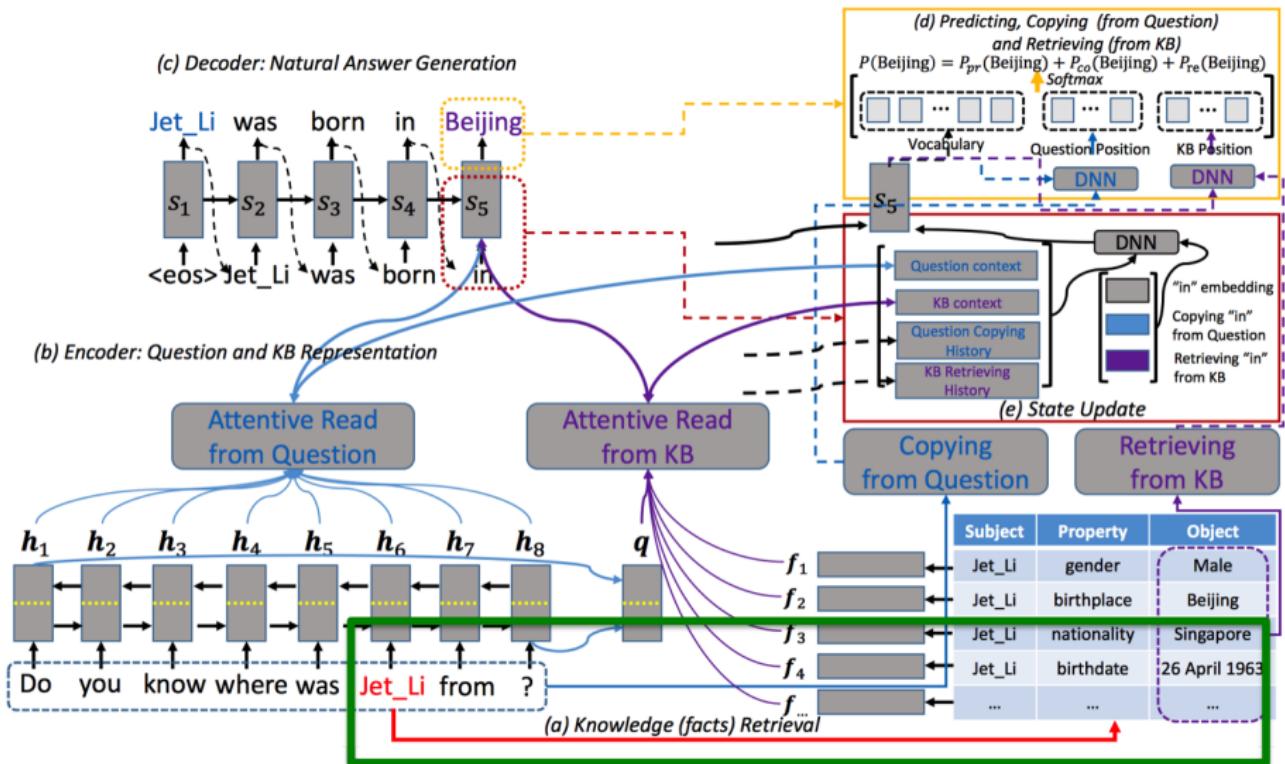
## Encoder-Decoder框架



[He et al., 2017]

# COREQA

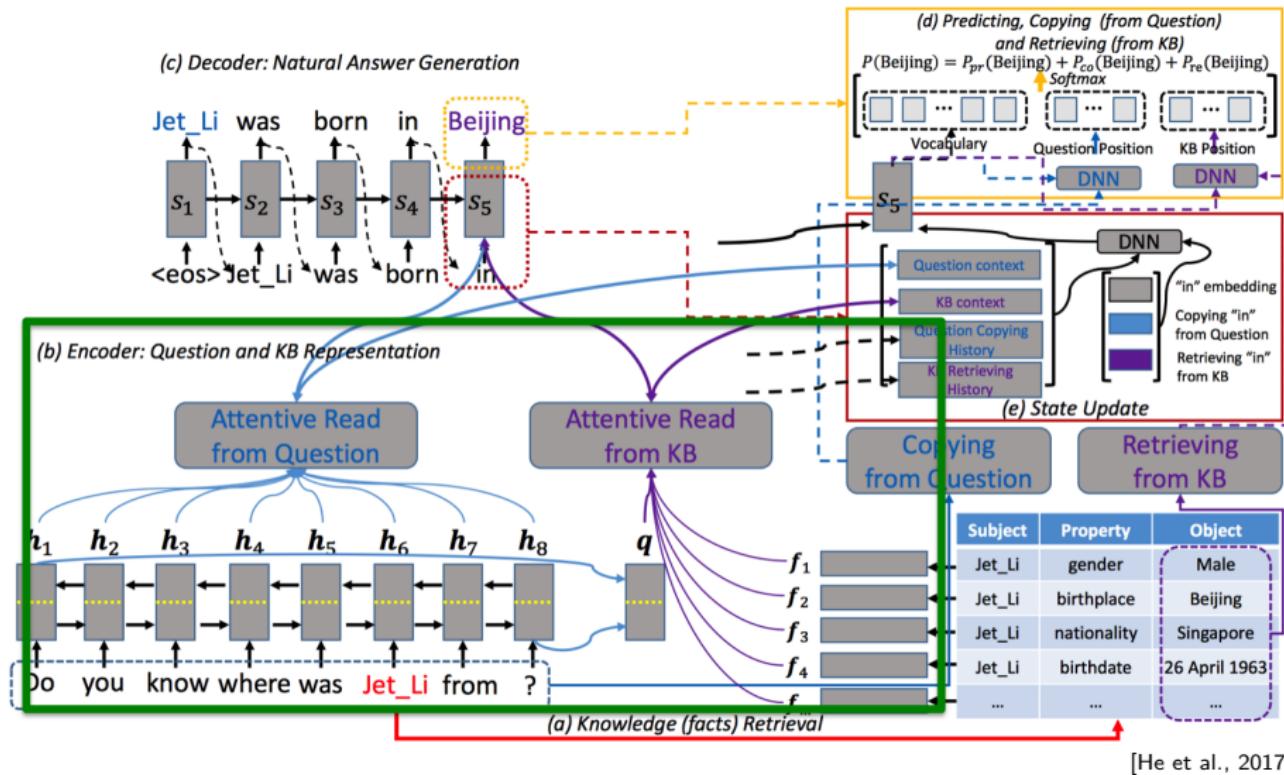
## Encoder-Decoder框架：通过实体查询知识（三元组）



[He et al., 2017]

# COREQA

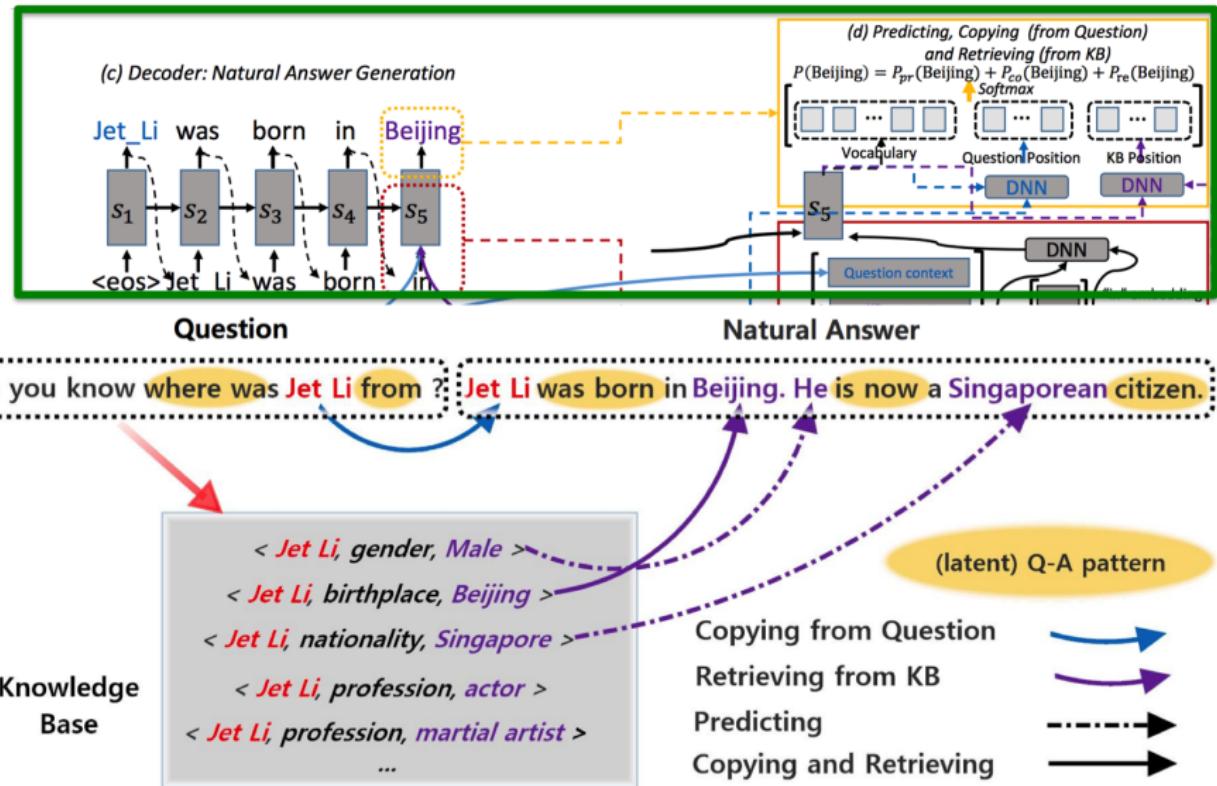
## Encoder-Decoder框架：问题与知识编码



[He et al., 2017]

# COREQA

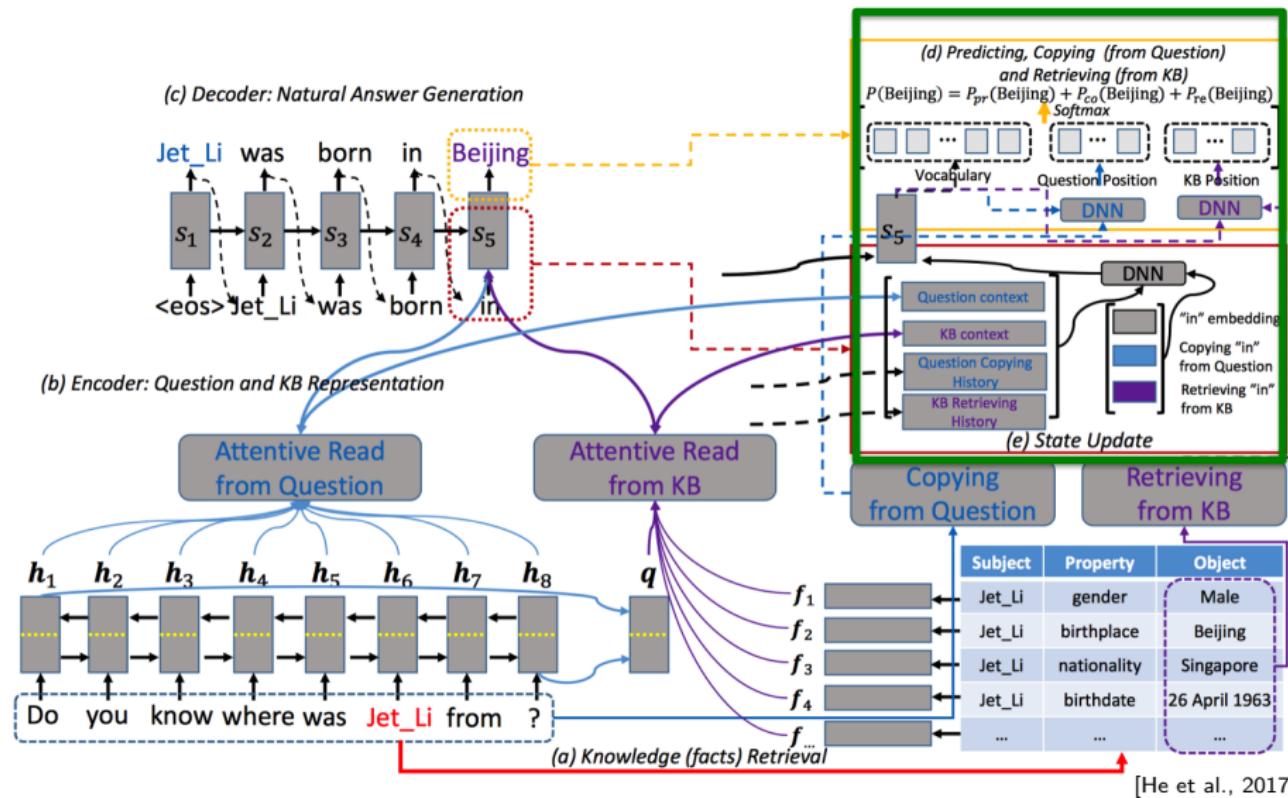
## Encoder-Decoder框架 : 解码生成答案



# COREQA

## Encoder-Decoder框架

: 检索、拷贝机制及状态更新



# 利用多源异构知识资源

Seq-to-Seq框架: Key-Value Memory: 知识库、表格、文本

.....

kb directed_by	Mark Haggard
kb written_by	Bruce Kimmel
doc year	1976
doc directed	Bruce Kimmel
kb movie_name	The First Nudie Musical
doc director	Mark Haggard

Q: the film The First Nudie Musical was directed by who?

A: The First Nudie Musical is a 1976

American motion

picture directed by Mark Haggard

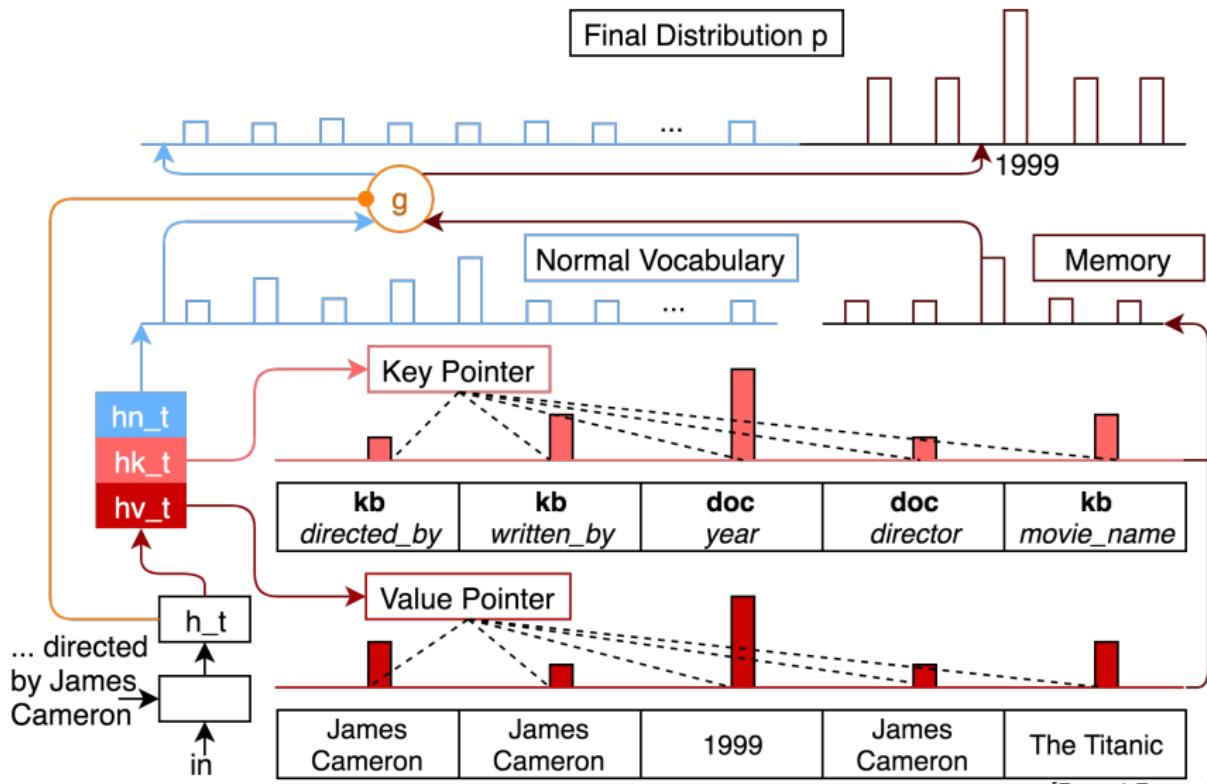
and Bruce Kimmel.

    
memory from topic word    memory from knowledge base    memory from documents

[Fu and Feng., 2018]

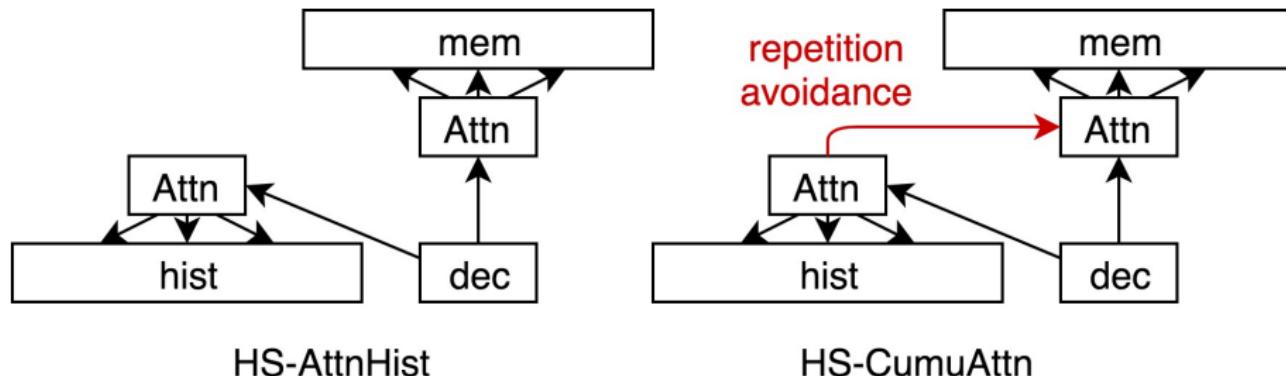
# 利用多源异构知识资源

## Seq-to-Seq框架: 根据KVM特性分离Attention



# 利用多源异构知识资源

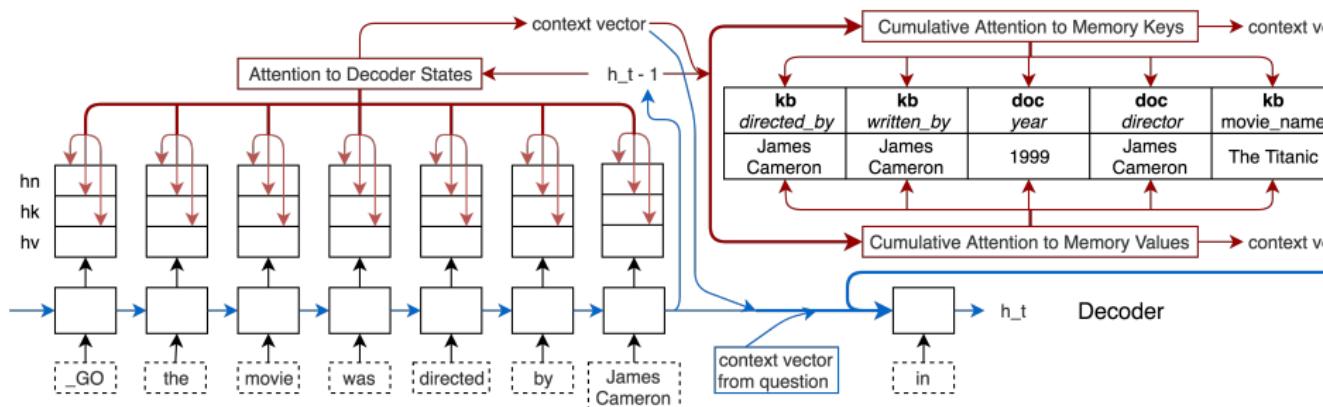
Seq-to-Seq框架: 关注历史、避免重复、精确读取新信息



[Fu and Feng., 2018]

# 利用多源异构知识资源

Seq-to-Seq框架:      准确、简洁、丰富



[Fu and Feng., 2018]

- 取得长足进步

- ▶ 广受关注
- ▶ 深度学习方法的广泛应用
- ▶ beyond toy datasets ...
- ▶ 新的应用形态

# 面向知识的智能问答

- 取得长足进步

- ▶ 广受关注
- ▶ 深度学习方法的广泛应用
- ▶ beyond toy datasets ...
- ▶ 新的应用形态

- 仍然充满挑战

- ▶ 问题的语义表示
- ▶ 自然语言表述与知识之间的鸿沟
- ▶ 语义组合 (Semantic Composition)
- ▶ 推理 (浅层推理)
- ▶ 利用更丰富的知识资源

# 面向知识的智能问答

- 取得长足进步

- ▶ 广受关注
- ▶ 深度学习方法的广泛应用
- ▶ beyond toy datasets ...
- ▶ 新的应用形态

- 仍然充满挑战

- ▶ 问题的语义表示
- ▶ 自然语言表述与知识之间的鸿沟
- ▶ 语义组合 (Semantic Composition)
- ▶ 推理 (浅层推理、**知识推理**、**常识推理**)
- ▶ 利用更丰富的知识资源

# 面向知识的智能问答

- 取得长足进步

- ▶ 广受关注
- ▶ 深度学习方法的广泛应用
- ▶ beyond toy datasets ...
- ▶ 新的应用形态

- 仍然充满挑战

- ▶ 问题的语义表示
- ▶ 自然语言表述与知识之间的鸿沟
- ▶ 语义组合 (Semantic Composition)
- ▶ 推理 (浅层推理、**知识推理**、**常识推理**)
- ▶ 利用更丰富的知识资源
- ▶ 如何真正实际应用

# 面向知识的智能问答

- 取得长足进步

- ▶ 广受关注
- ▶ 深度学习方法的广泛应用
- ▶ beyond toy datasets ...
- ▶ 新的应用形态

- 仍然充满挑战

- ▶ 问题的语义表示
- ▶ 自然语言表述与知识之间的鸿沟
- ▶ 语义组合 (Semantic Composition)
- ▶ 推理 (浅层推理、**知识推理**、**常识推理**)
- ▶ 利用更丰富的知识资源
- ▶ 如何真正实际应用: 不同知识来源、语态、场景、多轮、多语言

# Thank You!

PKU  
Information  
Extraction

# 参考文献 – 1

- John Zelle and Raymond Mooney. Learning to parse database queries using inductive logic programming. In AAAI 1996 Luke S Zettlemoyer and Michael Collins. Learning to map sentences to logical form: Structured classification with probabilistic categorial grammars. In UAI 2005
- Yuk Wah Wong and Raymond J Mooney. Learning synchronous grammars for semantic parsing with lambda calculus. In ACL 2007
- Percy Liang, Michael I Jordan, and Dan Klein. Learning dependency-based compositional semantics. Computational Linguistics, 2013.
- Qingqing Cai and Alexander Yates. Large-scale semantic parsing via schema matching and lexicon extension. In ACL 2013
- Jonathan Berant, Andrew Chou, Roy Frostig, and Percy Liang. Semantic parsing on freebase from question-answer pairs. In EMNLP 2013
- Tom Kwiatkowski, Eunsol Choi, Yoav Artzi, and Luke S. Zettlemoyer. Scaling semantic parsers with on-the-fly ontology matching. In EMNLP 2013

## 参考文献－2

- Siva Reddy, Mirella Lapata, and Mark Steedman. Large-scale semantic parsing without question-answer pairs. In TACL 2014
- Xuchen Yao and Benjamin Van Durme. 2014. Information extraction over structured data: Question answering with freebase. In ACL 2014
- Jonathan Berant and Percy Liang. Semantic parsing via paraphrasing. In ACL 2014
- Junwei Bao, Nan Duan, Ming Zhou, and Tiejun Zhao. Knowledge-based question answering as machine translation. In ACL 2014
- Kun Xu, Sheng Zhang, Yansong Feng, and Dongyan Zhao. Answering natural language questions via phrasal semantic parsing. In NLPCC 2014.
- Antoine Bordes, Sumit Chopra, and Jason Weston. Question answering with subgraph embeddings. In EMNLP 2014
- Jonathan Berant and Percy Liang. Imitation learning of agenda-based semantic parsers. TACL 2015.

## 参考文献－3

- Antoine Bordes, Nicolas Usunier, Sumit Chopra, and Jason Weston. Large-scale simple question answering with memory networks. CoRR, abs/1506.02075.
- Wen-tau Yih, Ming-Wei Chang, Xiaodong He, and Jianfeng Gao. Semantic parsing via staged query graph generation: Question answering with knowledge base. In ACL-IJCNLP 2015.
- Li Dong, Furu Wei, Ming Zhou, and Ke Xu. Question answering over freebase with multi- column convolutional neural networks. In ACL-IJCNLP 2015
- Yi Yang and Ming-Wei Chang. S-MART: Novel tree-based structured learning algorithms applied to tweet entity linking. In ACL- IJCNLP 2015
- Hannah Bast and Elmar Haussmann. More accurate question answering on Freebase. In CIKM 2015
- Kun Xu, Siva Reddy, Yansong Feng, Songfang Huang, and Dongyan Zhao. Question Answering on Freebase via Relation Extraction and Textual Evidence. In ACL 2016

## 参考文献－4

- Yuanzhe Zhang, Shizhu He, Kang Liu and Jun Zhao. A Joint Model for Question Answering over Multiple Knowledge Bases, In AAAI 2016
- Wen-tau Yih, Matthew Richardson, Christopher Meek, Ming-Wei Chang, and Jina Suh. The Value of Semantic Parse Labeling for Knowledge Base Question Answering, In ACL 2016
- Kun Xu, Yansong Feng, Songfang Huang, and Dongyan Zhao. Hybrid Question Answering over Knowledge Base and Free Text. In COLING 2016
- Siva Reddy, Oscar Tackstrom, Michael Collins, Tom Kwiatkowski, Dipanjan Das, Mark Steedman, and Mirella Lapata. Transforming Dependency Structures to Logical Forms for Semantic Parsing. In TACL 2016
- Wen-tau Yih and Hao Ma, Question Answering with Knowledge Bases, Web and Beyond, In NAACL 2016, (Tutorial)
- Heng Ji, <http://nlp.cs.rpi.edu/kbp/2017/elreading.html>

## 参考文献—5

- Mo Yu, Wenpeng Yin, Kazi Saidul Hasan, Cicero dos Santos, Bing Xiang, Bowen Zhou, Improved Neural Relation Detection for Knowledge Base Question Answering, in ACL 2017
- Shizhu He; Cao Liu; Kang Liu; Jun Zhao. Generating Natural Answers by Incorporating Copying and Retrieving Mechanisms in Sequence-to-Sequence Learning. ACL 2017
- Chen Liang; Jonathan Berant; Quoc Le; Kenneth D. Forbus; Ni Lao. Neural Symbolic Machines: Learning Semantic Parsers on Freebase with Weak Supervision. ACL 2017
- Jun Yin, Xin Jiang, Zhengdong Lu, Lifeng Shang, Hang Li, and Xiaoming Li. Neural generative question answering. IJCAI 2016
- Mo Yu; Wenpeng Yin; Kazi Saidul Hasan; Cicero dos Santos; Bing Xiang; Bowen Zhou, Improved Neural Relation Detection for Knowledge Base Question Answering, ACL 2017
- Yao Fu and Yansong Feng, Natural Answer Generation with Heterogeneous Memory, NAACL 2018

## 参考文献－6

- Miller A, Fisch A, Dodge J, et al. Key-value memory networks for directly reading documents, arXiv:1606.03126, 2016
- Haitian Sun, Bhuwan Dhingra, Manzil Zaheer, Kathryn Mazaitis, Ruslan Salakhutdinov, William W. Cohen, Open Domain Question Answering Using Early Fusion of Knowledge Bases and Text, EMNLP 2018
- Yuxuan Lai, Yansong Feng, Xiaohan Yu, Zheng Wang, Kun Xu and Dongyan Zhao, Lattice CNNs for Matching Based Chinese Question Answering, in AAAI 2019
- Kun Xu, Yuxuan Lai, Yansong Feng, Zhiguo Wang, Enhancing Key-Value Memory Neural Networks for Knowledge Based Question Answering, in NAACL 2019
- Yuncheng Hua, Yuan-Fang Li, Gholamreza Haffari, Guilin Qi, Wei Wu, Retrieve, Program, Repeat: Complex Knowledge Base Question Answering via Alternate Meta-learning, in IJCAI 2020