基于低维表示的大规模实体关系挖掘技术

Large-scale entity relation extraction based on *low-dimensional representations*

范淼

直博三年级

语音和语言技术中心

清华大学计算机系

指导教师：**郑方、周强**

fanmiao.cslt.thu@gmail.com

目录

1. 领域综述

- **信息抽取** (Information Extraction)在自然语言处理领域有长达近20年的研究历史，始终致力于将无结构化的文本转换为结构化的信息，而有便于给诸如：**问答系统** (Question-Answering System)、**信息检索**(Information Retrieval) 等其他应用领域提供更加便利的知识表示。

Google 知识图谱

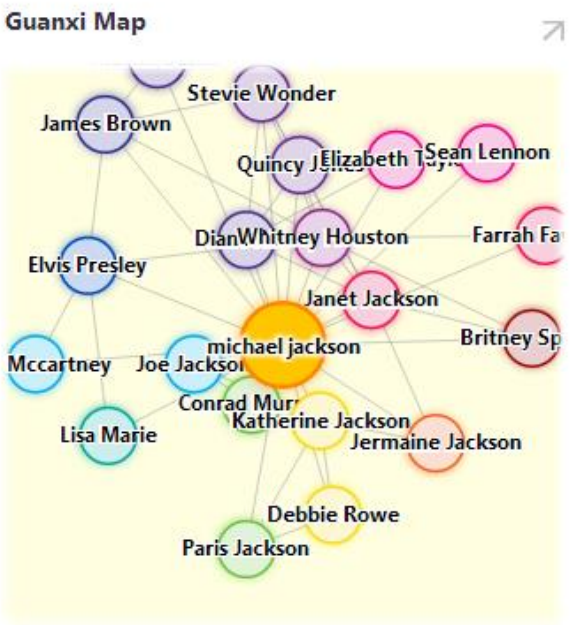

Microsoft 关系图谱

1. 领域综述

- 信息抽取 (Information Extraction) 主要分为**命名实体识别** (Named Entity Recognition, **NER**) 和**关系抽取** (Relation Extraction, **RE**) 两大任务。
- **命名实体识别**主要致力于从无结构的文本中识别*人名 (PER)*、*地名(LOC)*、*机构名称(ORG)* 等名词实体，目前技术比较成熟，识别率都在90%上下，目前**微软亚洲研究院，聂再清**研究员领导的小组持有的识别工具已经投入商用。
- **关系抽取**（**实体关系挖掘**，RE）是目前研究的主题，同时也是工业界关注的热点话题。该研究在NER的基础上，用于发现实体之间的关系，目前最受关注的是识别实体对（$< \boldsymbol{h(head\_entity}), \boldsymbol{t(tail\_entity}) >$）之间的关系**r**。

维基百科

Barack Hussein Obama II (/bəˈrɑːk huːˈseɪn oʊˈbɑːmə/; born August 4, 1961) is the 44th and current President of the United States,

<Barack Obama, *President of*, U.S.>

1. 领域综述

- **实体关系挖掘技术**的研究在2008年之前分为两种不同的研究方向：
  - 固定关系挖掘
  - 开放关系挖掘 (Open RE)
- 上述两种关系挖掘技术的不同点在于：是否有**新关系 (new relationship discovery)**的发现。
- 学生的研究方向主要关注于**固定关系挖掘**。
- 固定关系挖掘**基本假设**于我们在**圈定种类**的关系类别中，对实体之间的关系进行**预测**，因此属于**监督学习**范畴 (Supervised Learning based Relation Extraction Approaches)。

1. 领域综述

- **2008年之前**的关系挖掘的研究大多集中在**ACE, MUC**两类关系标注语料库中探讨如何利用规则方法、统计监督学习方法不断提升对多类别关系分类（预测）的精度。
- ACE和MUC两个人工标注数据库的规模都比较小。以ACE语料为例，共有大约1000篇文本，包含16771个关系实例，23种关系类型。
  - 代表工作有：
    - **基于规则的方法：**
      - J. Aitken, “Learning information extraction rules: An inductive logic programming approach”, ECAI’02.
      - D. McDonald, H.Chen, H. Su, and B. Marshall, “Extracting gene pathway relations using a hybrid grammar: The Arizona relation parser”, Bioinformatics 2004.
    - **特征选择的方法：**
      - J. Jiang and C. Zhai, “A systematic exploration of the feature space for relation extraction.”, NAACL’ 07.
    - **基于句法分析（核函数）的方法：**
      - Guodong Zhou, Min Zhang, Donghong Ji and Qiaoming Zhu. Tree kernel based relation extraction with context-sensitive structure parse tree Information. EMNLP’07.
- 2008年Sunita Sarawagi在*Foundations and Trends in Databases*发表知名综述长篇论文(117页)“Information Extraction”，对信息抽取，特别是**关系抽取**的研究做了深入总结，特别指出了现有基于语料库标注数据的**局限**。

1. 领域综述

- 2009年， 斯坦福大学的几位知名教授在ACL上提出一种新的信息抽取方法的范式(*Distant supervision for relation extraction without labeled data*)
  - Google Sites: 315.

Entity pair	<Barack Obama, U.S.>
Relation instances from knowledge bases	**1. President of (Barack Obama, U.S.)** **2. Born in (Barack Obama, U.S.)**
Relation mentions from free texts	**1. Barack Obama** is the 44th and current President of the **U.S.**. (President of & **Born in**) **2. Barack Obama** ended **U.S.** military involvement in the Iraq War. (**President of** & **Born in**) **3. Barack Obama** was born in Honolulu, Hawaii, **U.S.**. (**President of** & Born in) **4. Barack Obama** ran for the **U.S.** Senate in 2004. (**President of** & **Born in**)

1. 领域综述

- 之后，DSRE（Distant Supervision for Relation Extraction）蓬勃兴起，后续的工作也逐渐被各大高校和IT公司的研究部门争相学习和进一步探索。

Distant Supervision (Mintz2009): Mike Mintz, Steven Bills, Rion Snow, and Dan Jurafsky. 2009. *Distant supervision for relation extraction without labeled data.* *ACL’09.*

MIL (Riedel2010): Sebastian Riedel, Limin Yao, and Andrew McCallum. 2010. *Modeling relations and their mentions without labeled text.* *ECML 2010.*

MultiR (Hoffman2011): Raphael Hoffmann, Congle Zhang, Xiao Ling, Luke Zettlemoyer, and Daniel S. Weld. *2011. Knowledge-based weak supervision for information extraction of overlapping relations.* *ACL’11.*

MIML (Surdeanu2012):Mihai Surdeanu, Julie Tibshirani, Ramesh Nallapati, Christopher D. Manning. *Multi-instance Multi-label Learning for Relation Extraction.* *EMNLP-CoNLL’12.*

Incomplete Knowledge (Bonan2013): Bonan, Ralph Grishman, Li Wan, Chang Wang, David Gondek. *Distant Supervision for Relation Extraction with an Incomplete Knowledge Base.* *NAACL’13.*

2. 研究动机

- 2008年之前的研究，传统的基于人工标注语料库（ACE、MUC）的规则和监督学习方法的
  - **缺陷**：
    - 人工标注任务量庞大，开销巨大，不适合大规模应用。
    - 模型泛化能力太弱，因为标注数据量较少。
- 2009年至今，**Stanford University**, Mike Mintz在ACL’09的论文（The most solid paper in ACL）提出的基于弱标记（**知识库对齐**）的关系挖掘方法的**优势**和**缺陷**。
  - **优势**：
    - 自动通过知识库对齐假设，获取大规模弱标记样本，真正使关系挖掘模型能够应用于实际系统。
  - **缺陷**：
    - 弱标记(weakly labeled)方法的基本假设容易产生一部分**误标记样本**。
    - 大规模的弱标记数据同时产生**高维、稀疏特征**，给训练模型带来极高的**参数复杂度**。

3. 科学问题

- 综上，我们的对**固定关系挖掘**的**探究点**在于如何寻找能够处理**弱标记**（Weakly Labeled）**噪音**(Noisy)、**稀疏**(Sparse)，**同时**还能有效应对**大规模数据**(Large-scale)下的计算方法。

- 研究的**着眼点**在于如何通过**低维表示**寻找**真正**对**实体关系预测**有价值的信息，同时由于**低维表示**降低了**模型复杂度**并且改善了**特征的稀疏性**，能够在**大数据规模的**环境下应用。

- 因此学生的**研究题目**为：
  - **基于低维表示的大规模实体关系挖掘技术**
  - **Large-scale entity relation extraction based on low-dimensional representation.**

4. 研究意义

- **理论意义:**
  - 所要面对的数据**弱标记**（Weakly Labeled）、**噪音**(Noisy)、**稀疏**(Sparse)、**大规模**（Large Scale）是一个当下亟待解决的**机器学习问题**（Learning Algorithm）。
  - 基于**低维表示**（Low Dimensional Distributed Representation)**的大规模**（分布式）计算方案成为最有可能的**突破口**！
- **应用意义:**
  - 真正尝试将**实体关系挖掘技术**从**小数据集、试验模型**的两大不实用**弊端**中脱离。
  - 充分利用现有**互联网数据**（无结构、半结构互联网文本；结构化知识库）探究**实体关系挖掘技术**。

5. 研究计划

- **研究目标：** 给定**大规模**实体对$<\boldsymbol{h},\boldsymbol{t}>$，以及实体对的**上下文环境**，探索基于**低维表示的方法**在已知的关系集合R中**挖掘**最佳关系子集R',用来描述$<\boldsymbol{h},\boldsymbol{t}>$之间的正确关系。
- **上下文环境（数据源）：**

半结构化Web文本（维基百科文本）

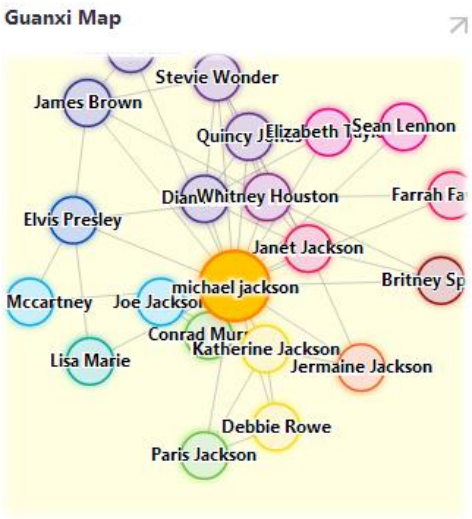

结构化的知识库

5. 研究计划

关系挖掘方法

信息的低维表示

上下文信息：

数据源：

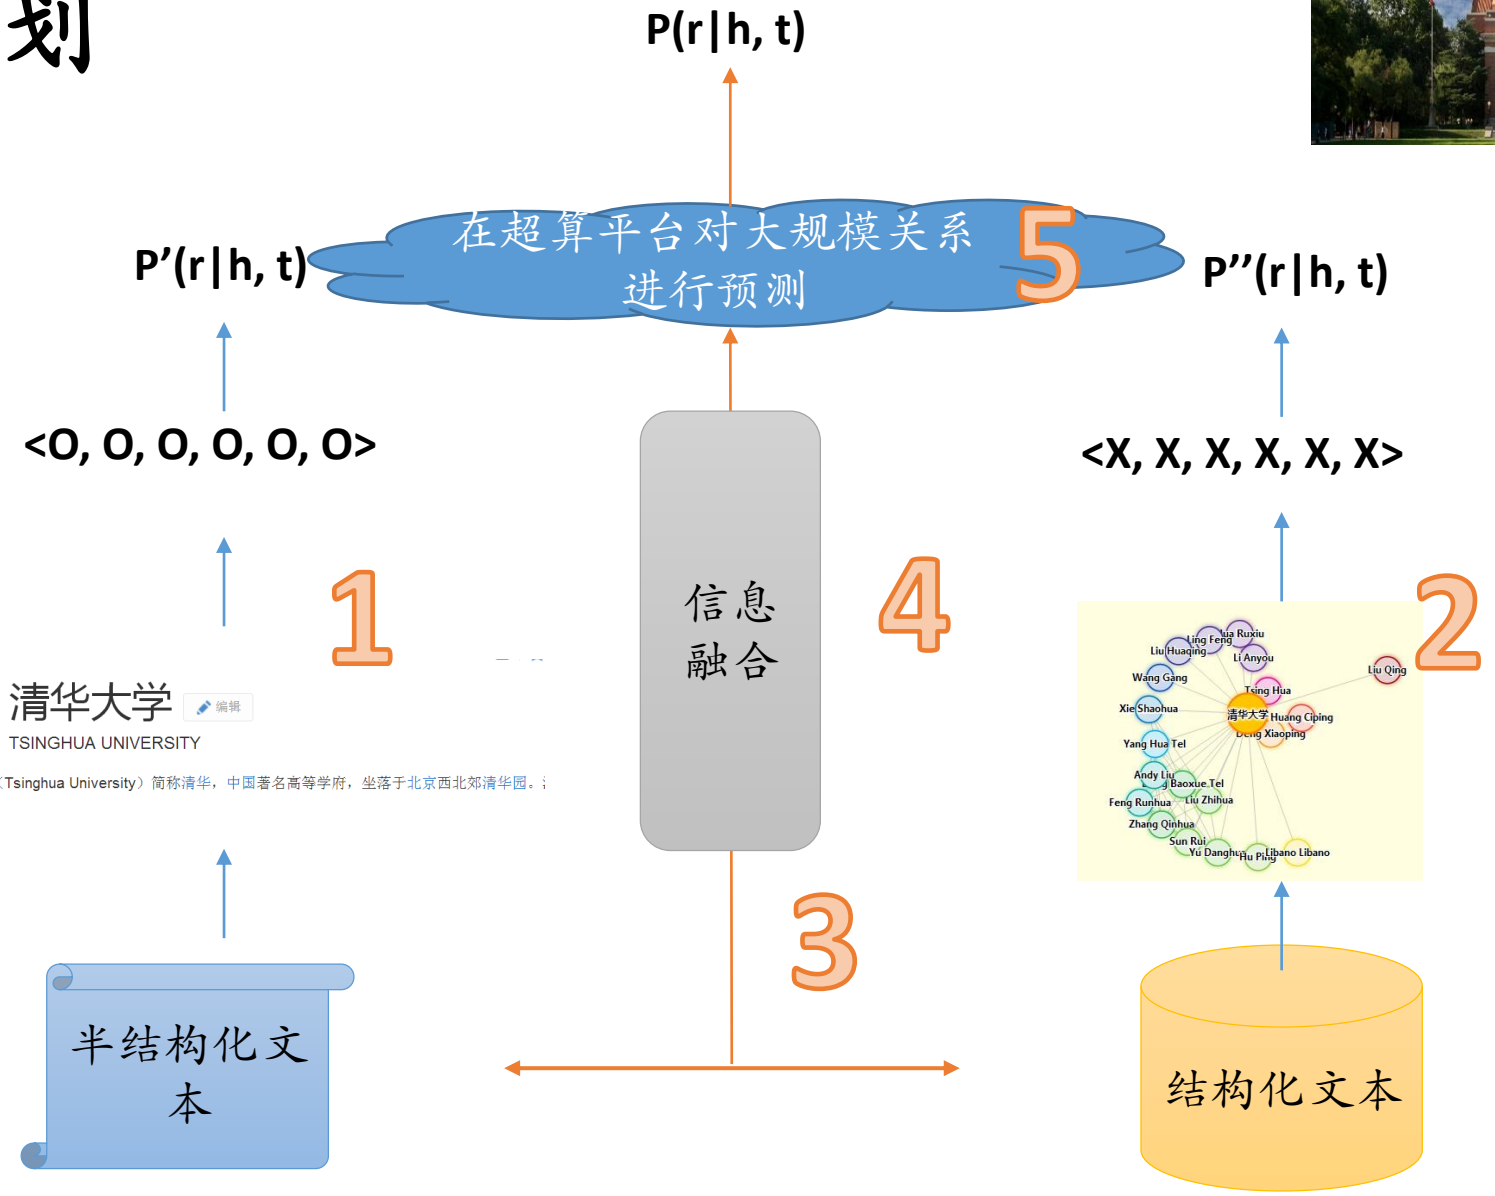

5. 研究计划

- **阶段一：探究低维表示方法半结构化文本关系抽取中的有效性：**
  - ***Miao Fan***, Deli Zhao, Qiang Zhou, Zhiyuan Liu, Thomas Fang Zheng, Edward Y. Chang. 2014. Distant supervision for relation extraction with *matrix completion*. ACL 2014. ***long paper, oral presentation***. (Rank: A)
  - 该论文从低维矩阵补完（低维矩阵表示三元组<h, r, t>）的角度，采用直推式模型，充分利用测试样本的特征信息，取得突破，主要处理从**自由文本**中抽取关系实例。

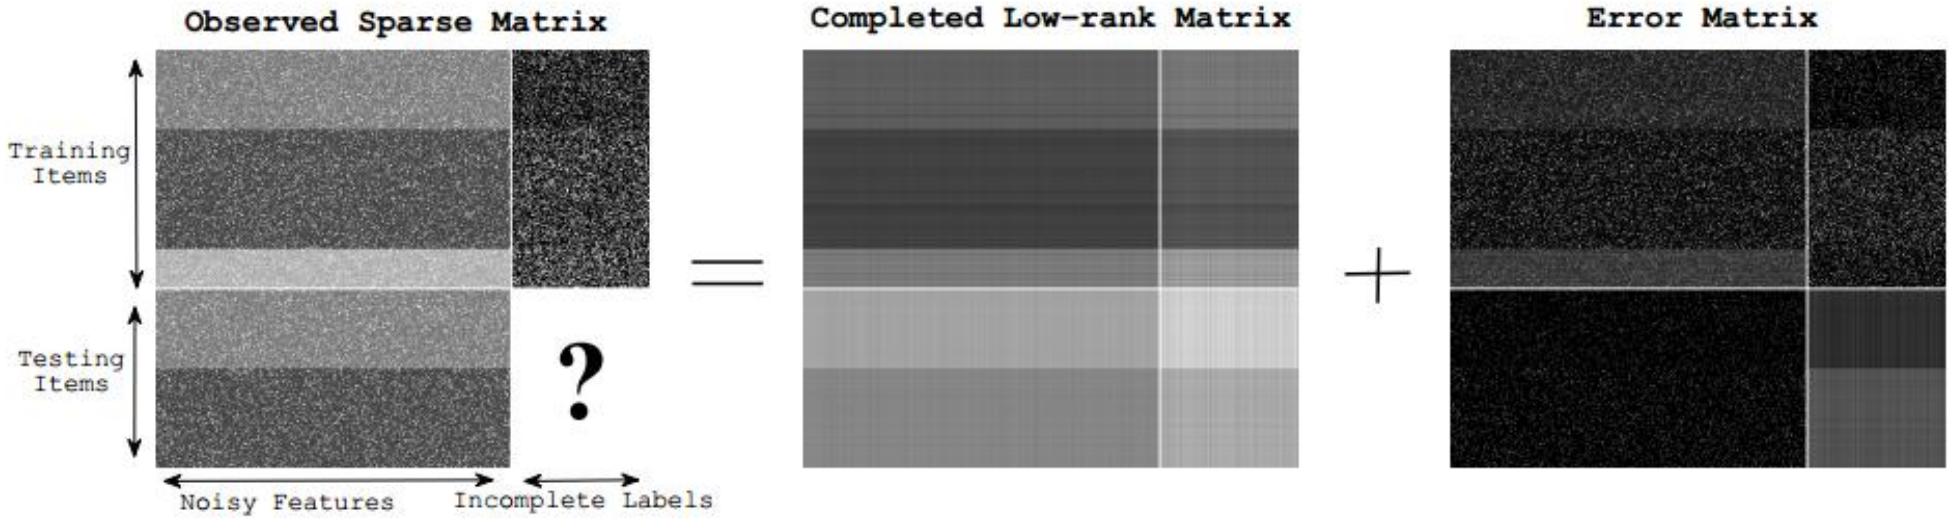

ACL 2014

5. 研究计划

- **阶段二**：探究**低维表示方法在大规模知识图谱上的易用性**：
  - ***Miao Fan,*** Qiang Zhou, Thomas Fang Zheng, Ralph Grishman. Large Margin Nearest Neighbor Embedding for Knowledge Representation. **WI 2015**. *research paper submission*. **(Rank: B)**
  - ***Miao Fan***, Qiang Zhou, Emily Chang, Thomas Fang Zheng. Transition-based Knowledge Graph Embedding with Relational Mapping Properties. **PACLIC 2014**. *long paper, ORAL*. **(Rank: C)**
  - 从低维向量表示（三元组<h, r, t>）的角度切入，设计更加**易于计算**的框架，便于处理**大规模关系数据（百万量级）**，主要应用在**知识图自身的关系推理**（*Link prediction*）。

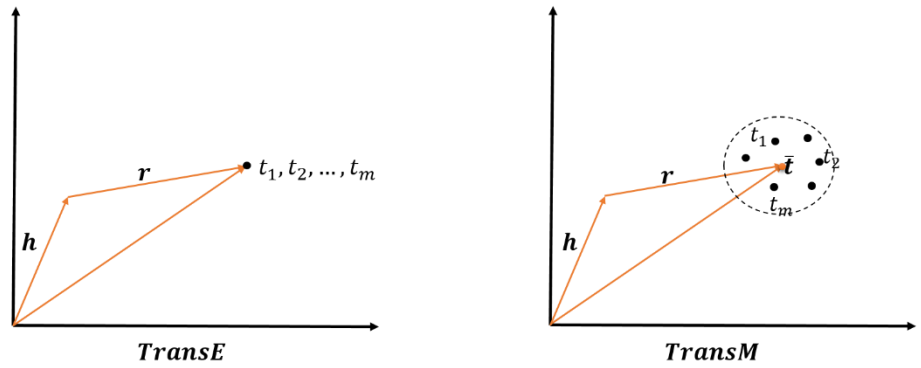

PACLIC 2014

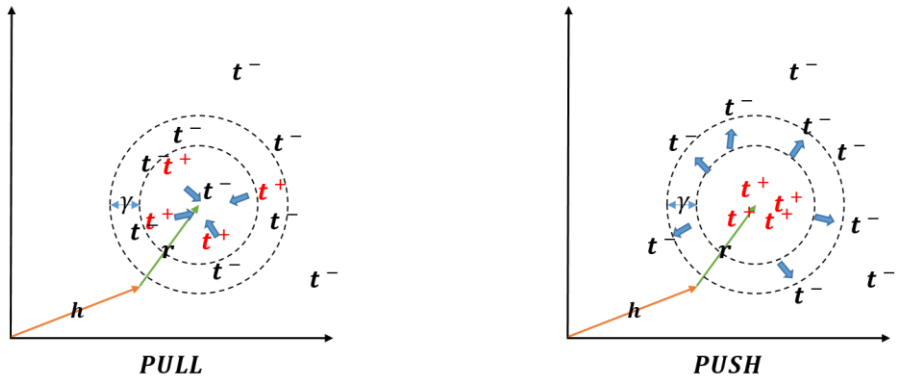

WI 2015

5. 研究计划

- **阶段三**：尝试从**数据源**底层进行**信息整合**
  - ***Miao Fan***, Qiang Zhou, Deli Zhao, Thomas Fang Zheng, Edward Y. Chang. 2014. Distant Supervision for Entity Linking. **CICLING 2015**. *long paper, submission*.
- **阶段四：**尝试整合知识库（结构化）和Web文本（半结构化），提出**统一的**基于低维表示的实体关系挖掘理论框架。
  - 2015年3月-2016年3月，在**关系挖掘研究领域**的知名教授 Ralph Grishman (曾任ACL, NAACL主席，Google H-index：49）的联合指导下从事相关科研，加入其创建的“海神计划”，尝试整合两个模型各自的优势，提出统一的框架。

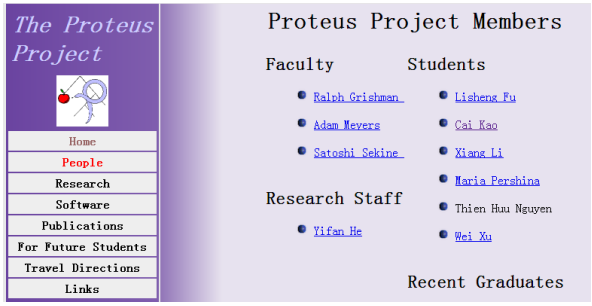

5. 研究计划

- **阶段五**：参考阶段二，设计更加**易于计算**的框架，处理**世界级关系数据（19亿）**，使用微软“宇宙”**超级计算平台**(Cosmos)，对Web文本（Wikipedia），大规模知识库（Freebase）进行统一处理，推断实体关系，为**实体搜索，知识图谱**等应用提供实际理论参考。

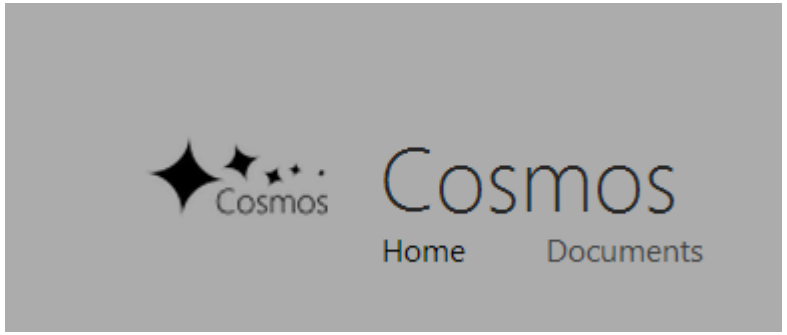

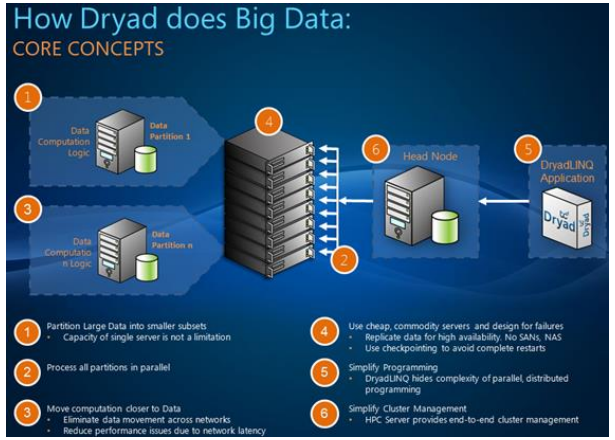

5. 研究计划

- **整体研究时间表：**

起始时间	研究内容	研究成果（计划）
2014年3月	基于低维表示的**无结构化文本**实体关系挖掘技术	ACL’14
2014年9月	基于低维表示的**结构化知识**实体关系推断技术	AAAI’15, PACLIC’14
2015年3月	基于低维表示的实体关系挖掘（推断）**整合技术**	正在进行
2016年3月	基于低维表示的**大规模（分布式）**实体关系挖掘技术	在微软COSMOS平台已经成功完成1百亿级别数据模型的**原型开发**
2017年3月	整理博士论文，准备博士论文答辩	-

6. 研究进度

关系挖掘方法

信息的低维表示

上下文信息：

数据源：

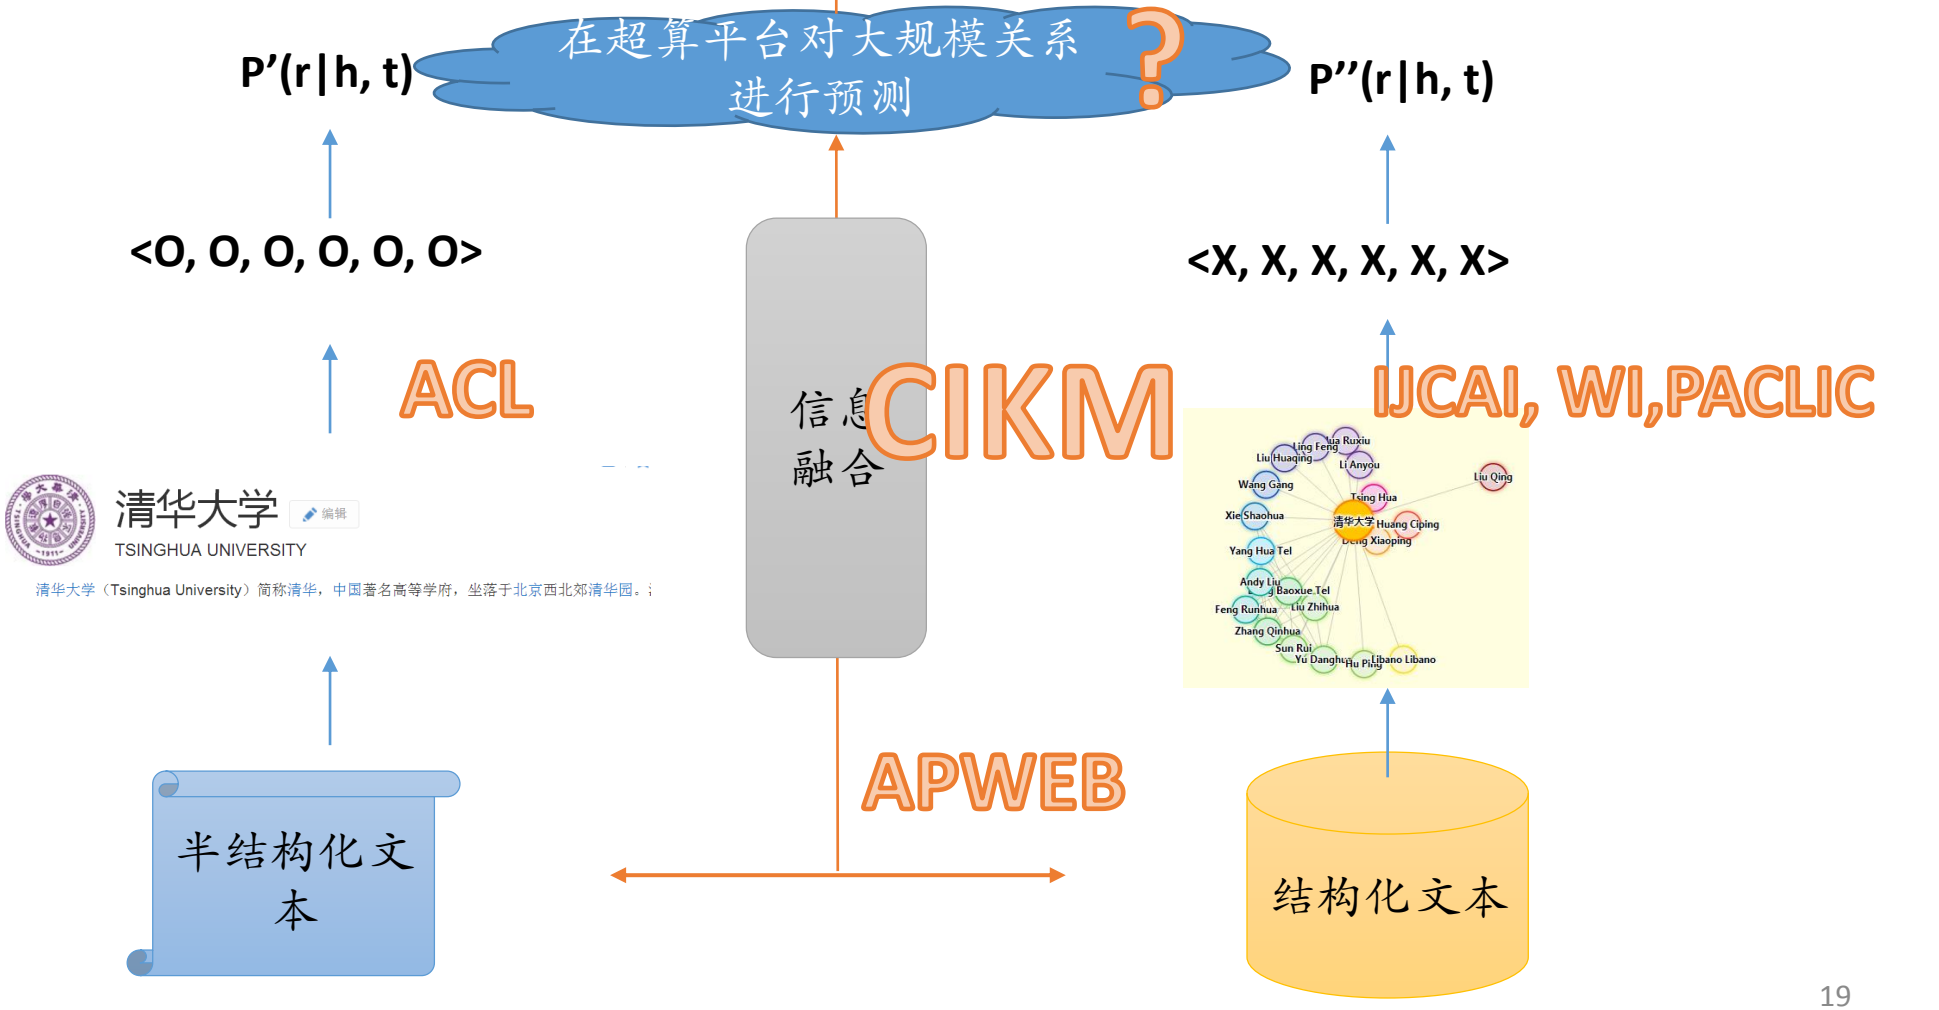

6. 研究进度（按照计算机系的重要会议排名）

- [1] **Miao Fan**, Deli Zhao, Qiang Zhou, Zhiyuan Liu, Thomas Fang Zheng, Edward Y. Chang: *Distant supervision for relation extraction with matrix completion*. ACL 2014. *long paper, ORAL*. (Rank: A)
- [2] **Miao Fan**, Qiang Zhou, Thomas Fang Zheng, Ralph Grishman: *Large Margin Nearest Neighbor Embedding for Knowledge Representation*. WI 2015 *research paper submitted*. (Rank: B)
- [3] **Miao Fan**, Qiang Zhou, Thomas Fang Zheng: Learning Embedding Representations for Inferencing on Imperfect and Incomplete Knowledge Repositories. IJCAI 2015. *research paper submitted*. (Rank: A, CCF: A)
- [4] **Miao Fan**, Kai Cao, Yifan He, Ralph Grishman. Jointly Embedding Relations and Mentions for Knowledge Population. CIKM 2015. *short paper submission*. (Rank: B, CCF: B)
- [5] **Miao Fan**, Qiang Zhou, Emily Chang, Thomas Fang Zheng: *Transition-based Knowledge Graph Embedding with Relational Mapping Properties*. PACLIC 2014. *long paper , ORAL*. (Rank: C)
- [6] **Miao Fan**, Qiang Zhou, Thomas Fang Zheng: *Distant Supervision for Entity Linking*. APWEB 2015. CCF: C
- [7] **Miao Fan**, Qiang Zhou, Thomas Fang Zheng: *Mining the Personal Interests of Microbloggers via Exploiting Wikipedia Knowledge*. CICLING 2014: 188-200. *long paper, POSTER. (EI Compendex)*
- [8] **Miao Fan**, Qiang Zhou, Thomas Fang Zheng: *Content-Based Semantic Tag Ranking for Recommendation*. Web Intelligence (WI) 2012: 292-296. *short paper, ORAL*. (Rank: B)
- [9] **Miao Fan**, Yingnan Xiao, Qiang Zhou: *Bringing the associative ability to social tag recommendation*. ACL 2012 Workshop on Textgraph-7. *ORAL*.

7. 参考文献 (部分)

- [1] J. Aitken, “Learning information extraction rules: An inductive logic programming approach”, ECAI’02.
- [2] D. McDonald, H.Chen, H. Su, and B. Marshall, “Extracting gene pathway relations using a hybrid grammar: The Arizona relation parser”, Bioinformatics 2004.
- [3] J. Jiang and C. Zhai, “A systematic exploration of the feature space for relation extraction.”, NAACL’07.
- [4] Guodong Zhou, Min Zhang, Donghong Ji and Qiaoming Zhu. Tree kernel based relation extraction with context-sensitive structure parse tree Information. EMNLP’07.
- [5] Sunita Sarawagi. Information Extraction. 2008. Foundations and Trends in Databases.

注：学生开题前共阅读相关领域重要文献近百篇，这里仅列出报告中涉及的重点20篇。

7. 参考文献 (部分)

- [6] Mike Mintz, Steven Bills, Rion Snow, and Dan Jurafsky. 2009. *Distant supervision for relation extraction without labeled data*. *ACL'09.*
- [7] Sebastian Riedel, Limin Yao, and Andrew McCallum. 2010. *Modeling relations and their mentions without labeled text*. *ECML 2010*.
- [8] Raphael Hoffmann, Congle Zhang, Xiao Ling, Luke Zettlemoyer, and Daniel S. Weld. *2011. Knowledge-based weak supervision for information extraction of overlapping relations. ACL'11.*
- [9] Mihai Surdeanu, Julie Tibshirani, Ramesh Nallapati, Christopher D. Manning. *Multi-instance Multi-label Learning for Relation Extraction. EMNLP-CoNLL'12.*
- [10] Bonan, Ralph Grishman, Li Wan, Chang Wang, David Gondek. *Distant Supervision for Relation Extraction with an Incomplete Knowledge Base*. *NAACL'13.*

7. 参考文献 (部分)

- [11] J. Bengio, Y.; Ducharme, R.; Vincent, P.; and Janvin, C. 2003. A neural probabilistic language model. Journal of Machine Learning Research (JRML) 3:1137 − 1155.
- [12] Bordes, A.; Weston, J.; Collobert, R.; Bengio, Y.; et al. 2011. Learning structured embeddings of knowledge bases. In AAAI.
- [13] J. Bordes, A.; Glorot, X.; Weston, J.; and Bengio, Y. 2014. A semantic matching energy function for learning with multirelational data. Machine Learning 94(2):233 − 259
- [14] Chaiken, R.; Jenkins, B.; Larson, P.- ˚ A.; Ramsey, B.; Shakib,
- D.; Weaver, S.; and Zhou, J. 2008. Scope: easy and efficient parallel processing of massive data sets. Proceedings of the VLDB Endowment 1(2):1265 − 1276
- [15] Sunita Sarawagi. Information Extraction. 2008. Foundations and Trends in Databases.

注：学生开题前共阅读相关领域重要文献近百篇，这里仅列出报告中涉及的重点20篇。

7. 参考文献 (部分)

- [16] Weston, J.; Bordes, A.; Yakhnenko, O.; and Usunier, N. 2013. Connecting language and knowledge bases with embedding models for relation extraction. In Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing, 1366 − 1371. Seattle, Washington, USA: Association for Computational Linguistics.
- [17] Socher, R.; Chen, D.; Manning, C. D.; and Ng, A. 2013. Reasoning with neural tensor networks for knowledge base completion. In Advances in Neural Information Processing Systems, 926 − 93

- [18] Schwenk, H., and Gauvain, J.-L. 2002. Connectionist language modeling for large vocabulary continuous speech recognition. In ICASSP, 765 − 768. IEEE
- [19] Nickel, M.; Tresp, V.; and Kriegel, H.-P. 2011. A threeway model for collective learning on multi-relational data. In Proceedings of the 28th international conference on machine learning (ICML-11), 809 − 816
- [20] Mikolov, T.; tau Yih, W.; and Zweig, G. 2013. Linguistic regularities in continuous space word representations. In HLT-NAACL, 746 − 751. The Association for Computational Linguistics.

欢迎各位老师提问！

求知若饥、虚心若愚
fanmiao.cslt.thu@gmail.com