

知识图谱的关键技术与应用

李征峻、孟静怡、王露、哈思娜、严文欣

目录

CONTENTS



01

知识图谱概述

02

知识抽取和知识融合

03

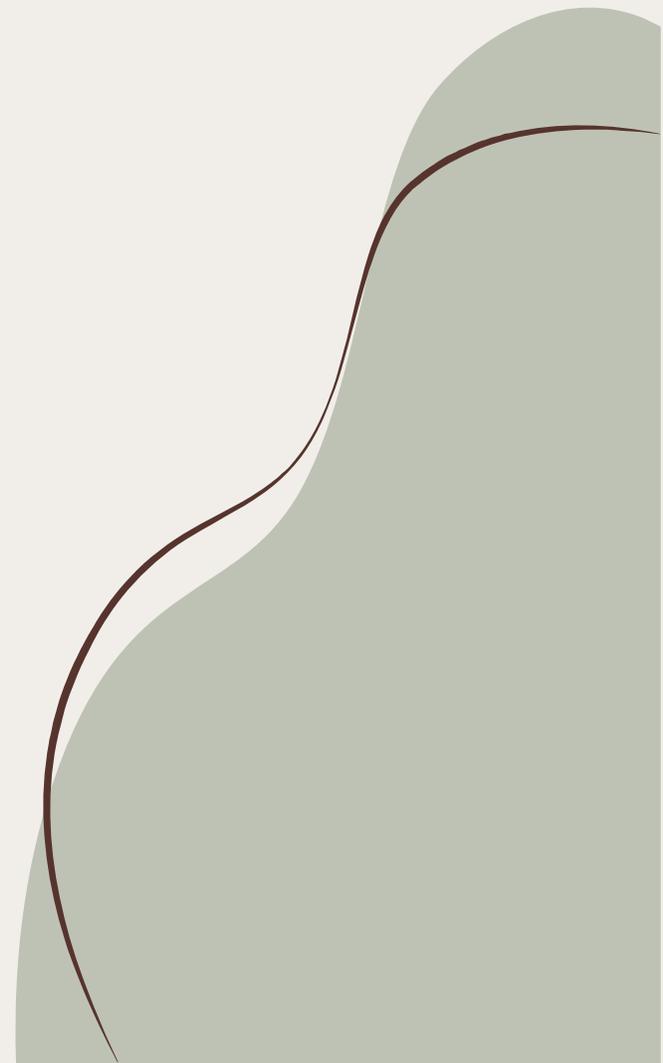
知识表示、知识存储
知识推理

04

前沿进展

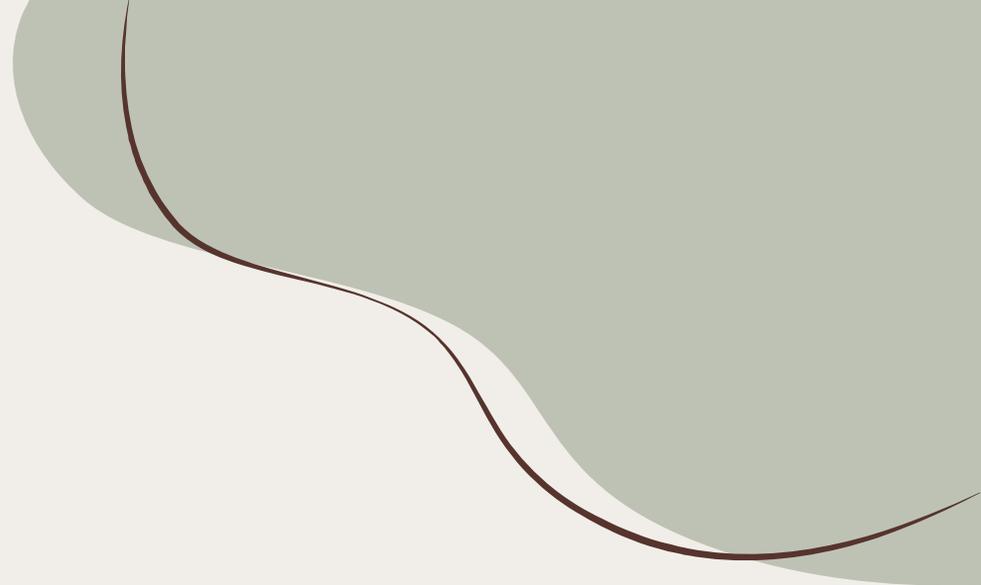
01

DEMO



知识图谱概述

PART.01

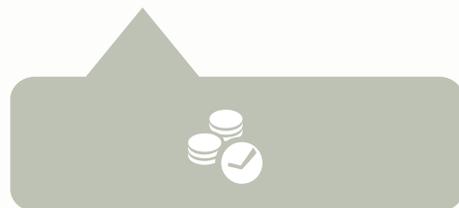


知识图谱概述

知识图谱的概念



知识图谱的历史



知识图谱的分类

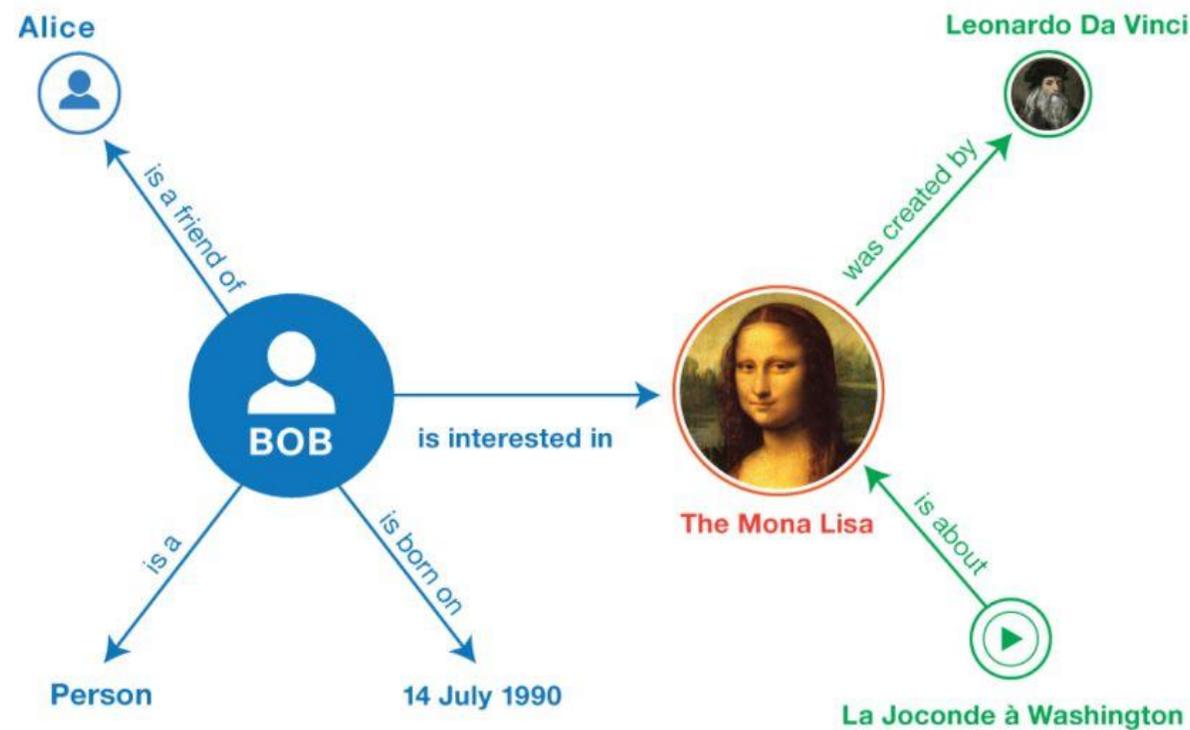


知识图谱的技
术与应用



1. 知识图谱的概念

知识图谱旨在描述真实世界中存在的各种实体或概念。其中，每个实体或概念用一个全局唯一确定的 ID 来标识，称为它们的标识符。每个属性-值对用来刻画实体的内在特性，而关系用来连接两个实体，刻画它们之间的关联。



1. 知识图谱的概念

- 在知识图谱里，我们通常用“实体 (Entity)”来表达图里的节点、用“关系 (Relation)”来表达图里的“边”。实体指的是现实世界中的事物比如人、地名、概念、药物、公司等，关系则用来表达不同实体之间的某种联系，比如人-“居住在”-北京、张三和李四是“朋友”、逻辑回归是深度学习的“先导知识”等等。

知识图谱

通用知识图谱

- 早期的知识库项目
 - Cyc: 基于形式化的知识表示方法刻画知识
 - WordNet: 主要定义了名词、动词、形容词和副词之间的语义关系
 - ConceptNet: 采用了非形式化、更加接近自然语言的描述
- 互联网时代知识图谱
 - Freebase: 一个开放共享的、协同构建的大规模链接数据库
 - DBpedia: 是从Wikipedia抽取出来的链接数据集
 - Schema.org: 本质是采用互联网众包的方式生成和收集高质量的知识图谱数据
 - Wikidata: 支持以三元组为基础的知识条目 (Item) 的自由编辑
 - BabelNet: 目前最大规模的多语言词典知识库
 - NELL: 主要采用互联网挖掘的方法从Web中自动抽取三元组知识
 - Yago: 还考虑了时间和空间知识, 为很多知识条目增加了时间和空间维度的属性描述
 - Microsoft ConceptGraph: 以概念定义和概念之间的 IsA 关系为主
 - LOD: 遵循了Tim 提出的进行数据链接的四个规则

中文开放知识图谱

- Zhishi.me: 狗尾草科技、东南大学
- CN-DBpedia: 复旦大学
- XLore: 清华大学
- Belief-Engine: 中科院自动化所
- PKUPie: 北京大学
- ZhOnto: 狗尾草科技

OpenKG

- 开放的Dump或开放访问API
- 知识建模工具Protege
- 知识融合工具Limes
- 知识问答工具YodaQA
- 知识抽取工具DeepDive
- cnSchema.ORG
- OpenBase.AI

领域知识图谱

- 电商领域知识图谱: 如阿里巴巴电商知识图谱
- 医疗领域知识图谱: 如Linked Life Data 项目、中医药知识图谱
- 金融领域知识图谱

社区用户的贡献

开放音乐数据库 (MusicBrainz)

世界名人数据库 (NNDB)

Wikipedia

OpenCYC

Bio2RDF

GeoNames

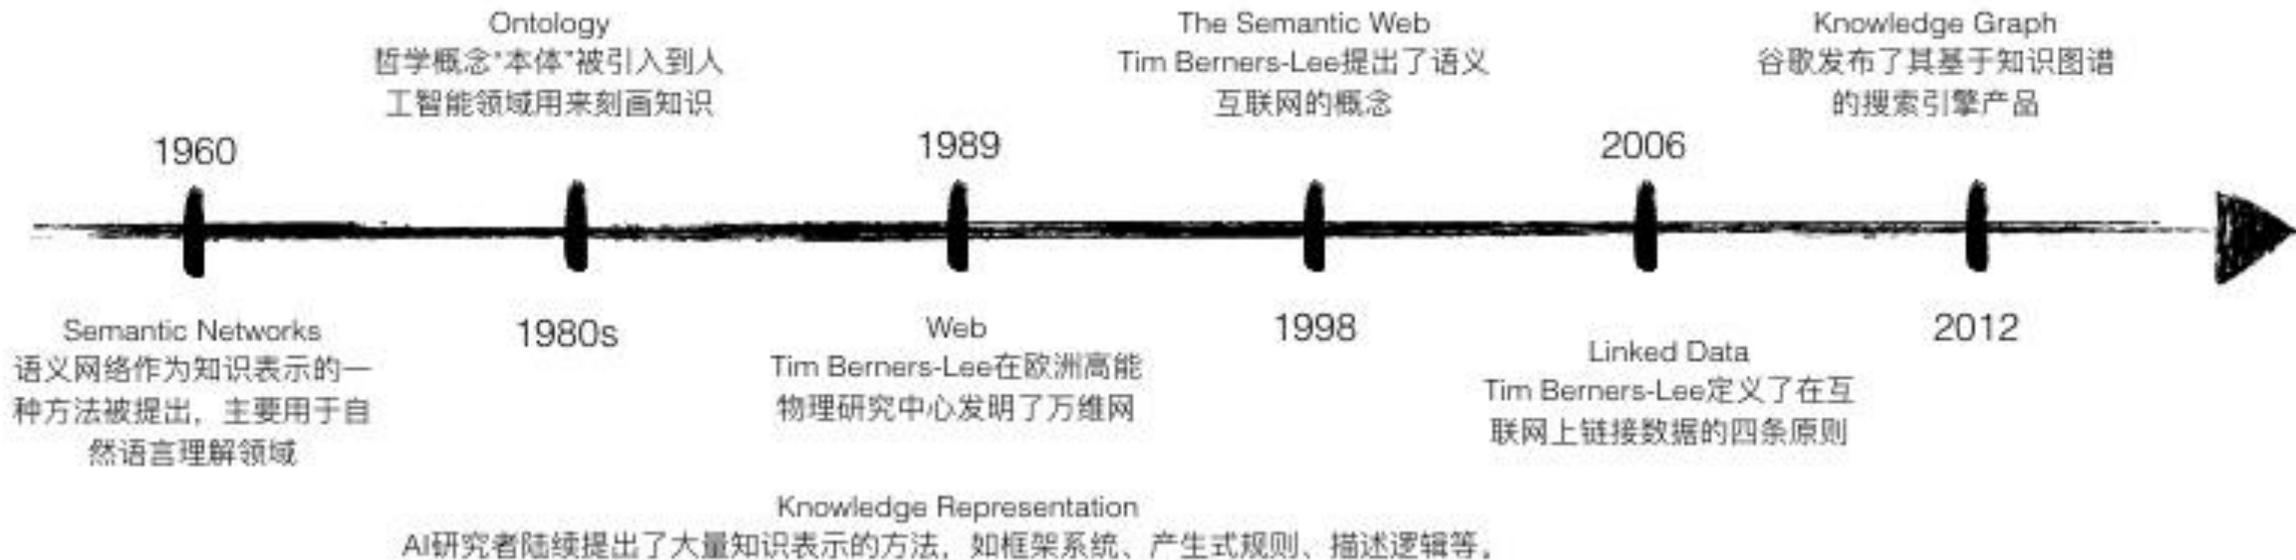
2. 知识图谱的分类：通用知识图谱与领域知识图谱的区别

分类 比较项目	通用知识图谱	领域知识图谱
知识来源及规模化	以互联网开放数据，如 Wikipedia 或社区众包为主要来源，逐步扩大规模	以领域或企业内部的数据为主要来源，通常要求快速扩大规模
对知识表示的要求	主要以三元组事实型知识为主	知识结构更加复杂，通常包含较为复杂的本体工程和规则型知识
对知识质量的要求	较多地采用面向开放域的 Web 抽取，对知识抽取质量有一定容忍度	知识抽取的质量要求更高，较多地依靠从企业内部的结构化、非结构化数据进行联合抽取，并依靠人工进行审核校验，保障质量
对知识融合的要求	融合主要起到提升质量的作用	融合多源的领域数据是扩大构建规模的有效手段
知识的应用形式	主要以搜索和问答为主要应用形式，对推理要求较低	应用形式更加全面，除搜索问答外，通常还包括决策分析、业务管理等，并对推理的要求更高，并有较强的可解释性要求
举例	DBpedia、Yago、百度、谷歌等	电商、医疗、金融、农业、安全等

3. 知识图谱的历史

- 知识图谱的概念是Google于2012年正式提出，但是知识图谱的发展却可以追溯到1960年的语义网络，中间经历了一系列的演变，才形成了今天的知识图谱。

3. 知识图谱的历史

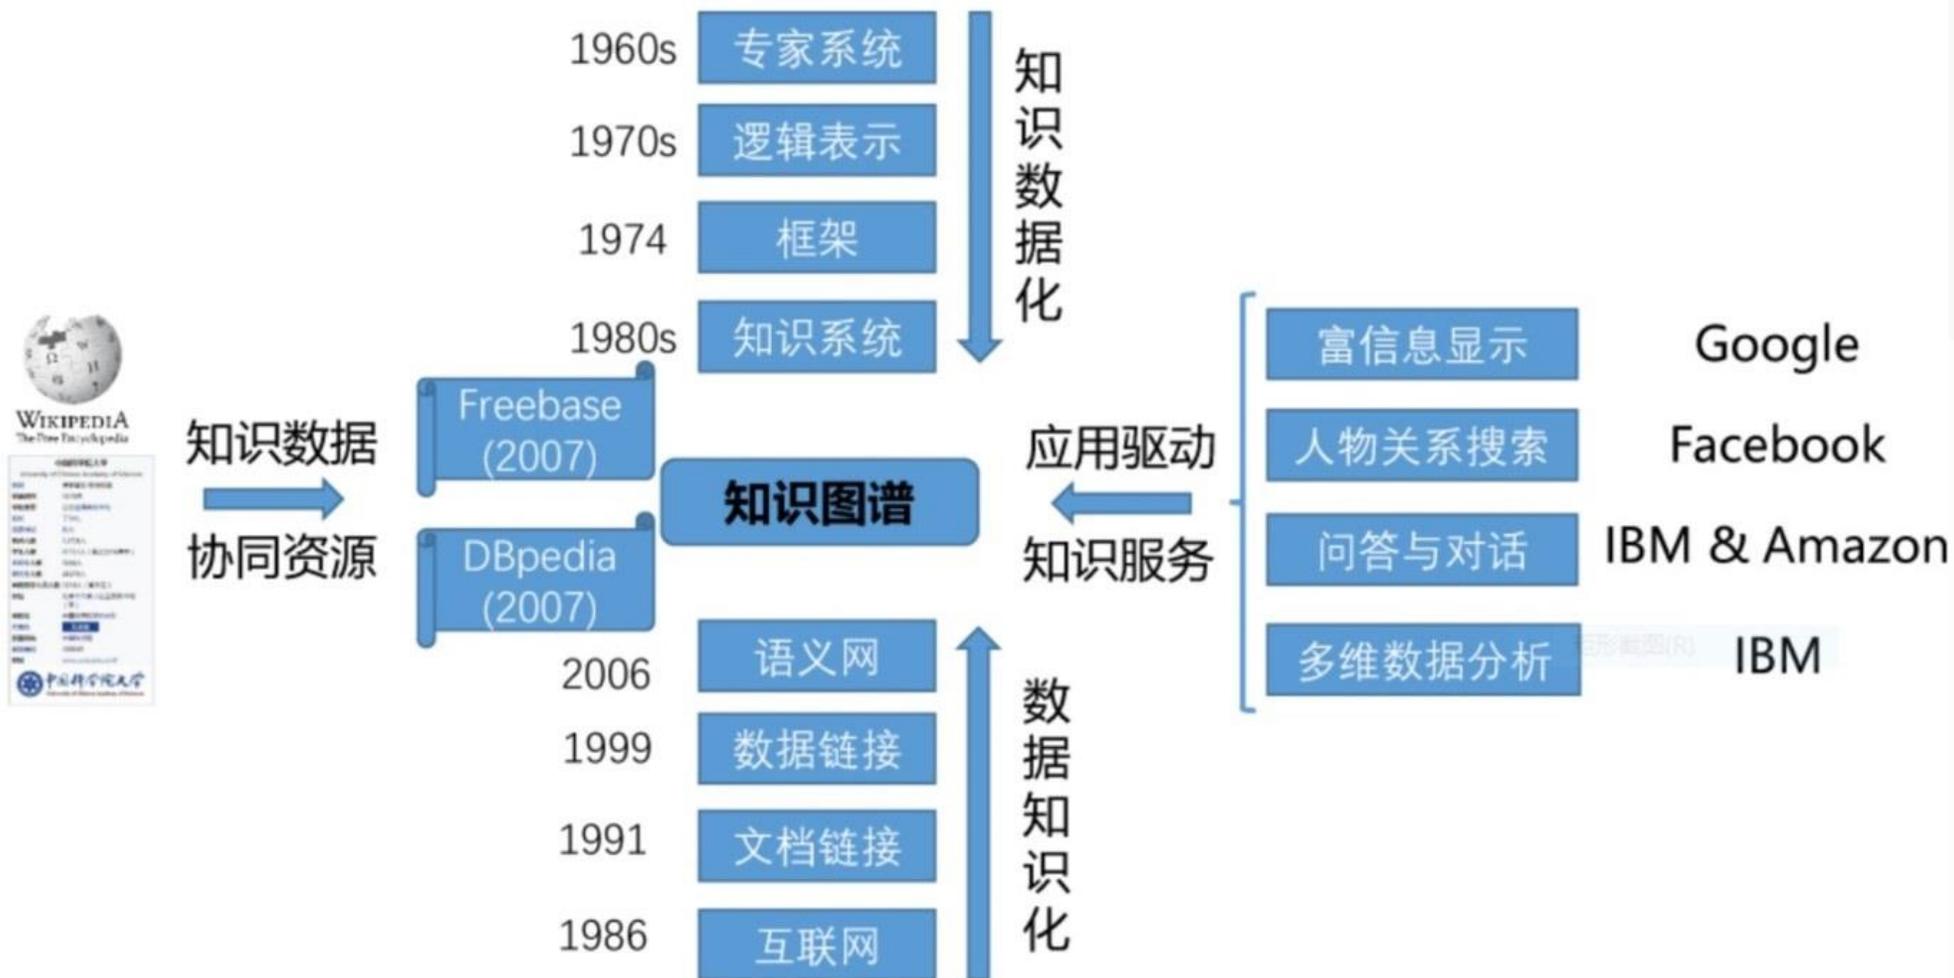


3. 知识图谱的历史

互联网公司知识图谱布局



3. 知识图谱的历史



4. 知识图谱的技术与应用



4. 知识图谱的技术与应用：开源知识图谱

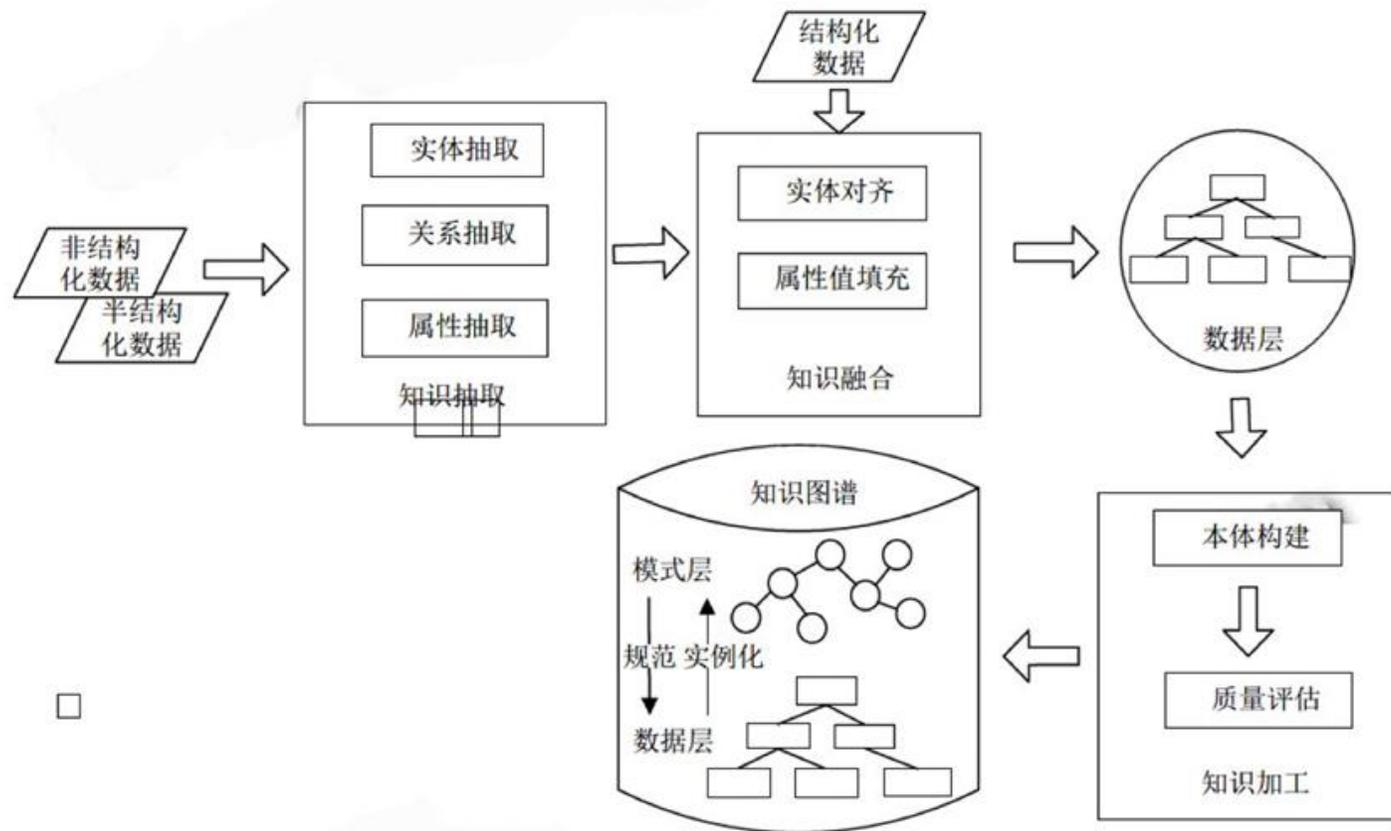
	DBpedia	Freebase	OpenCyc	Wikidata	YAGO
Number of triples	411 885 960	3 124 791 156	2 412 520	748 530 833	1 001 461 792
Number of classes	736	53 092	116 822	302 280	569 751
Number of relations	2819	70 902	18 028	1874	106
No. of unique predicates	60 231	784 977	165	4839	88 736
Number of entities	4 298 433	49 947 799	41 029	18 697 897	5 130 031
Number of instances	20 764 283	115 880 761	242 383	142 213 806	12 291 250
Avg. number of entities per class	5840.3	940.8	0.35	61.9	9.0
No. of unique subjects	31 391 413	125 144 313	261 097	142 278 154	331 806 927
No. of unique non-literals in object position	83 284 634	189 466 866	423 432	101 745 685	17 438 196
No. of unique literals in object position	161 398 382	1 782 723 759	1 081 818	308 144 682	682 313 508



知识抽取与知识融合

PART.02

构建知识图谱——自底向上



自底向上的知识图谱构建流程

知识抽取的概念

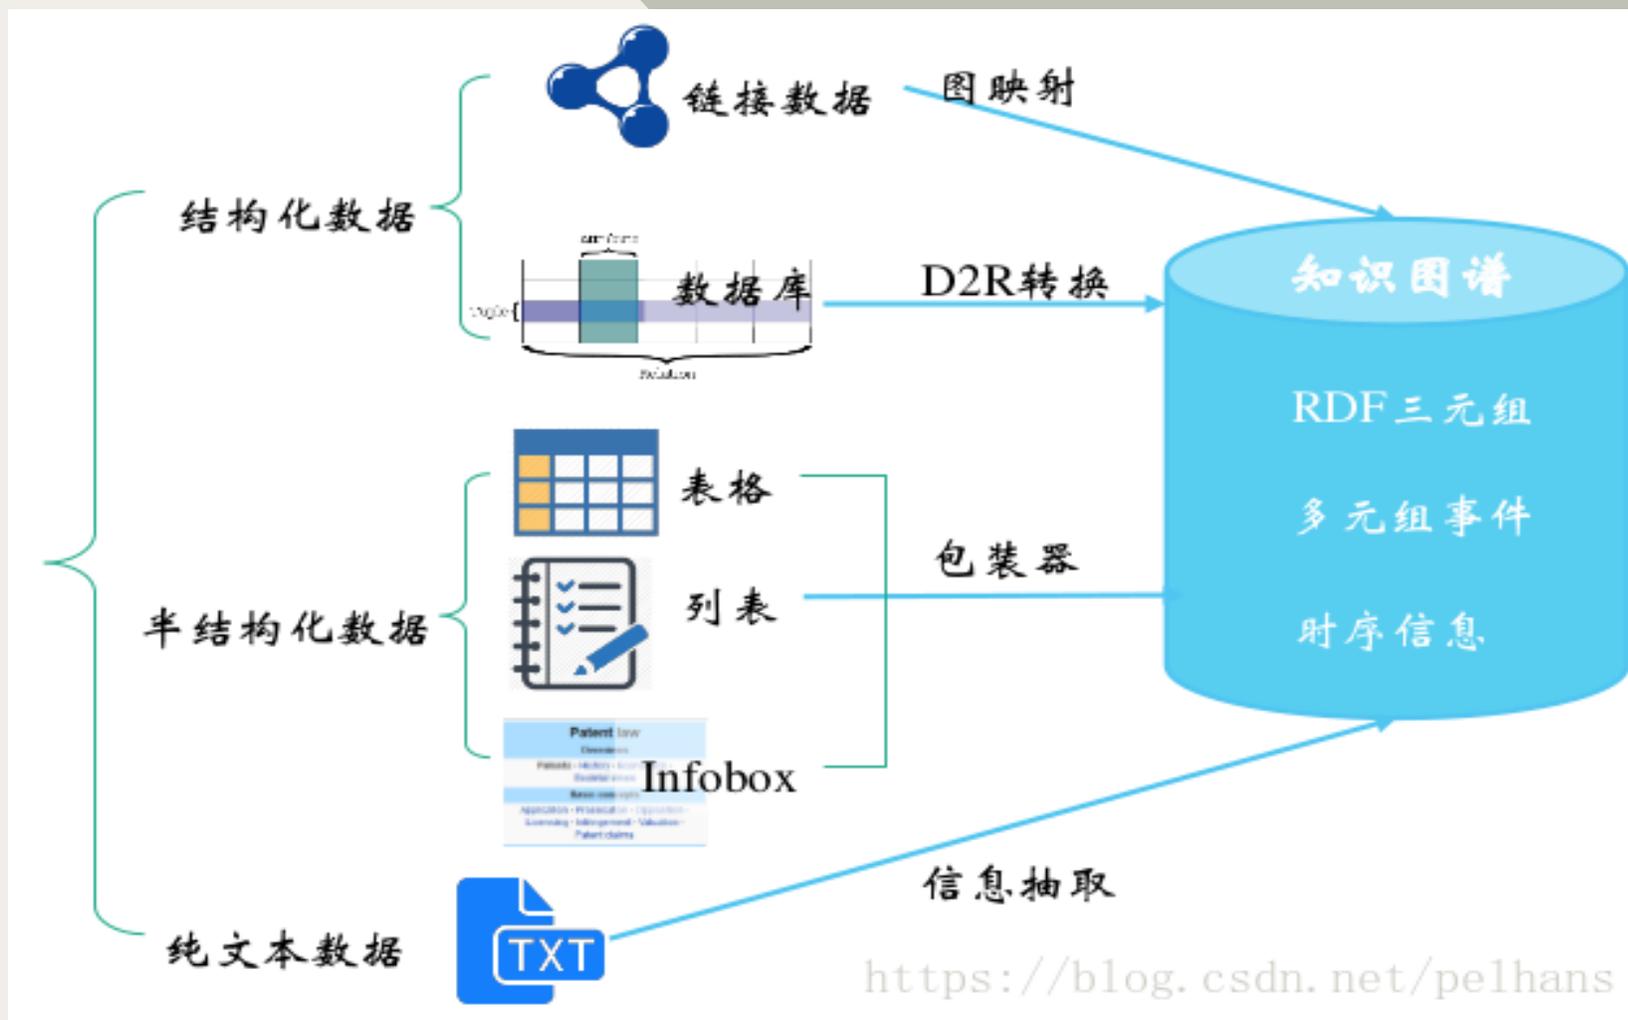
知识抽取是一种自动化地从半结构化和无结构数据中抽取实体、关系以及属性等结构化信息的技术。

在此基础上形成本体化的知识表达。

结构化数据

非结构化数据的不规则性和模糊行为使得使用传统程序难以理解

半结构化数据 非结构化数据



知识抽取的种类

实体抽取

关系抽取

属性抽取

事件抽取

术语抽取

概念抽取

1. 实体抽取（命名体识别）

[京东人工智能开放平台NeuHub](#)

请输入一段需要分析的文本： **随机示例**

据乌克兰国家应急服务中心统计，截至2022年3月4日，哈尔科夫已有39名平民死于冲突，272人受伤。俄乌冲突以来，乌克兰第二大城市哈尔科夫是双方主要争夺目标。

体验版还可以输入 176 字

开始分析

实体	类型
> 哈尔科夫	地址
> 39名	数值
> 272人	数值
> 2022年3月4日	日期
> 乌克兰国家应急服务中心	机构

从文本数据集中自动识别出命名实体，实体抽取地质量（准确率和召回率）对后续的知识获取效率和质量的影响极大，因此是信息抽取中最为基础和关键的部分。

2. 关系抽取

京东人工智能开放平台NeuHub

请输入一段需要分析的文本：[随机示例](#)

截至本公告出具日，经北京市工商行政管理局昌平分局核准并根据企业工商查询信息，[南瑞集团](#)所持有的[普瑞工程100%](#)的股权已过户至[国电南瑞](#)名下，相关工商变更手续已办理完成。

体验版还可以输入 918 字

开始分析

关系头	关系属性	关系尾
> 南瑞集团有限公司	关系：参股 持股比例：100%	中电普瑞电力工程有限公司
> 南瑞集团有限公司	关系：转让 接收方：国电南瑞	中电普瑞电力工程有限公司

普瑞工程是通过京东科技企业知识图谱被标准化为中电普瑞电力工程有限公司

文本语料经过实体抽取，得到的是一系列离散的命名实体，为了得到语义信息，还需要从相关预料中提取出实体之间的关联关系，通过关系将实体（概念）联系起来，才能够形成网状的知识结构。

3. 属性抽取

- 属性抽取的目标是从不同信息源中采集特定实体的属性信息。例如针对某个公众人物，可以从网络公开信息中得到其昵称、生日、国籍等信息。属性抽取技术能够从多种数据来源中汇集这些信息，实现对实体属性的完整勾画。
- 属性抽取较之关系抽取的难点在于，除了要识别实体的属性名还要识别实体的属性值，而属性值结构也是不确定的。因此大多研究都是基于规则进行抽取。
- 由于可以将实体的属性视为实体与属性值之间的一种名词性关系，因此**可以将属性抽取问题视为关系抽取问题。**

关于技术

基于规则的方法

基于统计机器学习的方法

基于深度学习的方法

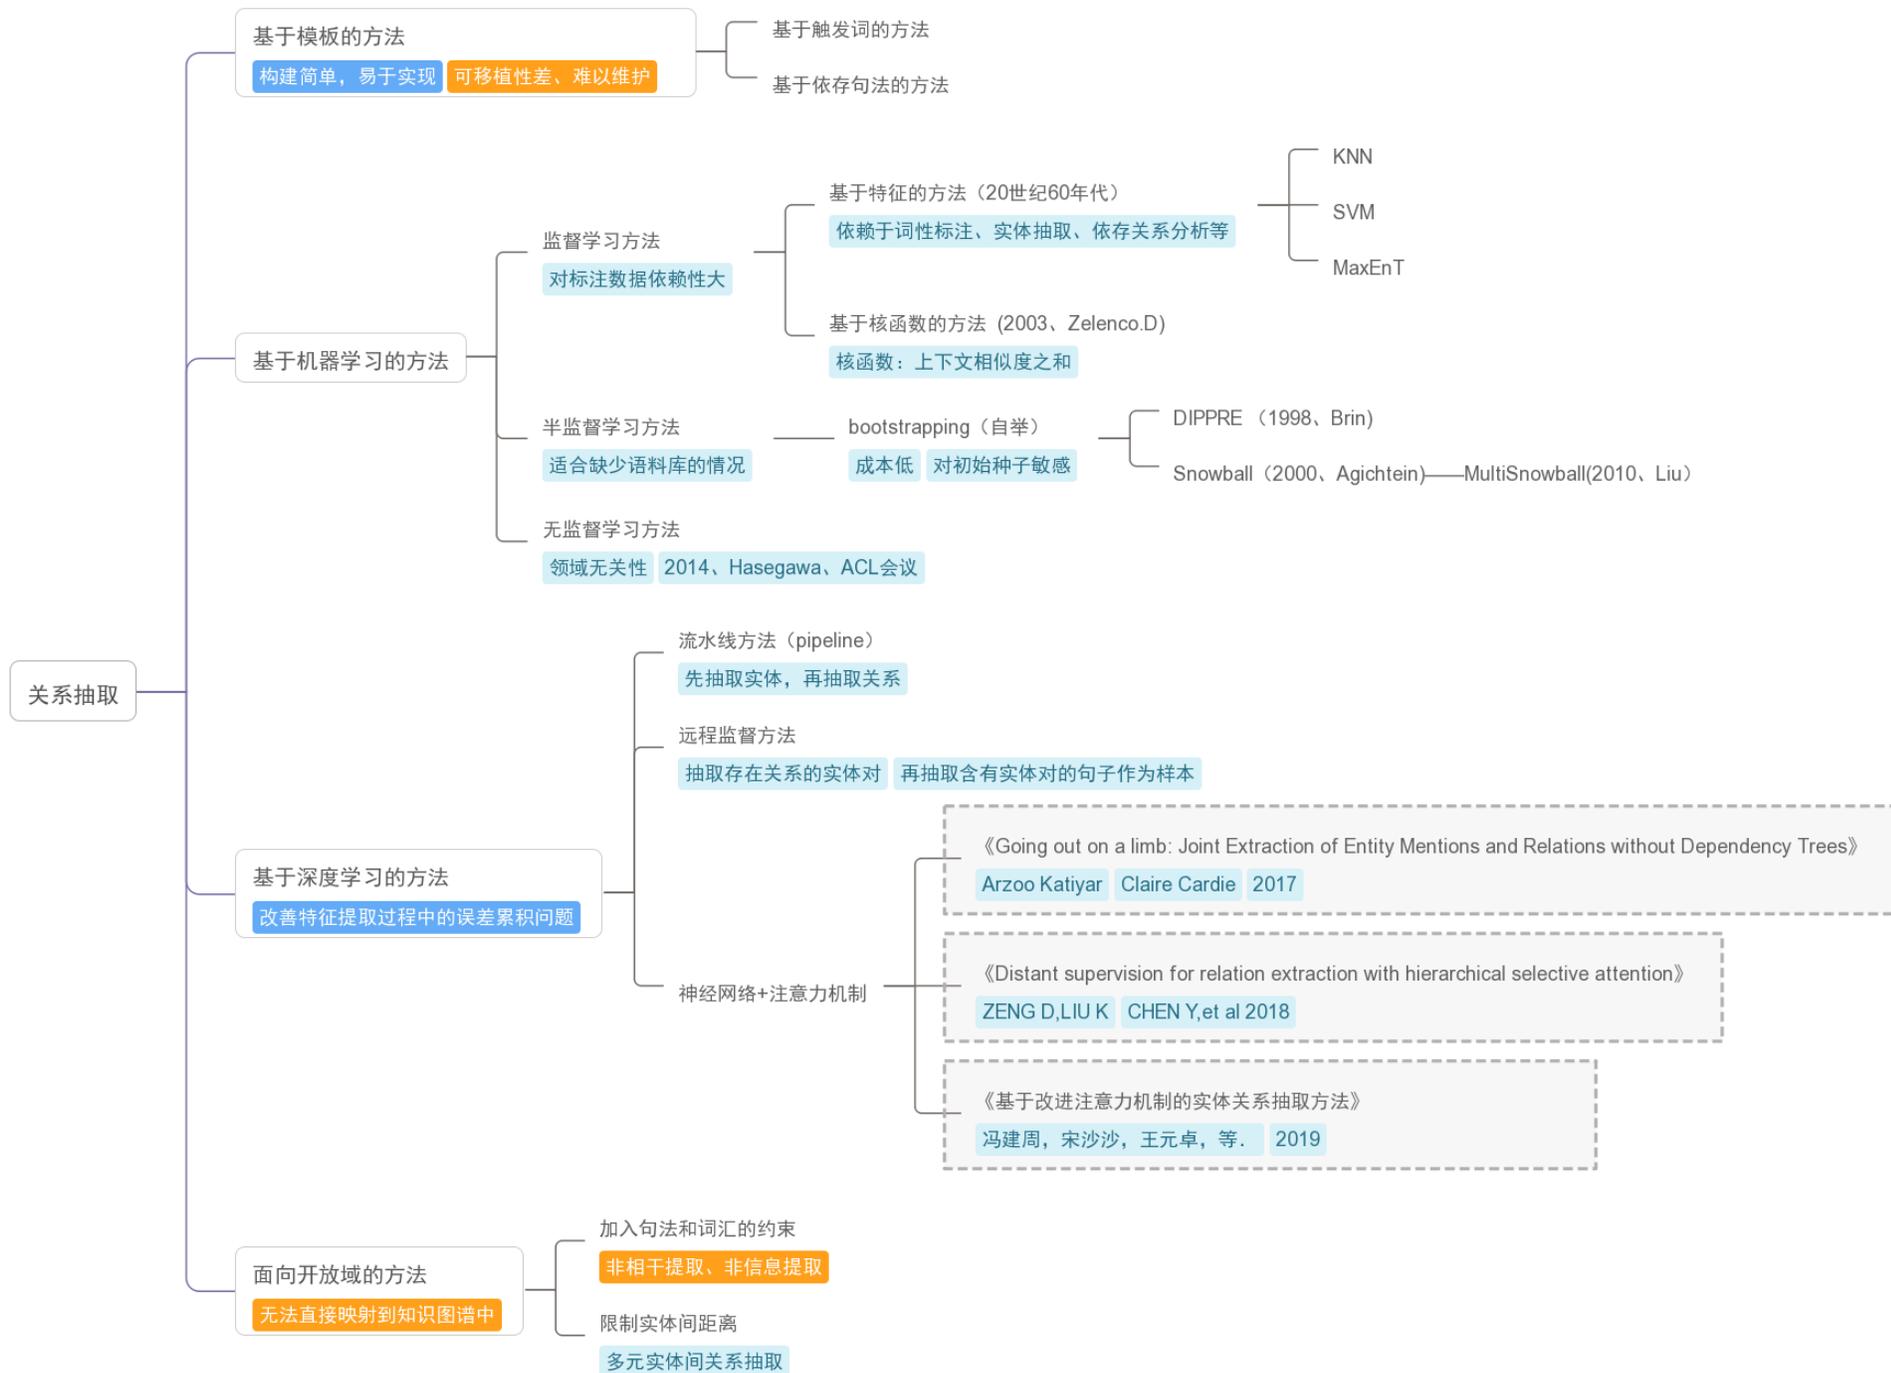


限定域



开放域

技术概览

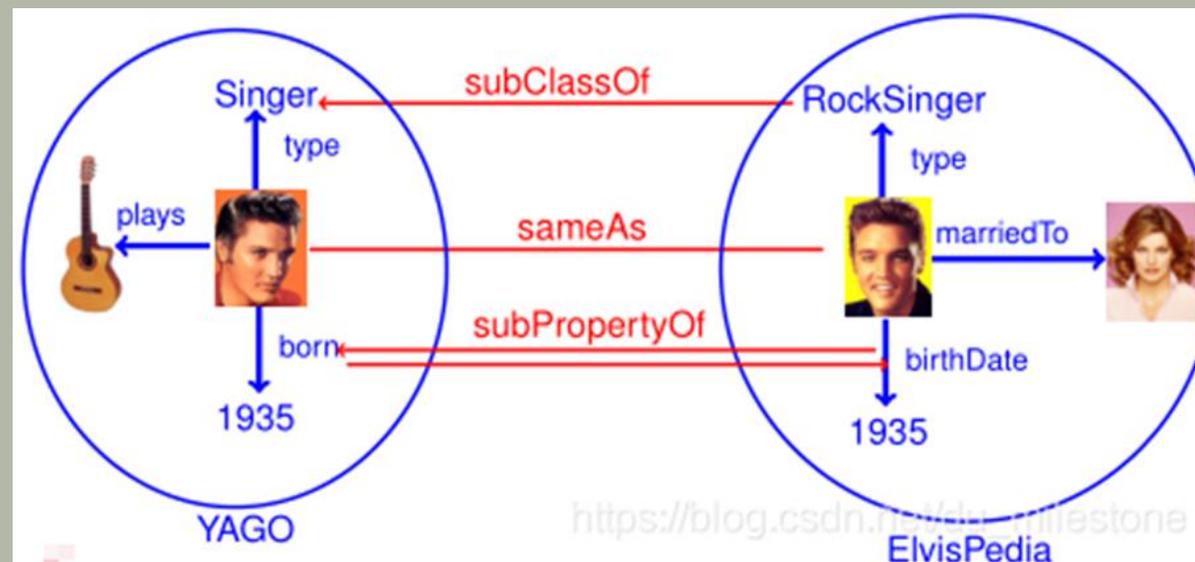


知识融合

知识融合是高层次的知识组合。

可以消除概念的歧义，提出冗余和错误概念，

从而确保知识的质量。



https://blog.csdn.net/du_milestone
将猫王从YAGO和ElvisPedia进行融合的例子

为什么要进行知识融合？

因为异构。

为什么会出现异构？

因为语言和概念层上的不匹配。

数据整合、消歧、加工、
推理验证、更新



数据、信息、方法、经
验以及人的思想的融合

要得到高质量的知识库！

消歧



学术界对该问题有多种不同的表述
实体对齐，本体匹配.....
本质上一样的

聚类、支持向量机、决策树.....
关键：相似性度量
用什么相似性函数？

合并





知识表示、知识存储、 知识推理

PART.03

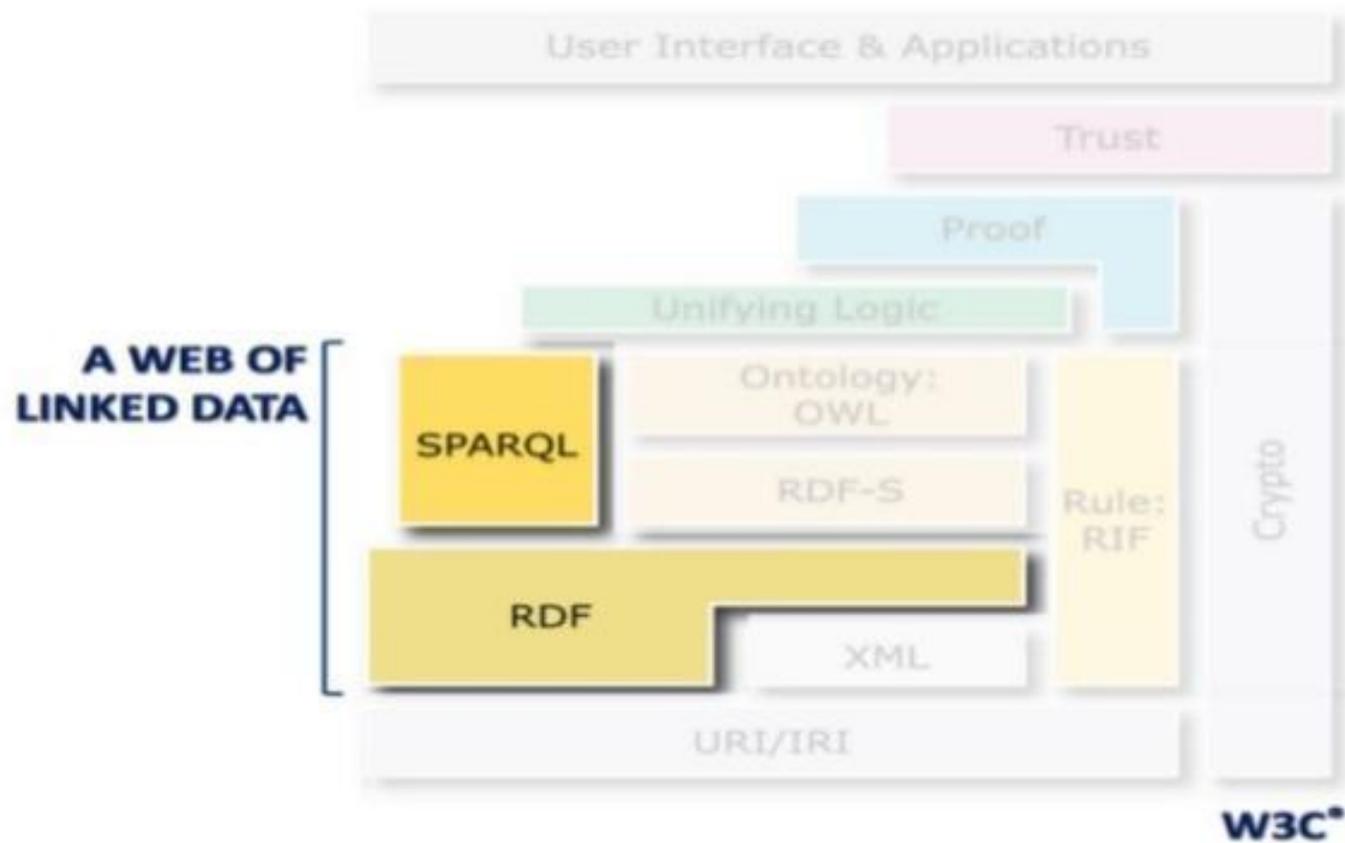
知识表示的概念

知识表示就是对知识的一种描述，或者说是对知识的一组约定，一种计算机可以接受的用于描述知识的数据结构。它是机器通往智能的基础，使得机器可以像人一样运用知识。

早期的知识表示方法：

- 一阶谓词逻辑
- 产生式系统
- 框架表示法
- 语义网络

基于语义网的知识表示框架

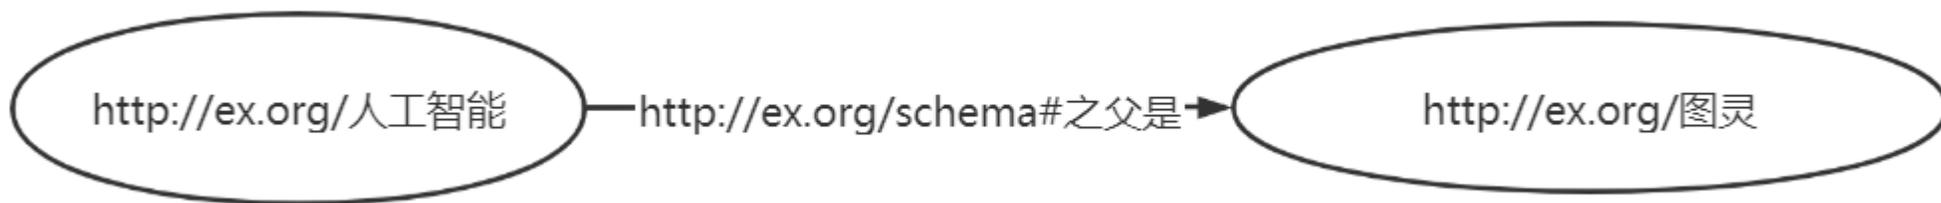


RDF (资源描述框架)

- R: 页面, 图片、视频等任何具有URI标识符的资源
- D: 标识属性、特征和资源之间的关系
- F: 标识模型、语言和这些描述的语法。

在RDF中, 知识总是以三元组的形式出现, 即每一份知识都可以被分解为: (subject, predicate, object)。

与此同时, RDF三元组可以看做是图模型的边和顶点 (vertex, edge, vertex)。



RDF和RDFS

RDFS(RDF Schema)在RDF的基础上提供了一个术语、概念的定义方式，以及那些属性可以应用到哪些对象上。换句话说，RDFS为RDF模型提供了一个基本的类型系统。

RDFS支持推理功能

谷歌 **rdf:type** 人工智能公司



人工智能公司 **rdfs:subclass** 高科技公司



谷歌 **rdf:type** 高科技公司

SPARQL

```
# prefix declarations
PREFIX foo: <http://example.com/resources/>
...
# dataset definition
FROM ...
# result
                                clause

SELECT ...
# query pattern
WHERE {
    ...
}
# query modifiers
ORDER BY ...
```



SPARQL是RDF的查询语言，它基于RDF数据模型，可以对不同的数据集撰写复杂的连接，同时还被所有主流的图数据库支持。

SPARQL与SQL的主要区别



```
SELECT ?student ?email
WHERE {
    ?student exp:studies exp:CS328 .
    OPTIONAL {
        ?student foaf:mbox ?email .
    }
}
```

知识存储的概念

知识存储，即获取到的三元组如何存储在计算机中。目前业内存储知识的方式有三种，第一种为三元组形式的RDF存储；第二种为传统关系型数据库存储；第三种为图数据库存储。

一个 RDF 数据集由一组相关的三元组的组成。由于这个三元组集合可以抽象为一张 graph，因此也称为 RDF graph。

图数据库

高性能

图模型固有的数据索引结构，使得它的数据查询与分析速度更快。

灵活

使用者可以根据业务变化随时调整数据模型。



敏捷

图数据库的图模型非常直观，支持测试驱动开发模式。

简便

很多图数据库提供了专业的分析算法、工具。

目前主流的图数据库有：Neo4j, Janusgraph, Dgraph, Giraph, TigerGraph等。

知识推理的概念

所谓的知识推理，就是在已有知识的基础之上，推断出未知的知识的过程。通过已经获取的知识，得到所蕴含的新的事实，或者从大量的已有知识中归纳，从个体知识推广到一般性的知识。

针对知识图谱特有的三元组存储形式,面向知识图谱的知识推理被定义为对三元组缺失部分的预测,更主要的是对实体和关系进行的预测,一般在<实体关系-实体>三元组中进行。

知识推理的分类

面向知识图谱
的知识推理

基于图结构和统计规则挖掘的推理

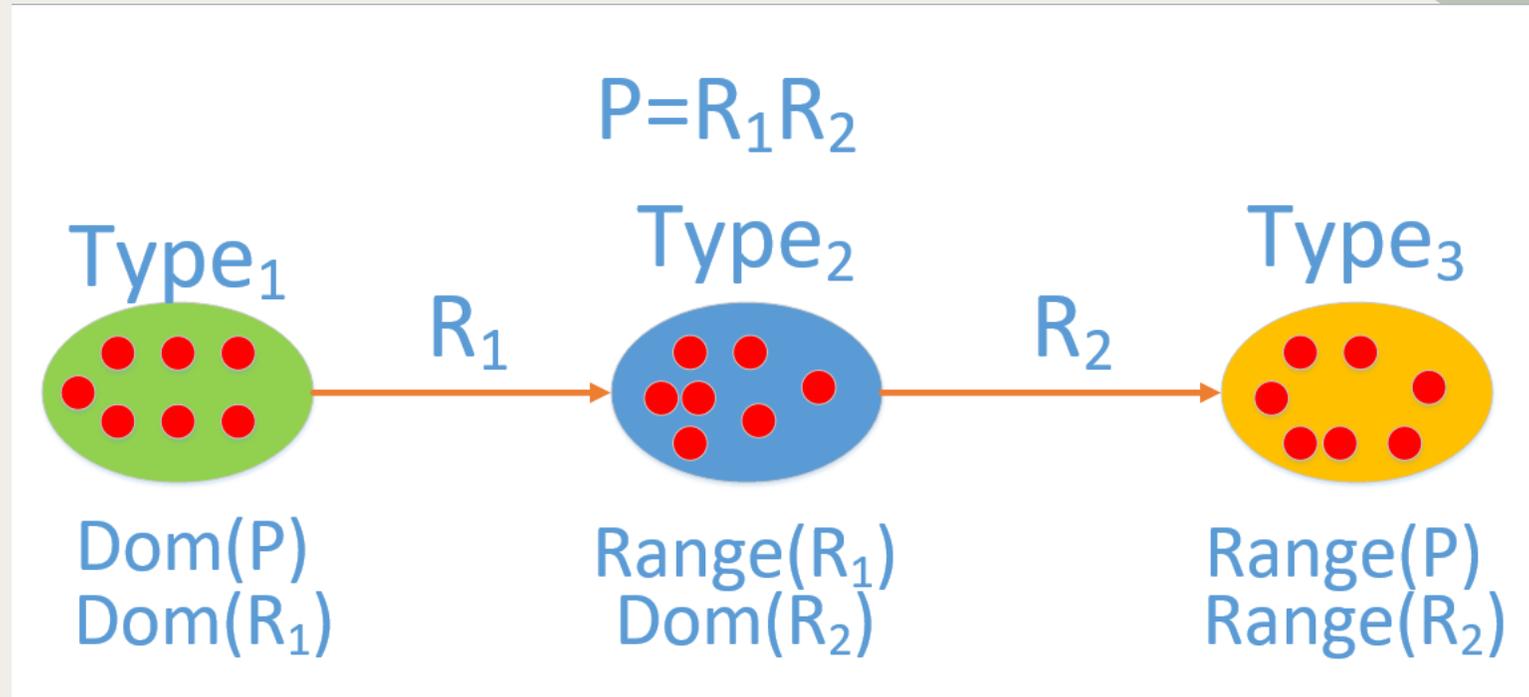
基于知识图谱表示学习的推理

基于神经网络的推理

混合推理

基于图结构和统计规则挖掘的推理

PRA: 路径排序算法

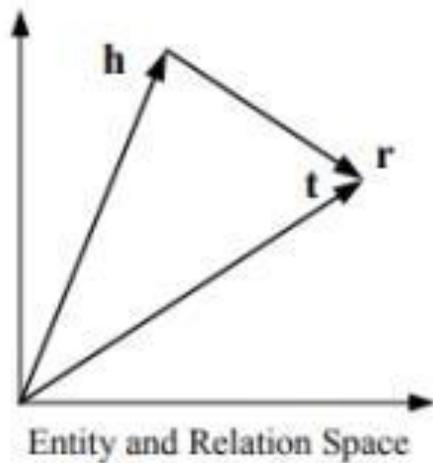


优点：可解释性强，能够自动发现推理规则

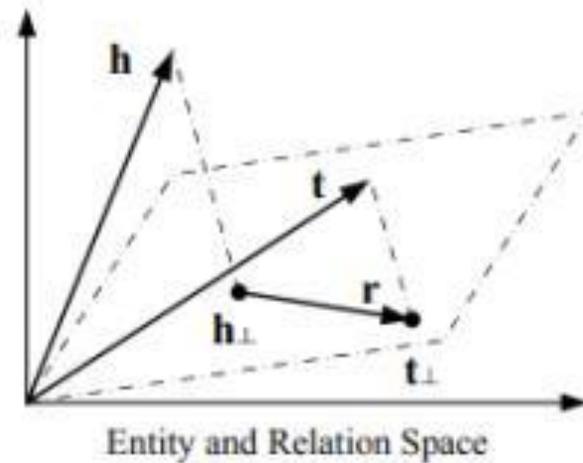
缺点：1. 处理低频关系效果差 2. 处理低连通图效果差 3. 图较大时处理速度慢

基于知识图谱表示学习的推理

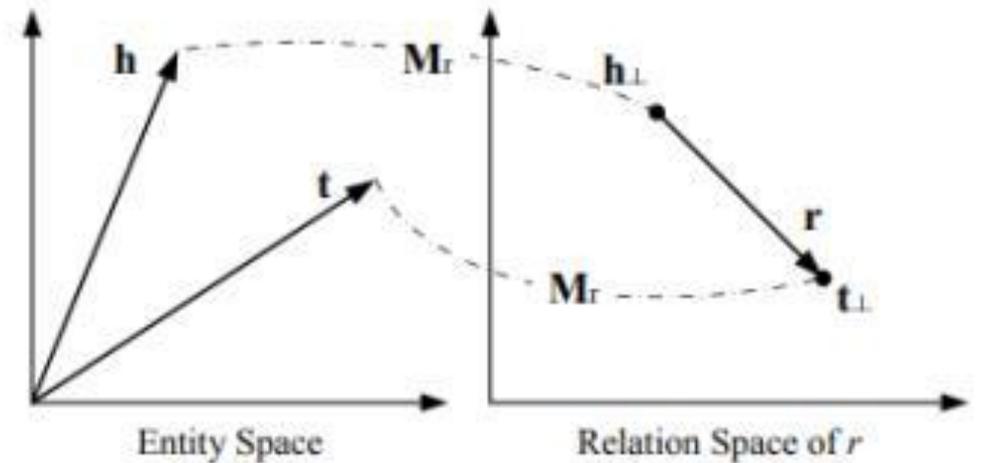
Trans 系列



(a) TransE.



(b) TransH.



(c) TransR.

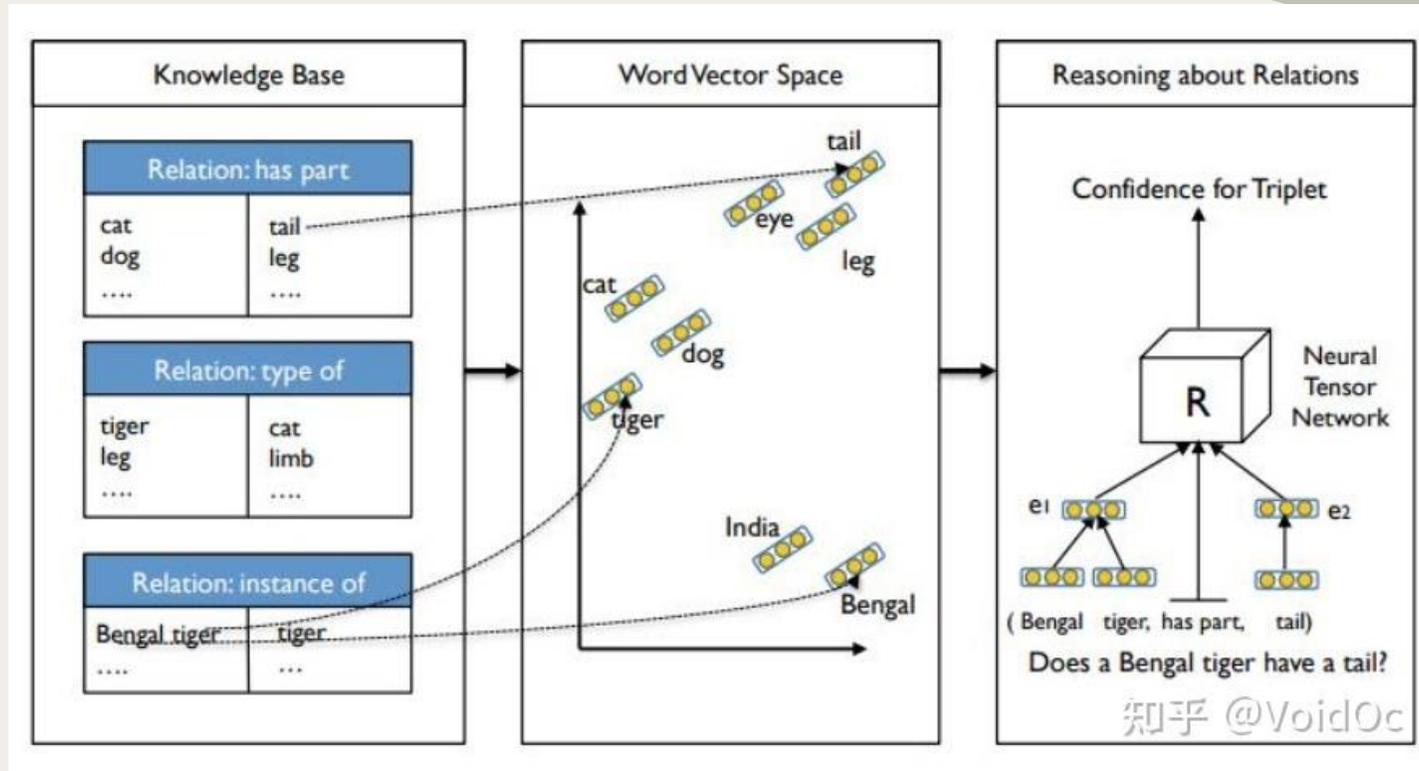
Trans E: 适合处理一对一的关系

Trans H: 适合处理多对多的关系

Trans R: 每个实体包含不同方面

基于神经网络的推理

NTN



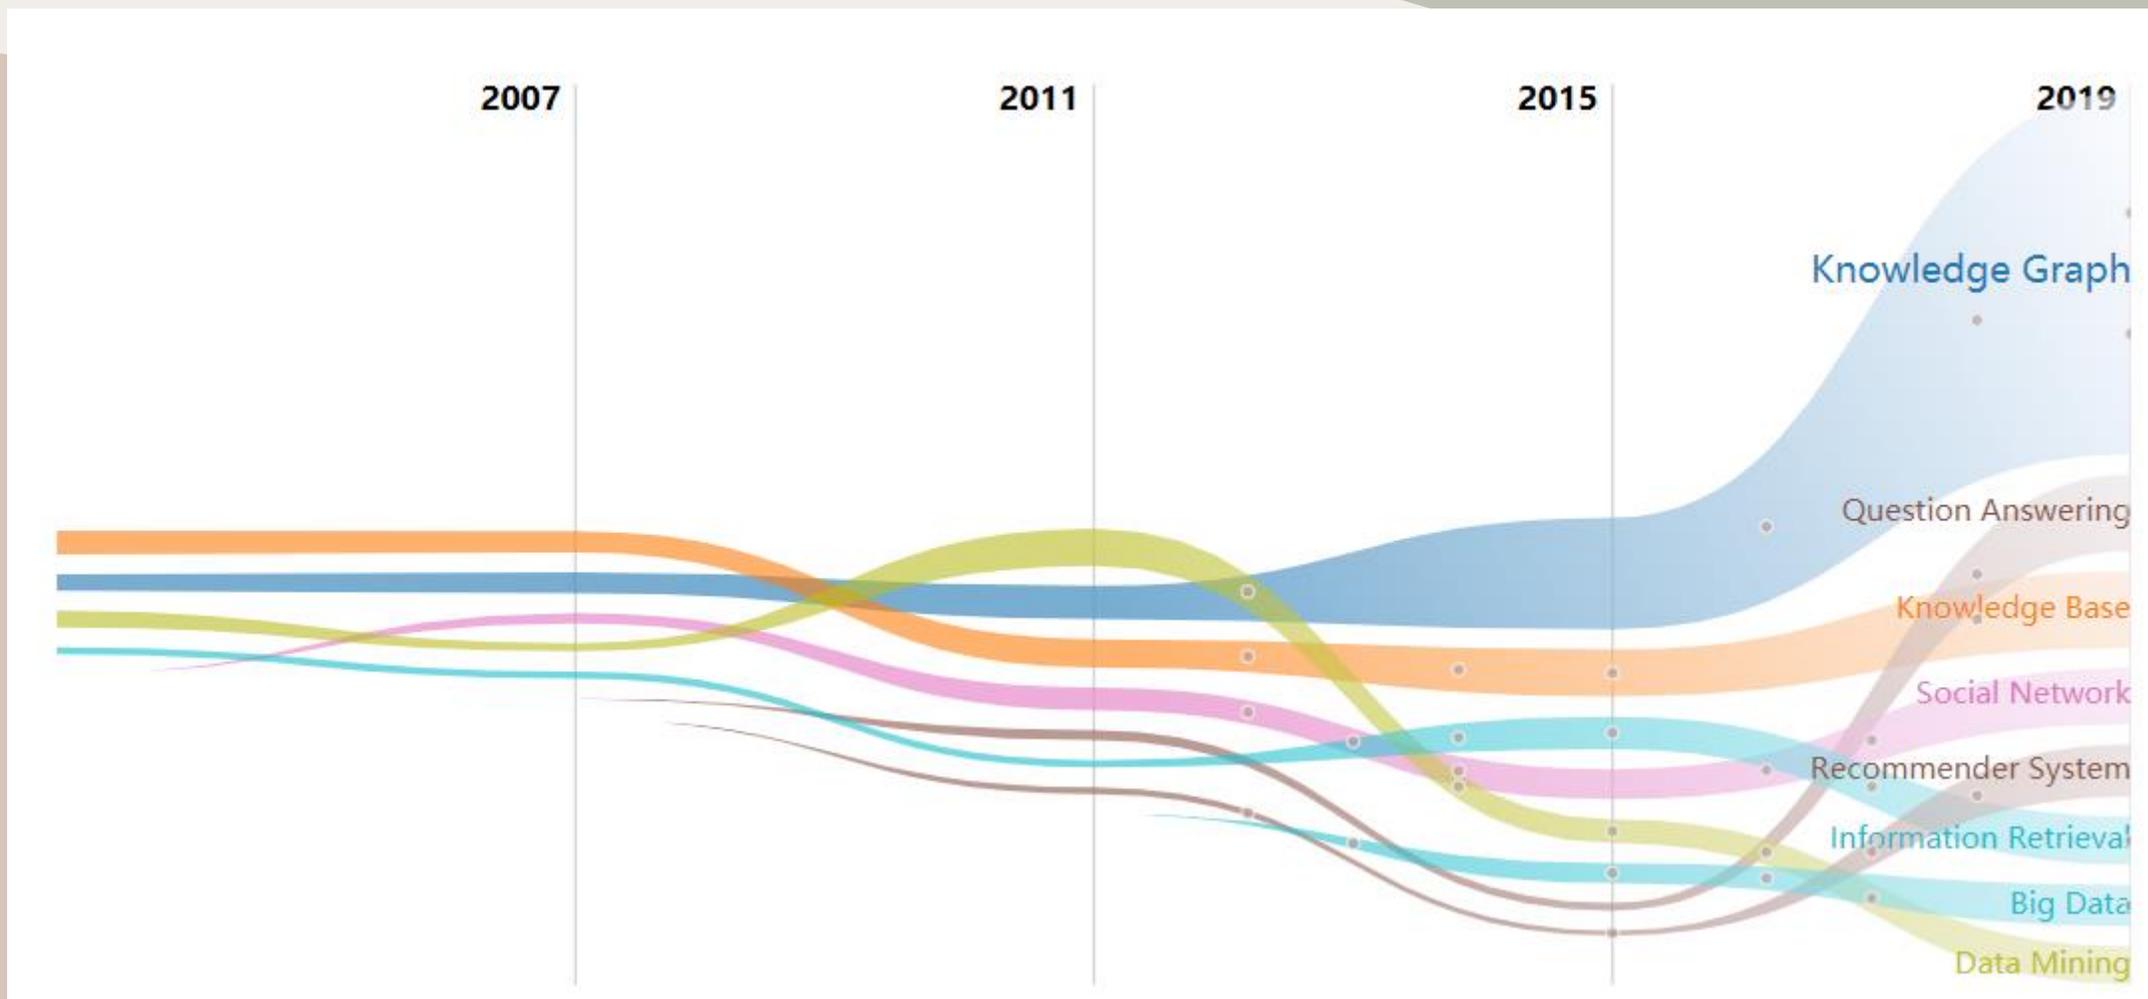
优点：实体中的单词数量远小于实体数量，可以重复利用单词向量构建实体表示
缺点：复杂度非常高在大规模稀疏知识图谱上的效果较差

前沿进展

PART.04



知识图谱及其子领域研究趋势



前沿工作：从顶会论文中发掘热点

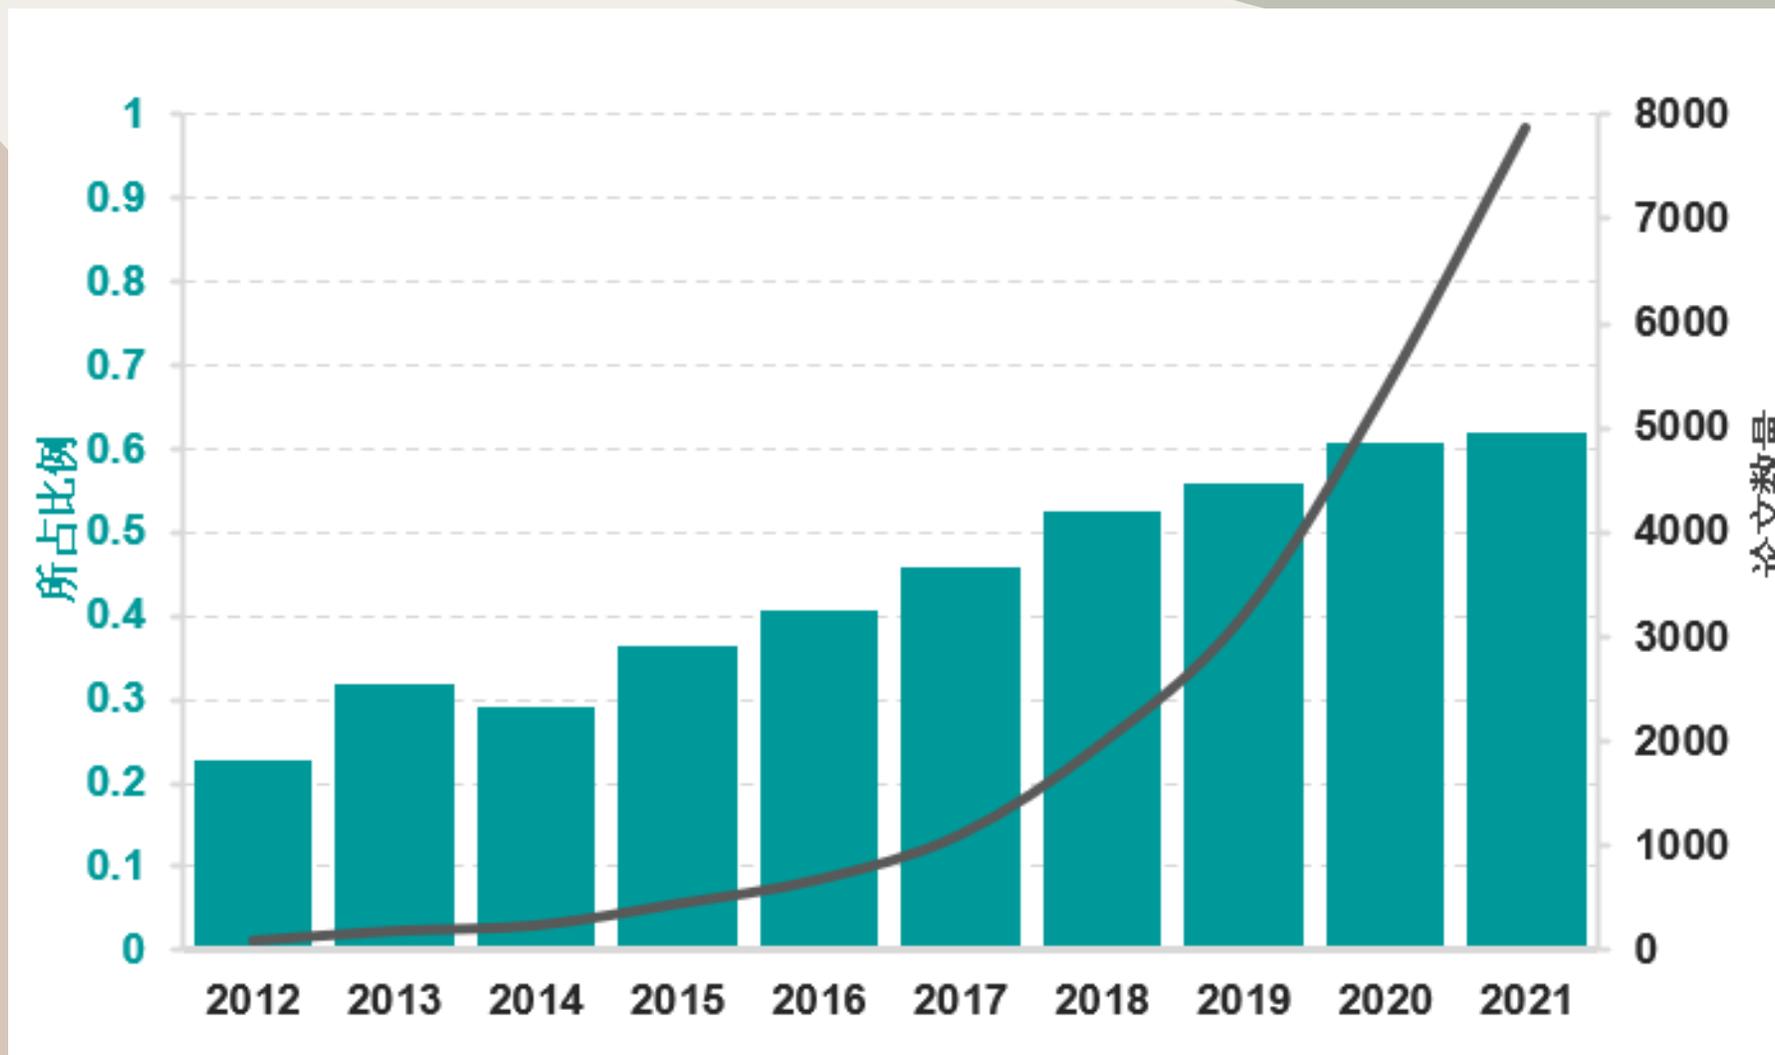
- 人工智能
- AAAI
- IJCAI
- 自然语言处理
- EMNLP
- ACL
- 学习表征
- ICLR
- 数据挖掘
- ICDM
- KDD

Publications in ACL2020 Groupd by Tracks

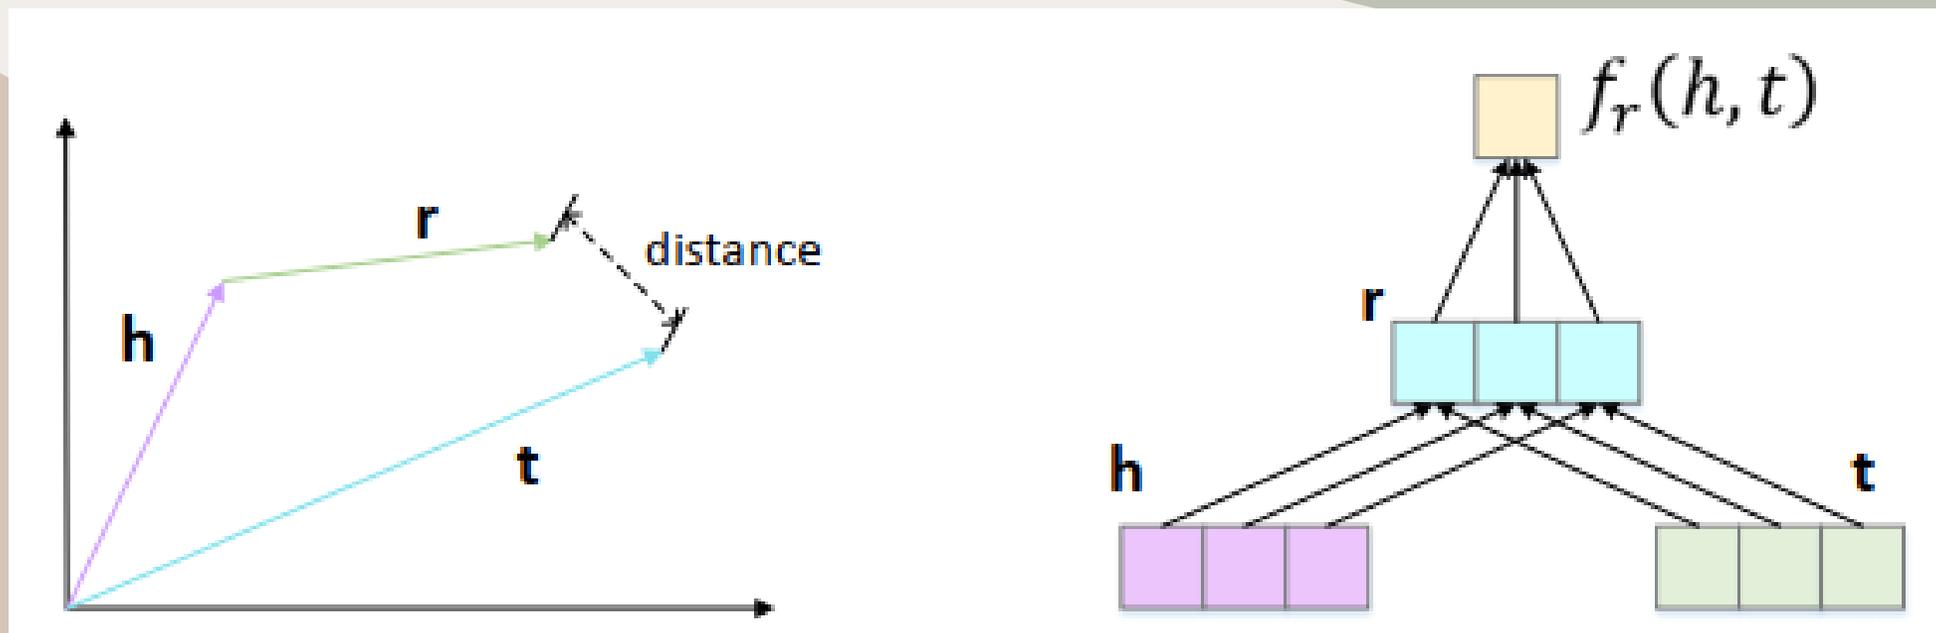
Name Entity Recognition

- [Named Entity Recognition without Labelled Data: A Weak Supervision Approach](#)
- [Improving Multimodal Named Entity Recognition via Entity Span Detection with Unified Multimodal Transformer](#)
- [Code and Named Entity Recognition in StackOverflow](#)
- [A Unified MRC Framework for Named Entity Recognition](#)
- [An Effective Transition-based Model for Discontinuous NER](#)
- [Improving Low-Resource Named Entity Recognition using Joint Sentence and Token Labeling](#)
- [Multi-Cell Compositional LSTM for NER Domain Adaptation](#)
- [Pyramid: A Layered Model for Nested Named Entity Recognition](#)
- [Simplify the Usage of Lexicon in Chinese NER](#)
- [Bipartite Flat-Graph Network for Nested Named Entity Recognition](#)
- [Connecting Embeddings for Knowledge Graph Entity Typing](#)
- [Named Entity Recognition as Dependency Parsing](#)
- [Neighborhood Matching Network for Entity Alignment](#)
- [Single-/Multi-Source Cross-Lingual NER via Teacher-Student Learning on Unlabeled Data in Target Language](#)
- [FLAT: Chinese NER Using Flat-Lattice Transformer](#)

Embedding: 从离散的符号化知识表示到连续的向量知识表示



Embedding: 从离散的符号化知识表示到连续的向量知识表示



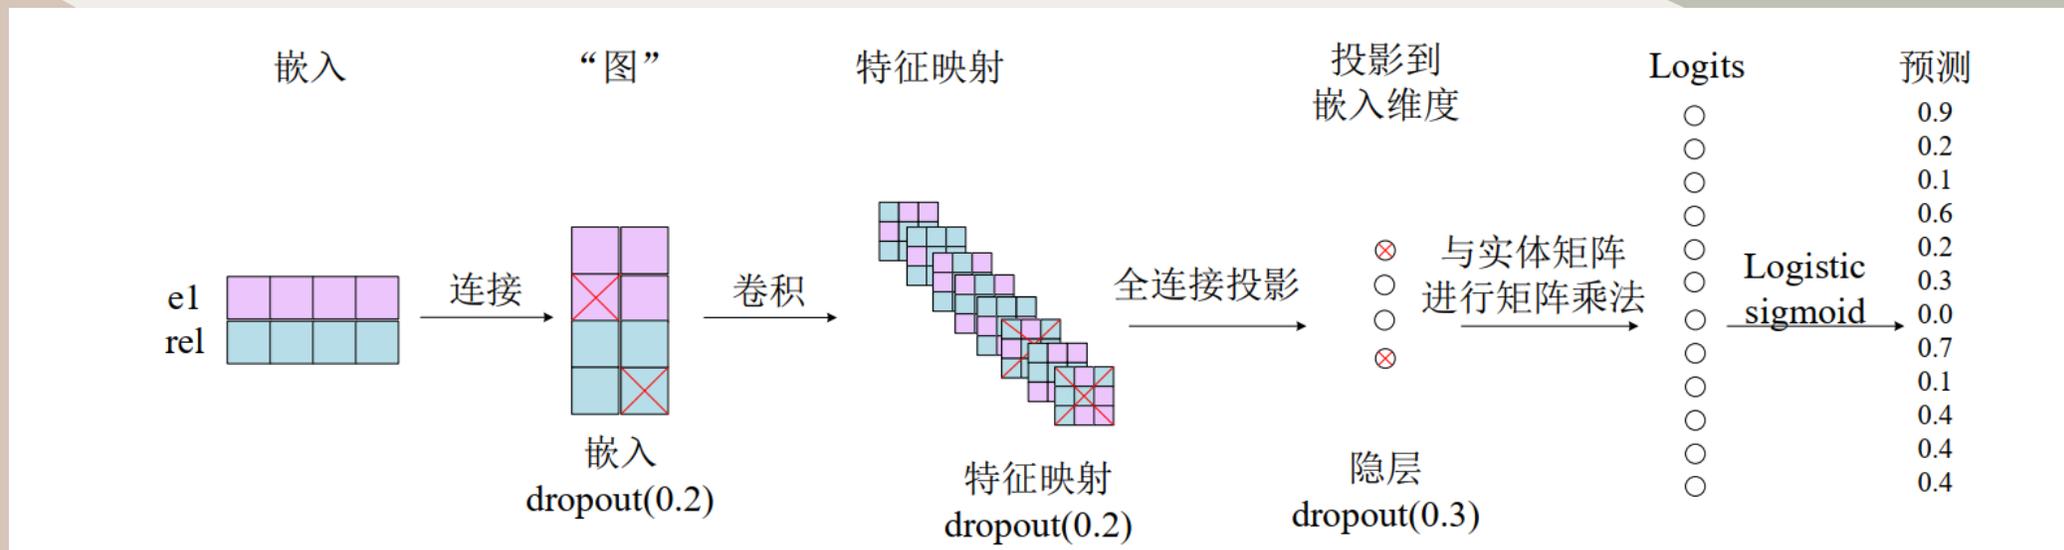
基于平移距离的TransE评分

基于语义相似度的DisMult评分

Antoine Bordes, Nicolas Usunier, Alberto García-Durán, Jason Weston, Oksana Yakhnenko. Translating Embeddings for Modeling Multi-relational Data. In: Proc. of the 27th Neural Information Processing Systems(NIPS). Lake Tahoe: Neural information processing systems foundation, 2013. 2787-2795.

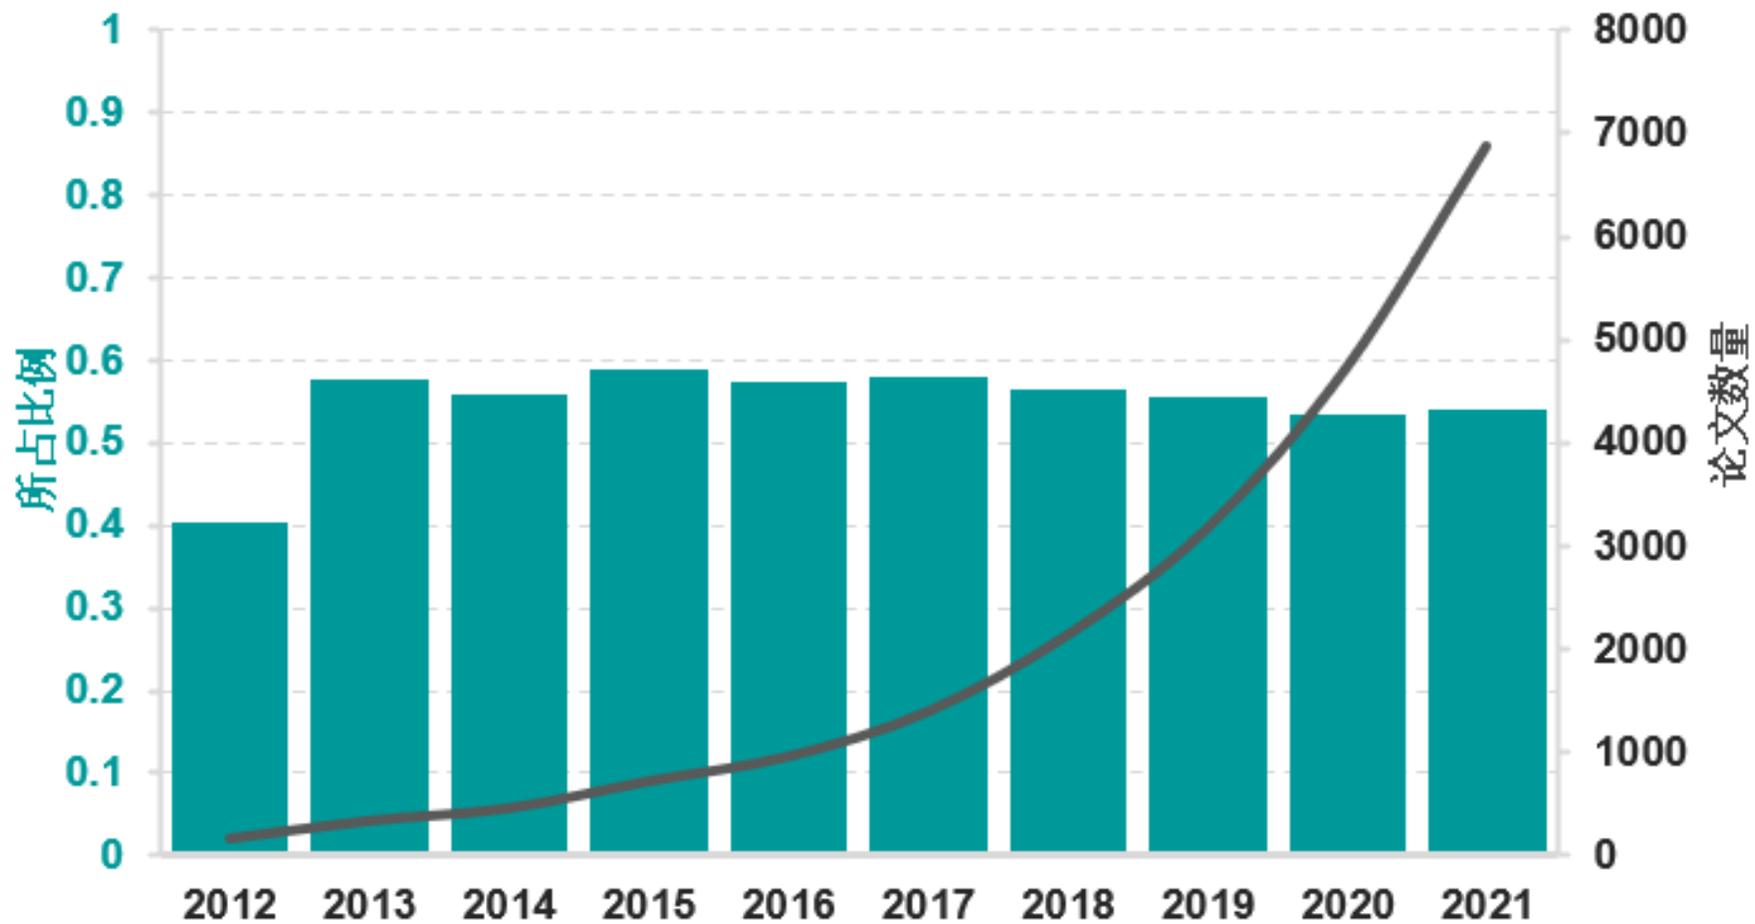
Bishan Yang, Wen-tau Yih, Xiaodong He, Jianfeng Gao, Li Deng. Embedding Entities and Relations for Learning and Inference in Knowledge Bases. In: Proc. of the 3th International Conference on Learning Representations(ICLR). San Diego: International Conference on Learning Representations, 2015.

Embedding: 从离散的符号化知识表示到连续的向量知识表示



convE: 卷积的应用

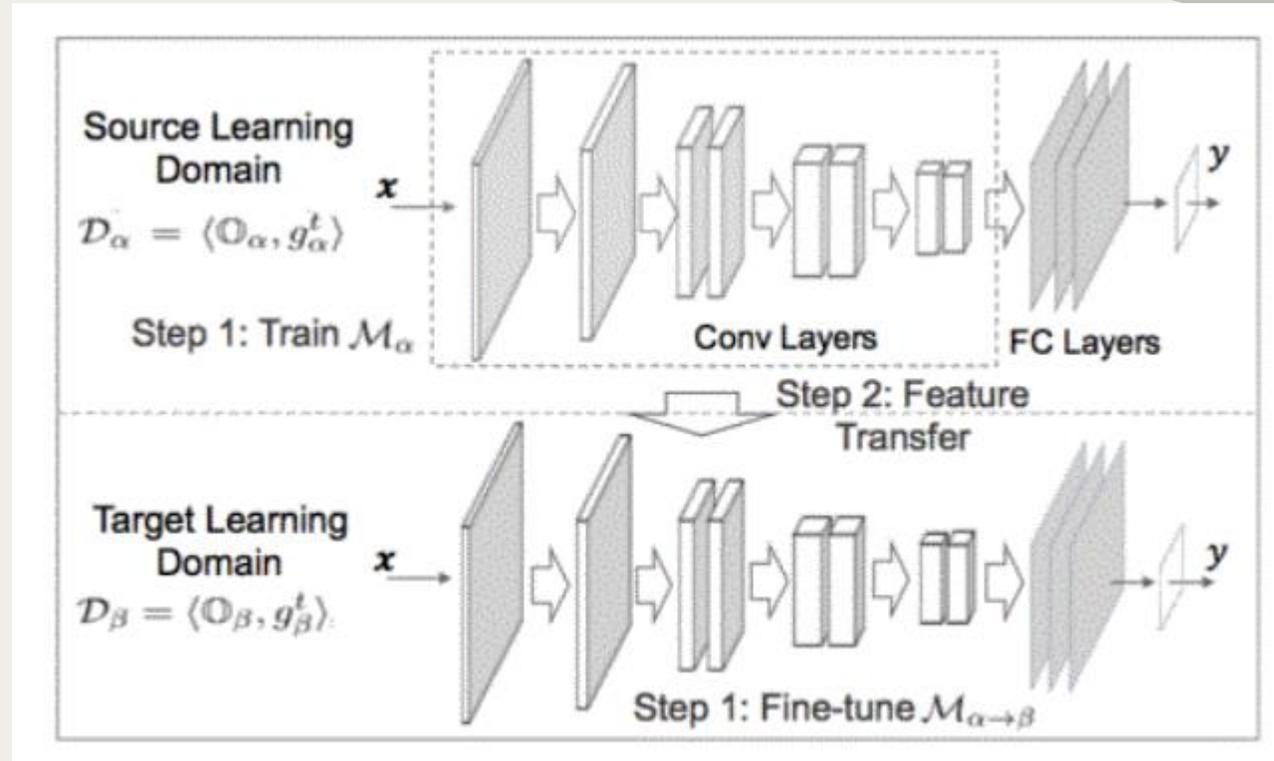
Explainable: 黑盒的曙光



Explainable: 黑盒的曙光

可解释性：将知识图谱作为先验知识融入深度学习模型，提升模型可解释性

ITransF



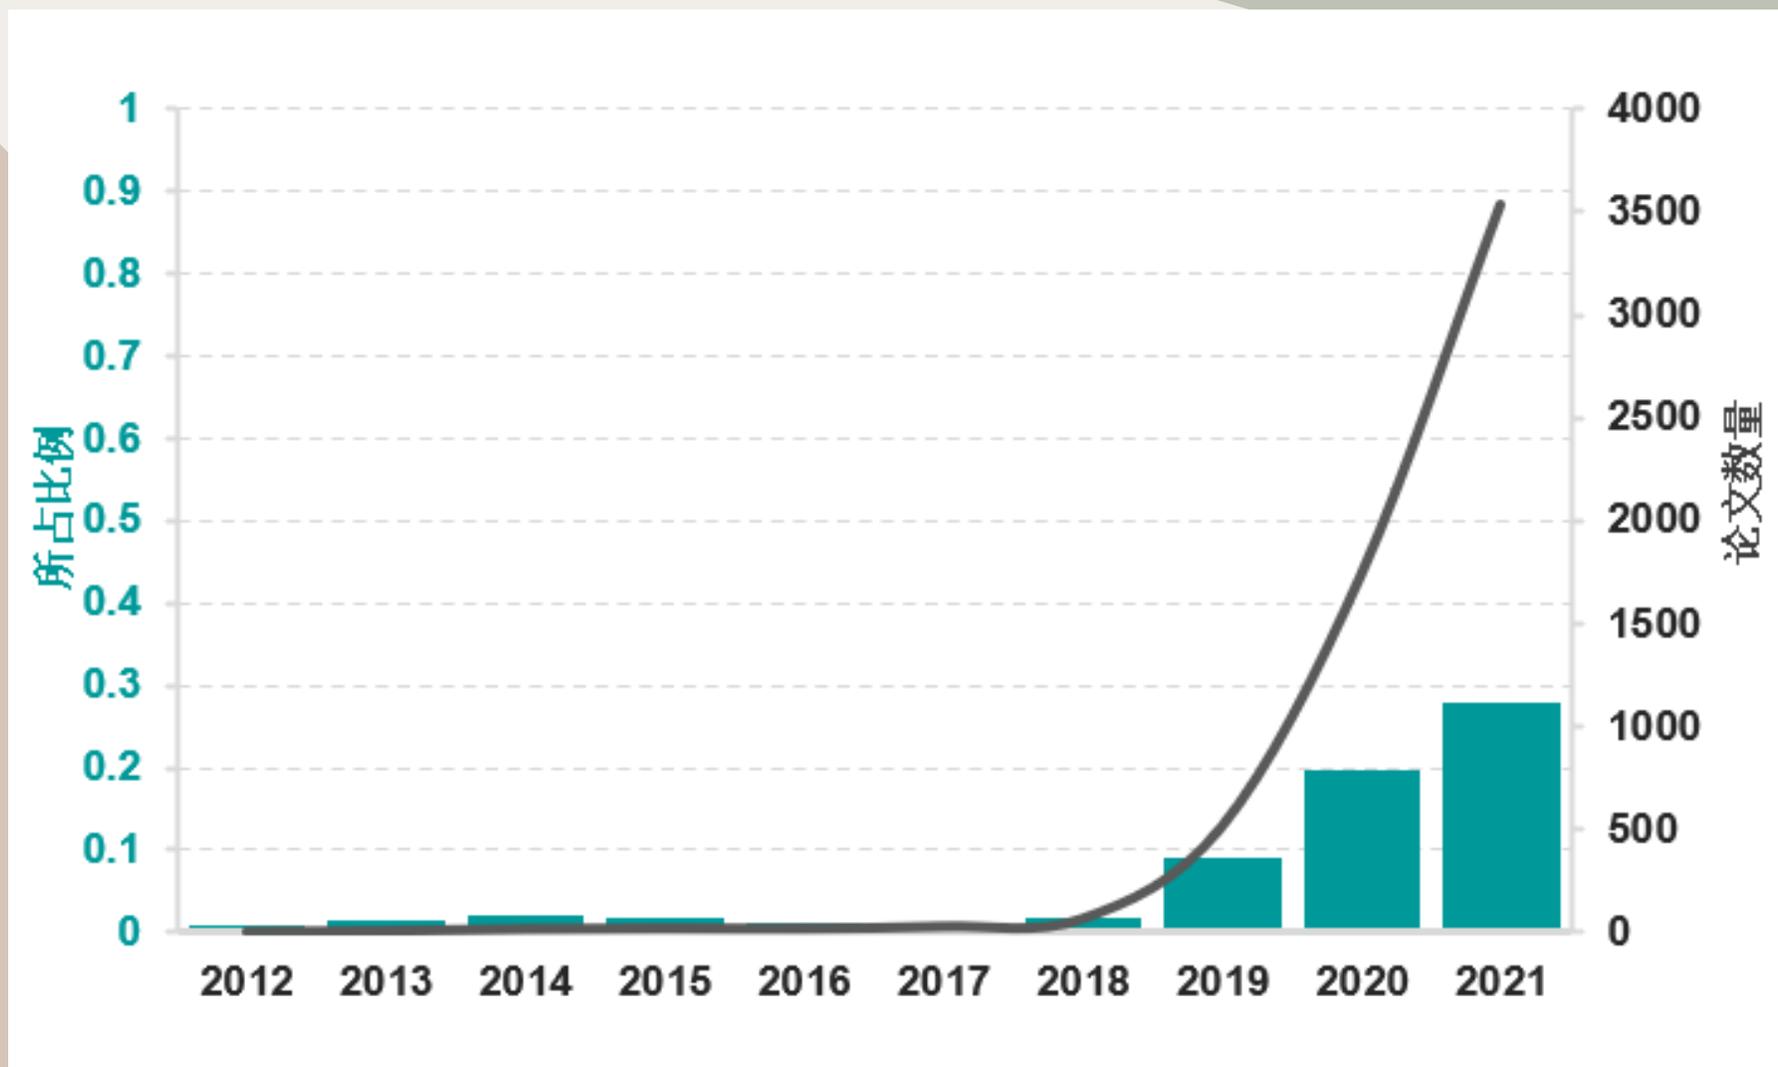
CrossE

可解释的AI: Explainable AI (XAI)

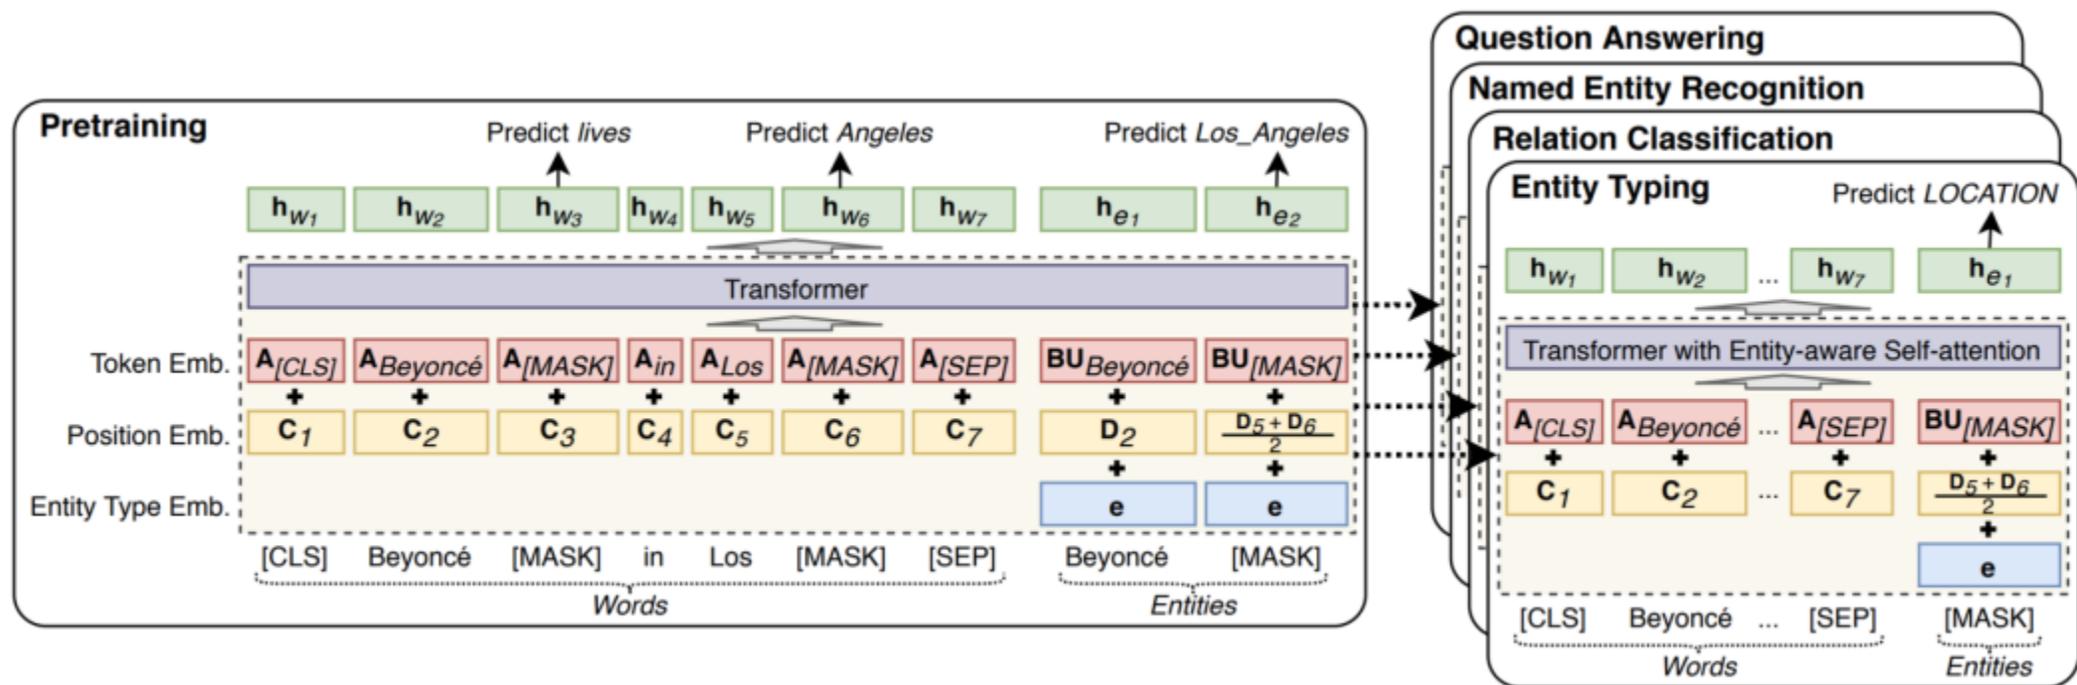
Qizhe Xie, Xuezhe Ma, Zihang Dai, Eduard H. Hovy. An Interpretable Knowledge Transfer Model for Knowledge Base Completion. In: Proc. of the 55th Conference of Association for Computational Linguistics(ACL). Vancouver: Association for Computational Linguistics (ACL), 2017. 950-962.

Wen Zhang, Bibek Paudel, Wei Zhang, Abraham Bernstein, Huajun Chen. Interaction Embeddings for Prediction and Explanation in Knowledge Graphs. In: Proc. of the 12th ACM International Conference on Web Search and Data Mining(WSDM). New York: Association for Computing Machinery, 2019. 96-104.

Transformer: 知识图谱增强语言模型



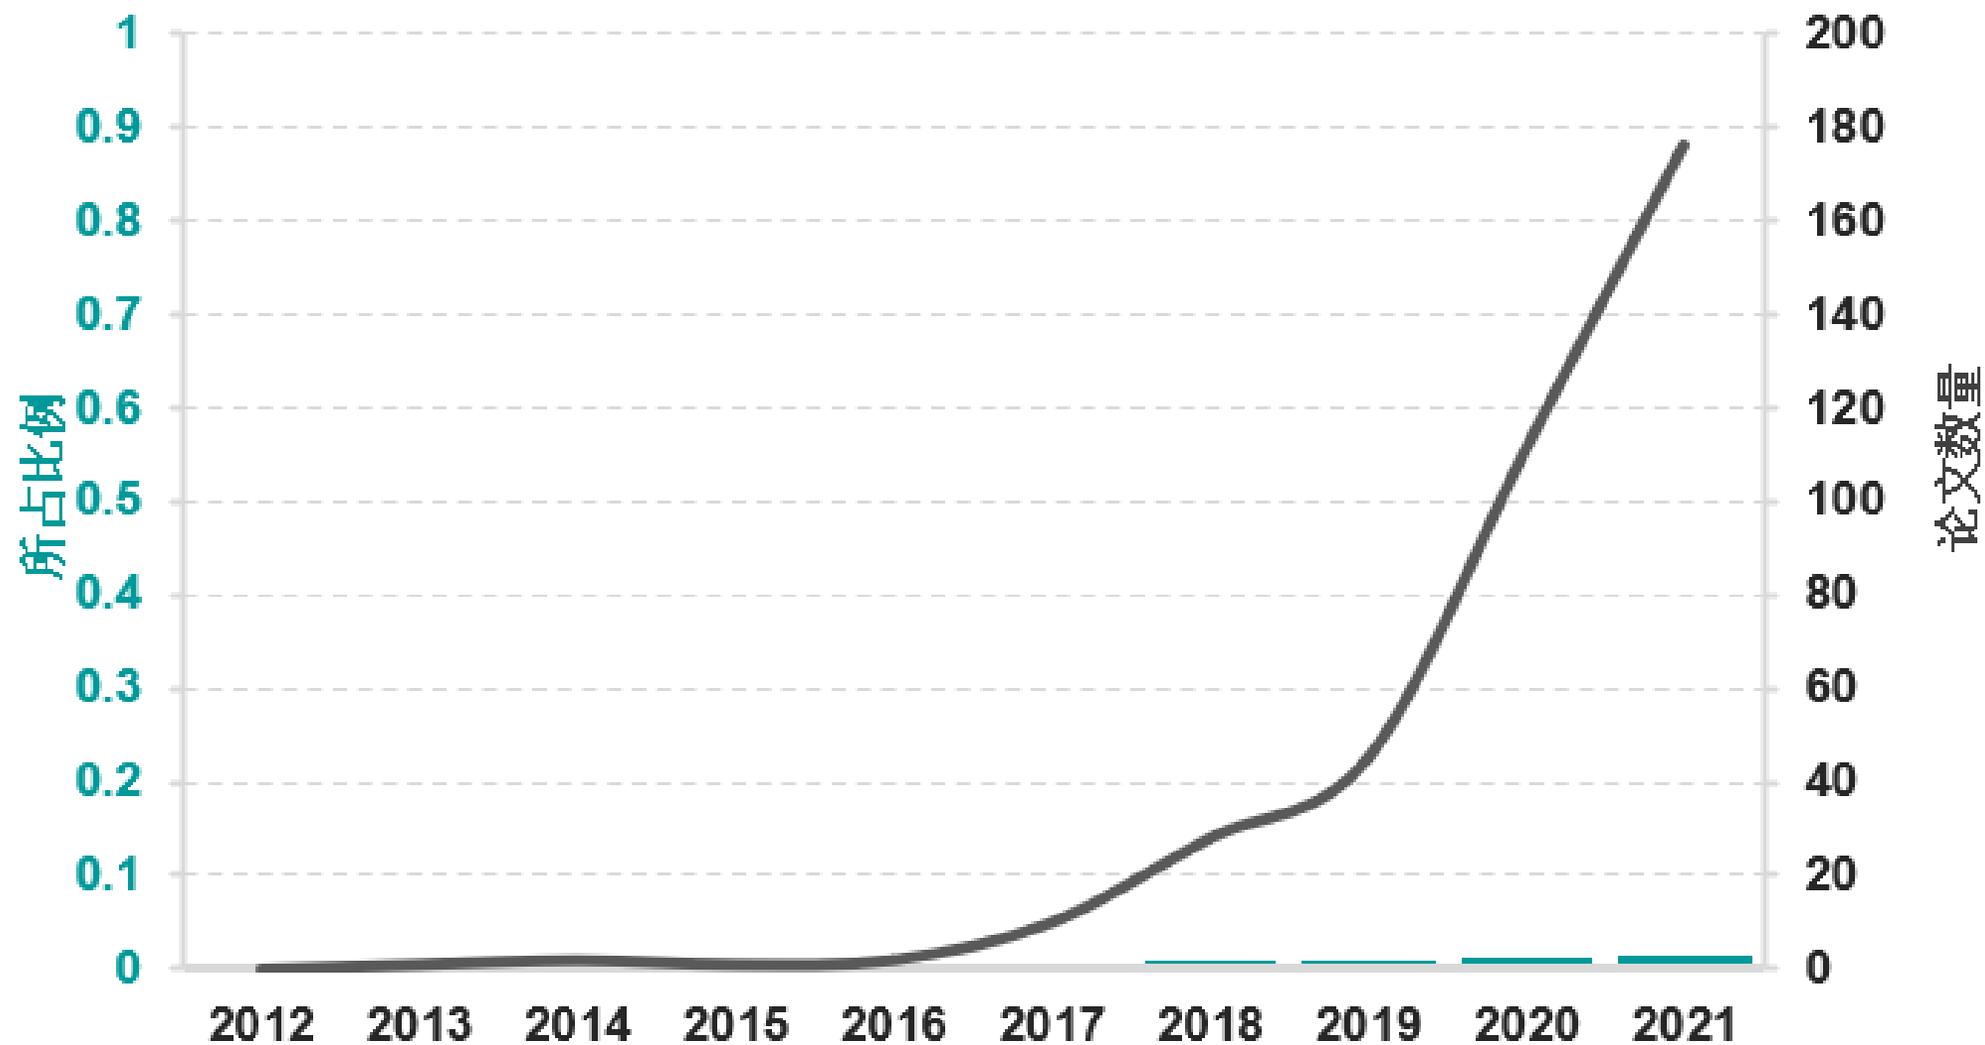
Transformer: 知识图谱增强语言模型



增强过后的Transformer
多语言嵌入仍是挑战...

LUKE: Deep Contextualized Entity Representations with Entity-aware Self-attention

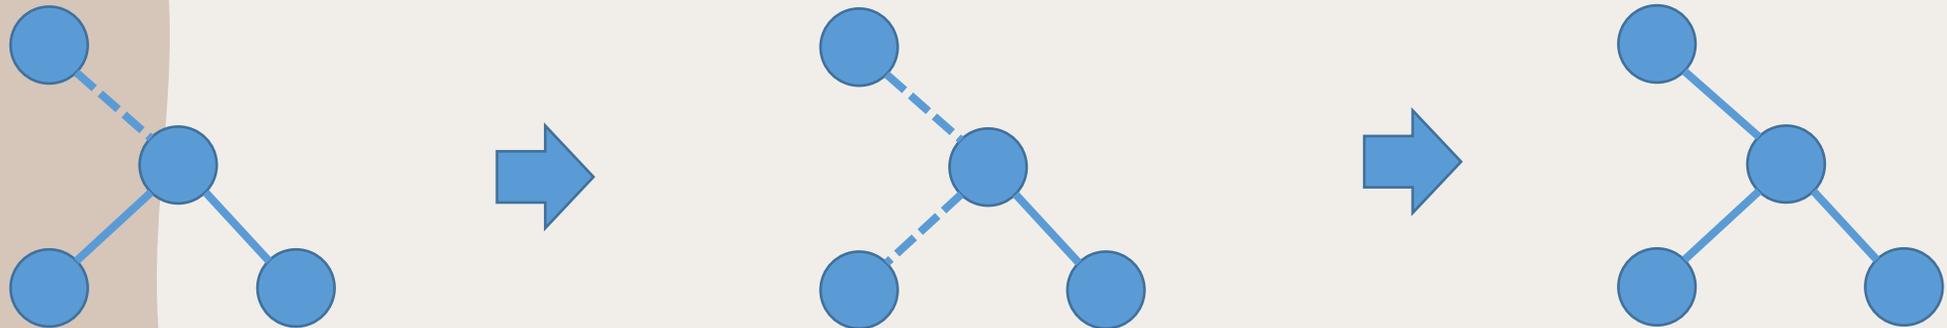
Dynamic: 时序知识图谱



Dynamic: 时序知识图谱

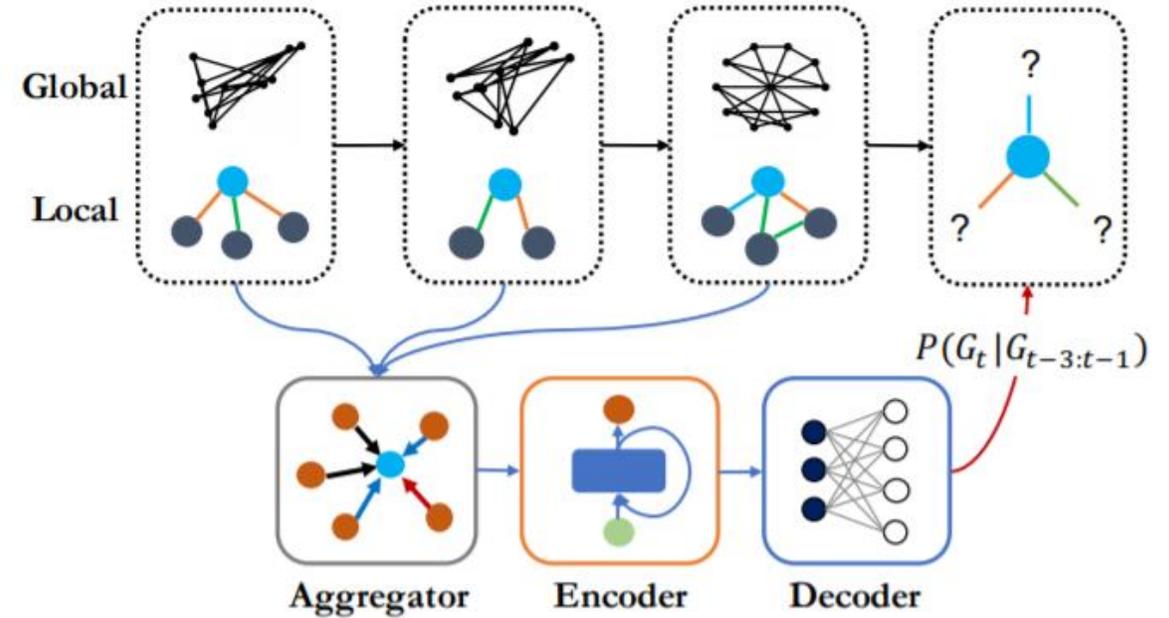
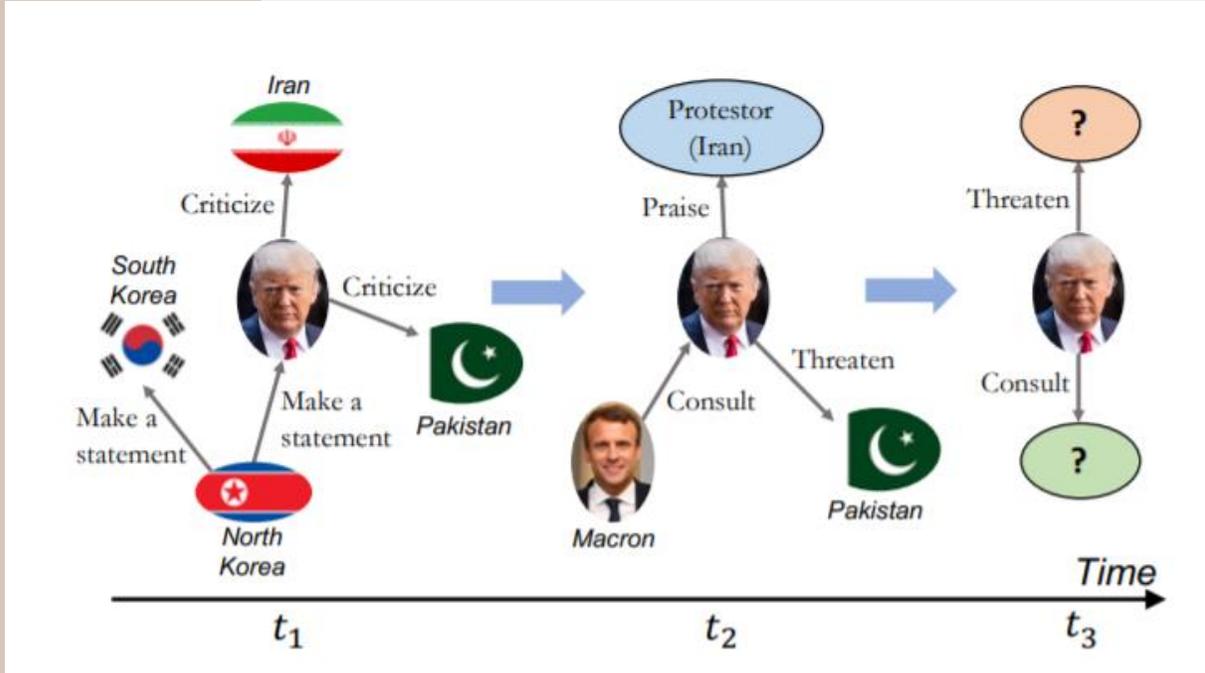
从 (h, r, t) 的三元组扩展为 (h, r, t, τ) 的时序四元组

$$f_{\tau}(h, r, t) = -\|\mathbf{h} + \mathbf{r} + \tau - \mathbf{t}\|_{L_{1/2}}$$



J. Leblay and M. W. Chekol, "Deriving validity time in knowledge graph," in WWW, 2018, pp. 1771–1776.

Dynamic: 时序知识图谱



W. Jin, C. Zhang, P. Szekely, and X. Ren, "Recurrent event network for reasoning over temporal knowledge graphs," in ICLR RLGM Workshop, 2019.

更多可能……

自动构建和动态变化：有监督学习

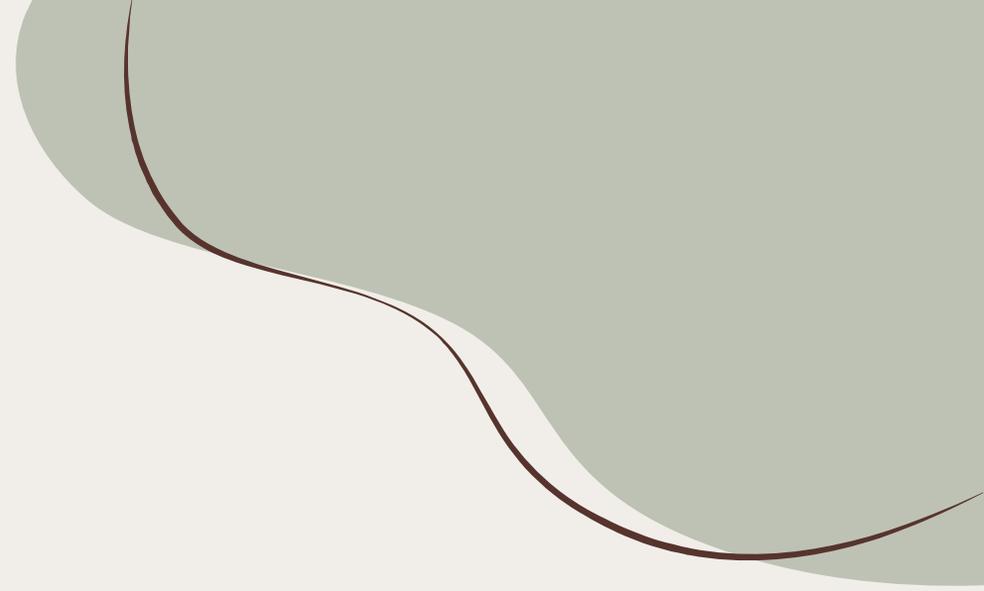
知识图谱X计算机视觉？

图片分类 鸢尾花分类

图片生成 多样性的问题

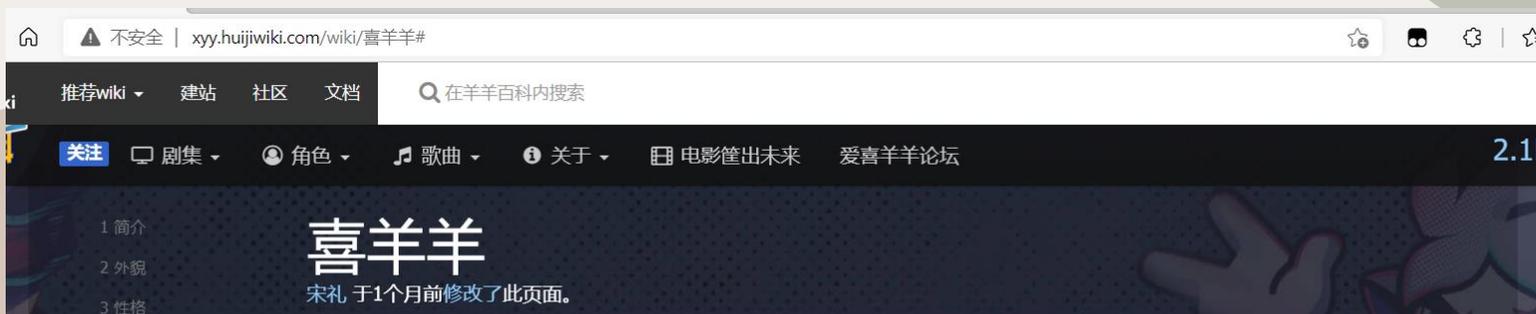
DEMO

PART.05



一、知识图谱的构建

知识抽取：结构化数据获取实体与三元组



知识抽取：非结构化数据获取实体与三元组

容易，终于又再进入羊村，可又被喜羊羊识破了。

烹煮。此时的众羊才知道灰太狼建造祭坛的真正目的。面对着将要被煮的危机，小羊这次又会如何面对呢

西哥却被灰太狼给抓了。这可怎么办呢？

女。灰太狼为了抓到小羊们偷偷溜到了地面。小羊们怎么才能解决这些危机呢？

兵，而此时灰太狼又想出坏点子。眼看小羊就要胜利在望，灰太狼的坏主意会得逞吗？

非常生气，只好借助道具追赶，这回黑大帅和灰太狼能否逃脱呢？喜羊羊他又能否成功捉住他们呢？

发生什么事呢？

opennre

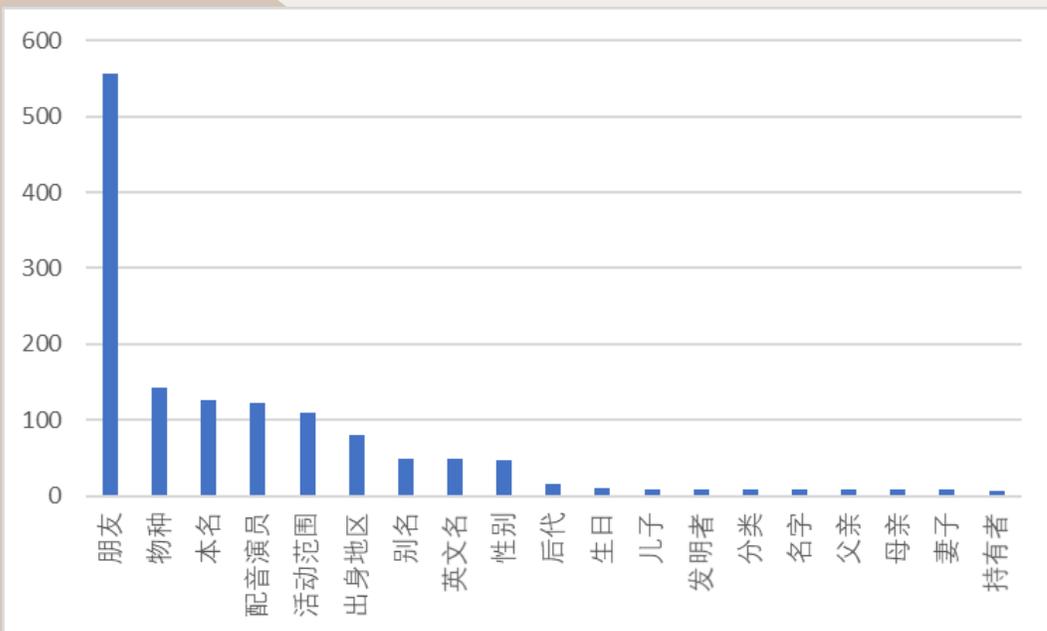
实体关系抽取

Model	ACC
wiki80_cnn_softmax	0.516
wiki80_bert_softmax	0.738
tacred_bert_softmax	0.619
tacred_bertentity_softmax	0.636
wiki80_bertentity_softmax	0.786
chinese-bert-wwm	0.919

wiki80_cnn_softmax	沸羊羊	喜羊羊	said to be same
	美羊羊	懒羊羊	
	懒羊羊	喜羊羊	
tacred_bert_softmax	沸羊羊	喜羊羊	NA
	美羊羊	懒羊羊	
	懒羊羊	喜羊羊	
chinese-bert-wwm	灰太狼	懒羊羊	夫妻
	灰太狼	潇洒哥	
	灰太狼	喜羊羊	

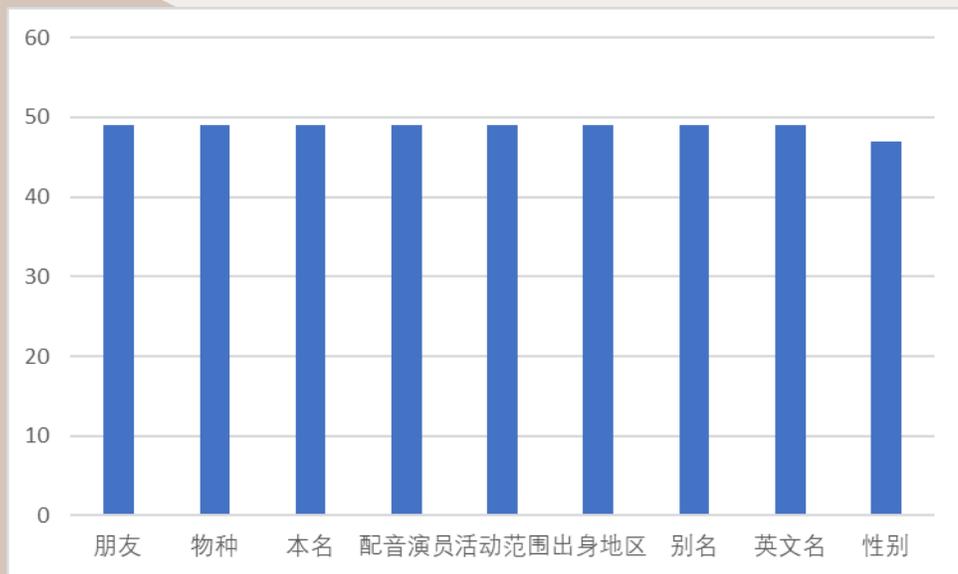
DeepKE

实体关系抽取



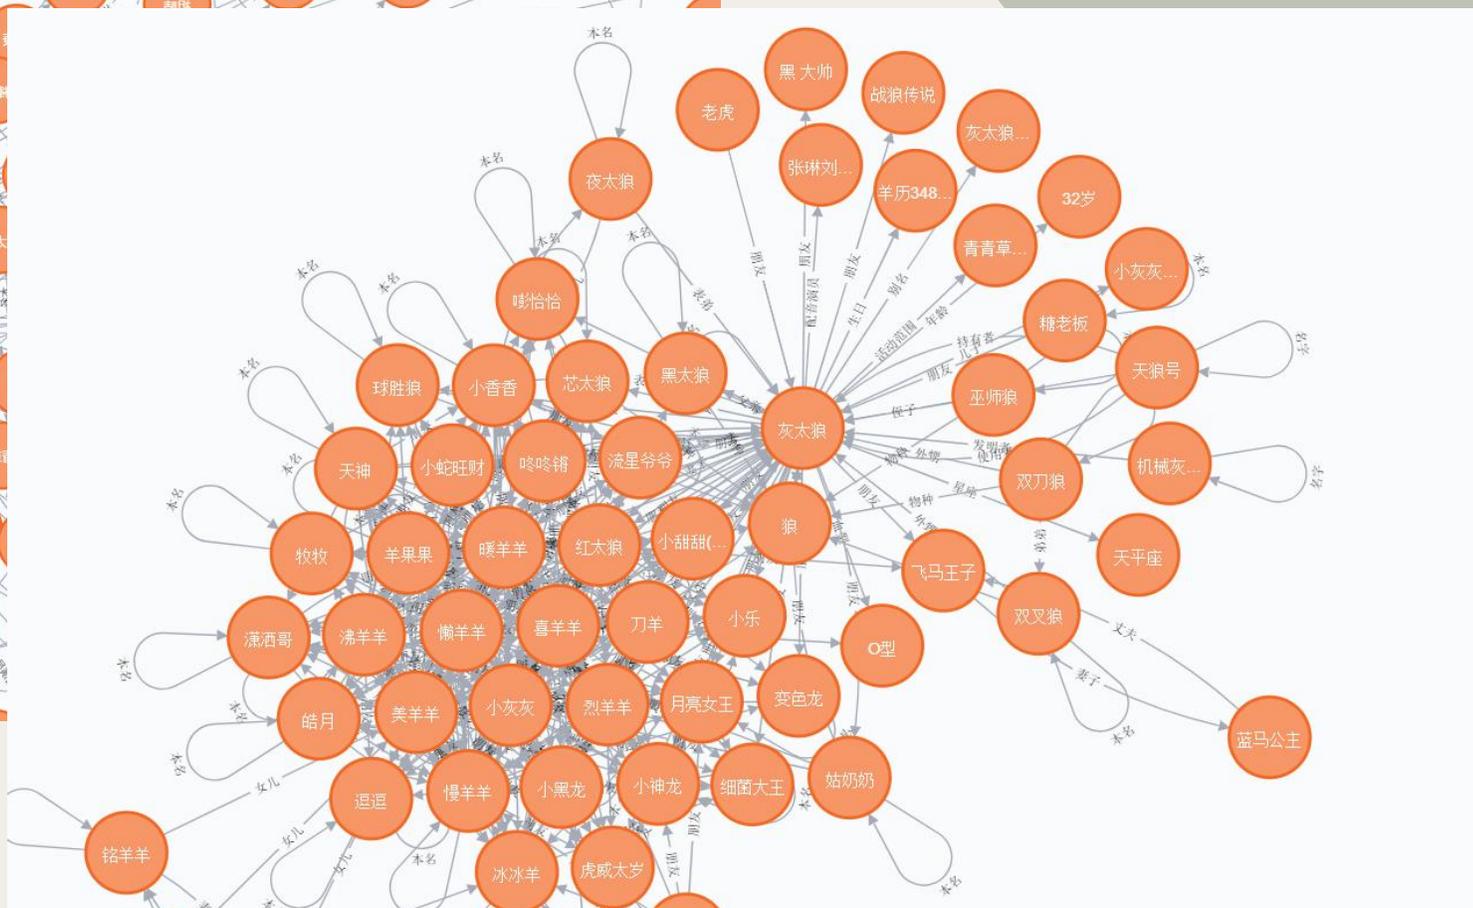
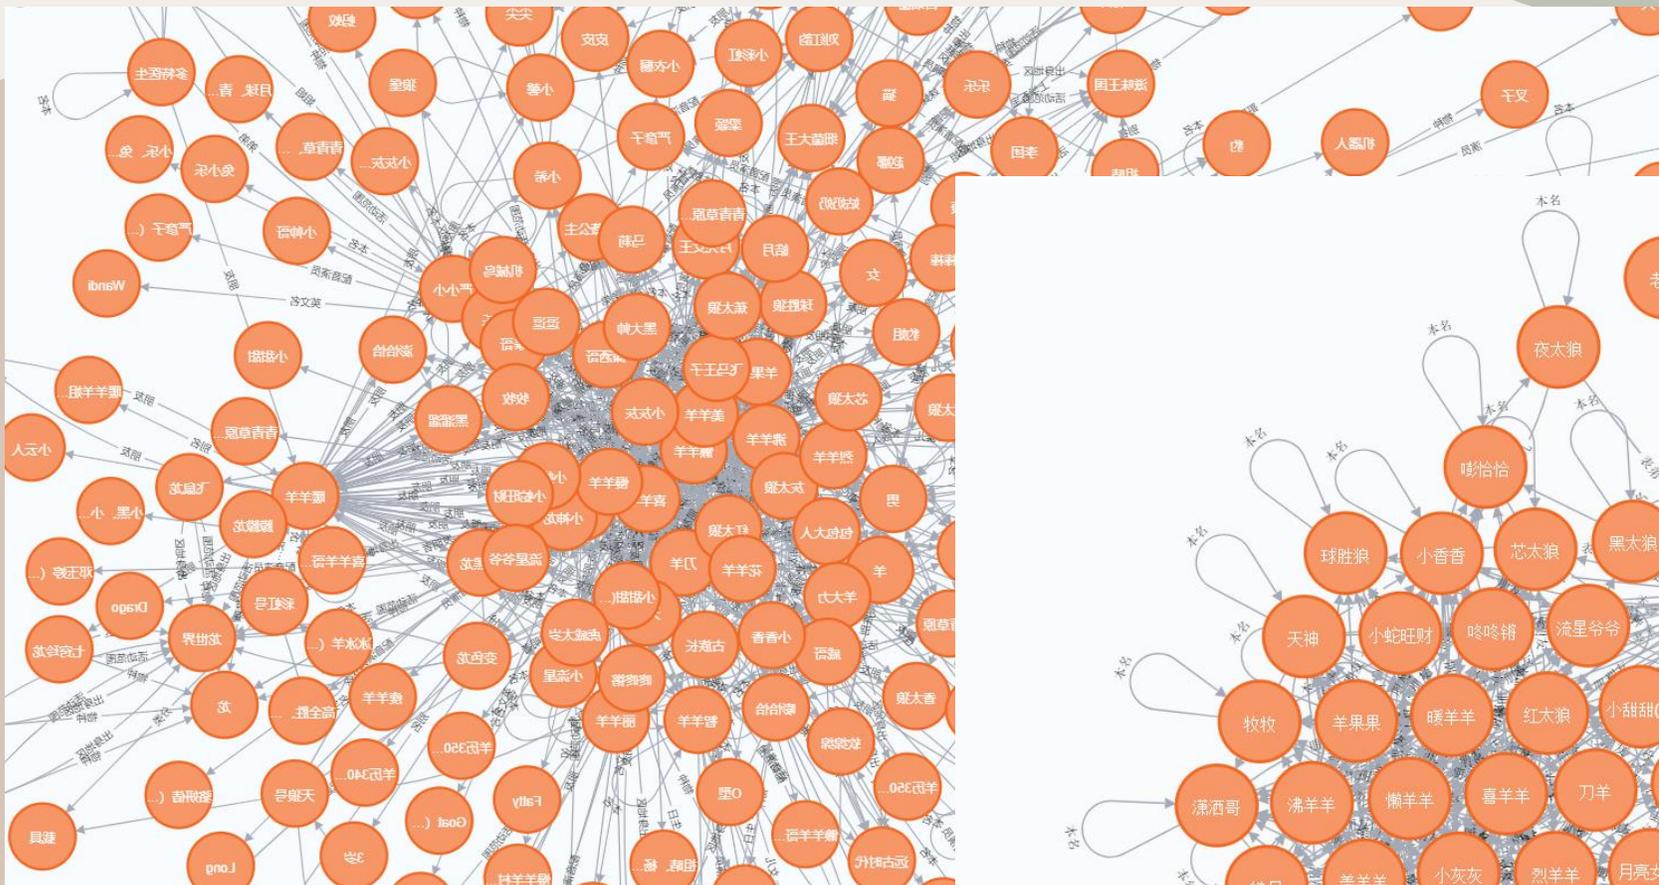
	PCNN	RNN	GCN	TRANSFORMER	BERT
验证集	80.11	83.87	55.91	82.26	90.86
训练集	86.23	85.64	63.15	86.12	91.33

实体关系抽取



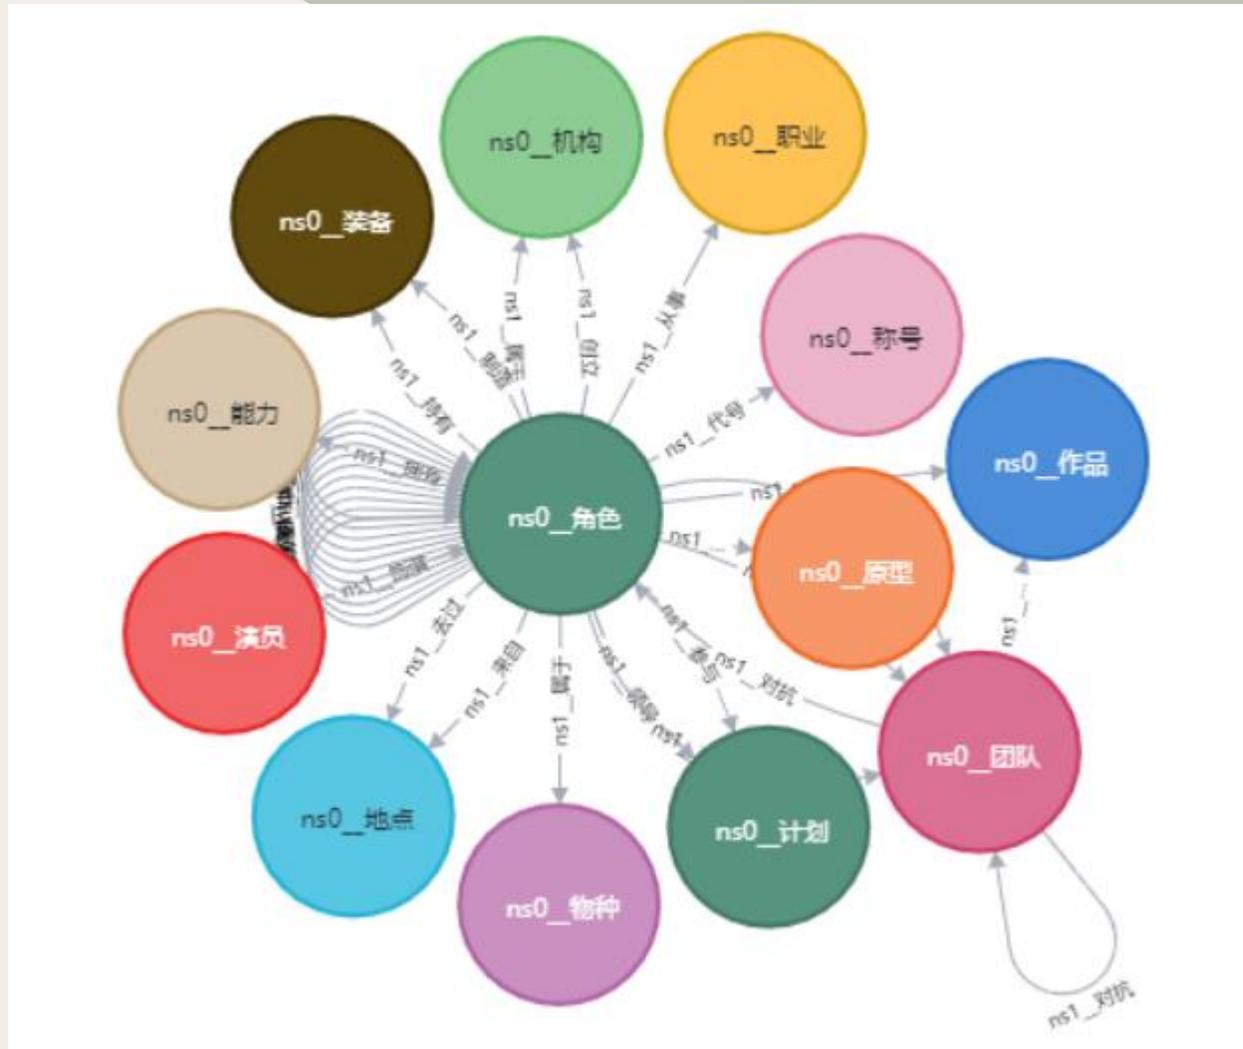
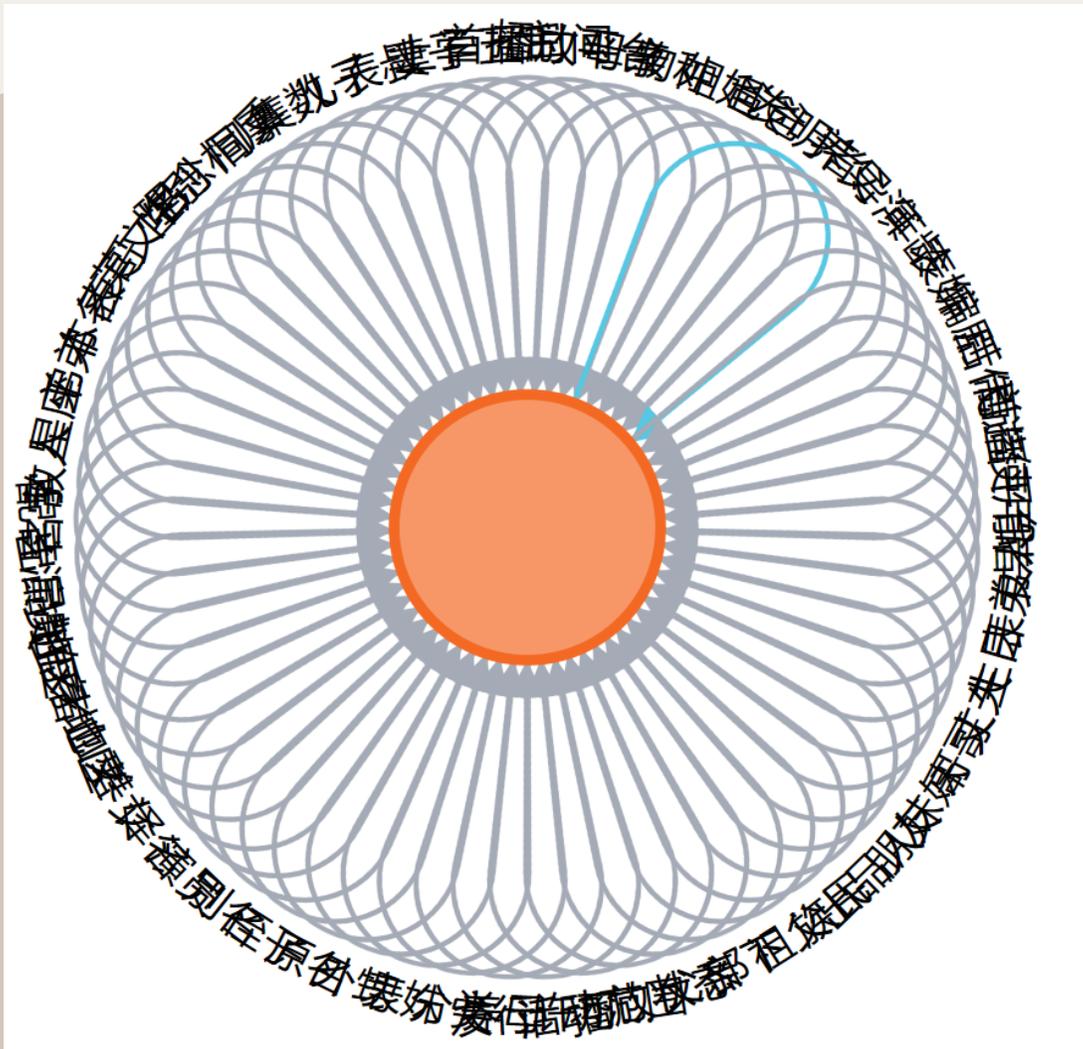
	PCNN	TRANSFORMER	PCNN	TRANSFORMER
验证集	80.11	82.26	77.1	78.56
测试集	86.18	86.18	80.61	82.39

知识存储:Neo4j



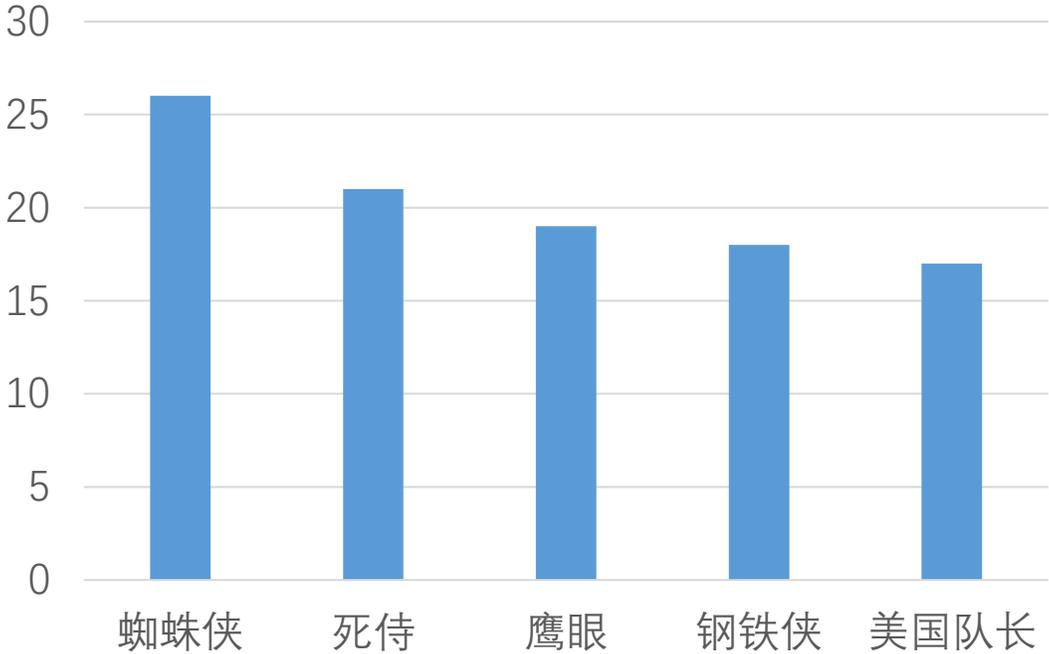
二、知识图谱的应用

本体层建模

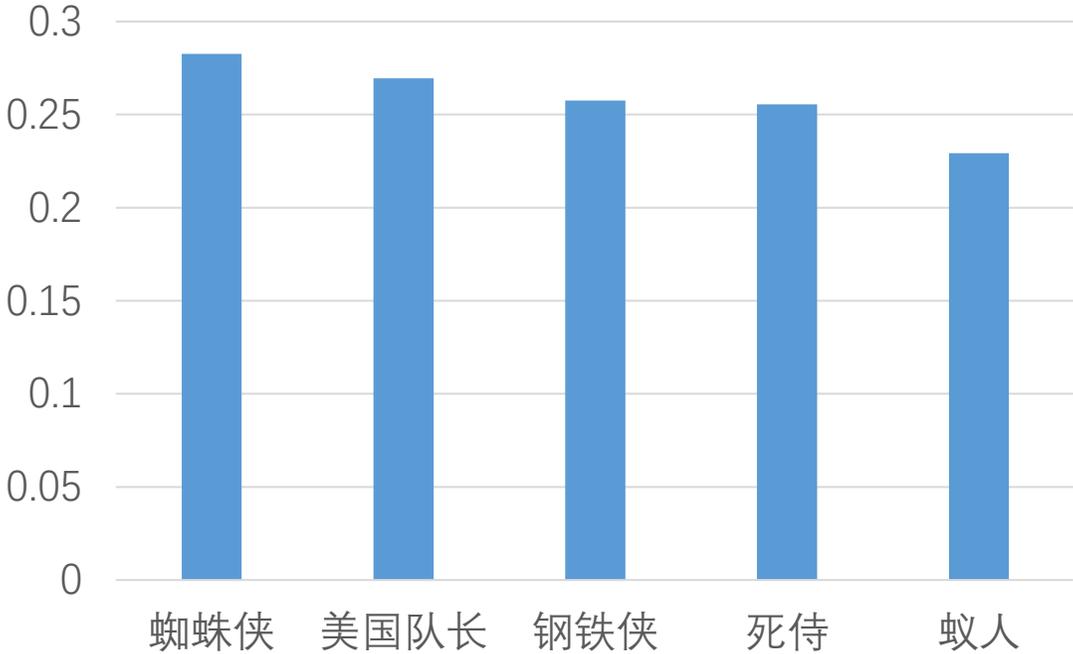


角色网络分析：节点中心度分析

度中心性



调和中心性



角色网络分析：社区检测

```
neo4j$ CALL gds.louvain.stream('my-cy...
```

	name	communityId
87	"菲尔·科尔森"	144
88	"卡尔·克里尔"	144
89	"梅琳达·梅"	144
90	"威廉姆·梅"	144
91	"安德鲁·加纳"	144
92	"兰斯·亨特"	144

```
neo4j$ CALL gds.labelPropagation.strea...
```

	name	communityId
6	"克林特·巴顿"	36
7	"奥创"	36
8	"汪达·马克希莫夫"	36
9	"亨利·皮姆"	36
10	"赫尔穆特·泽莫"	36
11	"洛基"	36

标签传播算法

知识问答

回答：青青草原的小灰灰的爸爸是狼堡的灰太狼

用户：小灰灰的妈妈是？

回答：青青草原的小灰灰的爸爸是狼堡的红太狼

用户：红太狼的妈妈是？

回答：狼堡的的红太狼的妈妈是狼堡的粉红太狼

用户：喜羊羊的爸爸是？

回答：青青草原的的喜羊羊的爸爸是青青草原的智羊羊

用户：喜羊羊的妈妈是？

回答：青青草原的的喜羊羊的爸爸是青青草原的丽羊羊

用户：智羊羊的妻子是？

回答：青青草原的的智羊羊的妻子是青青草原的丽羊羊

```
===== RESTART: C:/Users/  
灰太狼的爸爸是？  
狼堡的灰太狼的爸爸是狼堡的黑太狼？  
>>>
```

```
DeprecationWarning: invalid escape sequence \W  
sentence = re.sub('\W+', '', sentence).replace("_", '')  
Paddle enabled successfully.....  
DEBUG:jieba._compat:Paddle enabled successfully.....  
match(p)-[r0:父亲]->(n:Person{Name:'灰太狼'}) return  
p.Name,n.Name,p.cate,n.cate  
p.Name | n.Name | p.cate | n.cate  
-----|-----|-----|-----  
小灰灰 | 灰太狼 | 青青草原 | 青青草原  
  
青青草原的灰太狼的父亲是青青草原的小灰灰
```