

# 清华—中科汇联项目合作总结

邢超 骆天一 刘荣

清华大学信息技术研究院语音与语言技术中心

北京中科汇联信息技术有限公司




# 目录

- 研究工作
  - 检索性能提升
  - 拼写检查
  - 知识图谱与反问
  - 线下训练模块
  - 部分调研工作
  - 排序学习
  - 错别字纠错
  - RNN自动古诗生成
  - RNN相似问句判别

# 研究工作—检索性能提升

- Lucene 检索性能的提高
  1. 关键词权重: NER,Parser
  2. 多字段组合的全维度检索: MERT做优化 提升2%




# 研究工作—拼写检查

- 基于语言模型与注音的拼写检查

- 例子


- “如何办理虎口” => “如何办理户口”

- “青华大学怎么走”=>”清华大学怎么走”



# 研究工作—知识图谱与反问

- 基于知识图谱的检索--DB



# 研究工作—知识图谱与反问

- 基于知识图谱的检索—检索

- 渤海银行项目

- 例子

电话是多少？


    请问是哪个员工的？

小明

    小明的电话\*\*\*\*\*


那小东的呢？

    小东的电话\*\*\*\*\*



# 研究工作—线下训练模型

- 线下训练模型
  - 遗传算法的模型训练 2%
  - 一种自动训练参数的模型
  - 一篇专利



# 研究工作—部分调研工作

- 调研工作
  - 句法分析工具
  - 语义归一化
  - 指代消歧

## 目录

一 目前工具.....	3
二 复旦 NLP.....	3
2.1 简介.....	3
2.2 算法.....	3
2.3 格式.....	3
2.4 性能和效率.....	4
三 斯坦福 NLP.....	5
3.1 简介.....	5
3.2 算法.....	5
3.3 格式.....	5
3.4 性能和效率.....	6
四 HanLP.....	6
4.1 简介.....	6
4.2 算法.....	6
4.3 格式.....	7
4.4 性能和效率.....	7
五 LTP.....	7
5.1 简介.....	7
5.2 算法.....	8
5.3 格式.....	8
5.4 性能和效率.....	8
六 总结.....	9
参考文献:.....	9
附录:.....	10
一 斯坦福句法树的相关标记.....	10
二 清华大学依存关系.....	13
三 哈工大相关标注.....	13

# 研究工作—排序学习

- 离线学习
  - p@1 准确率: 61%→65%
  - 训练速度: 最多提升1000倍
  - 论文发表: EMNLP 2015, 一篇长论文
- 在线学习
  - 用户可输入QA对进行系统调教→实时增加QA对
  - 用户对排名靠后结果点赞→实时排名提升

# 研究工作—错别字纠错

- 系统解决方案及功能
  - 大语料语言模型（全领域）+小语料语言模型（具体领域）
  - 支持国家领导人名字纠错
  - 支持错别字纠错对手动扩充
- 纠错效果（汇联的测试集）
  - 系统标出71处错误（实际错误6处，误报比约9/10）

我进期要申请美国。青华大学。李瑞坏是第十五届中央委员。



一个需要纠错的文本

纠错结果: **1** 进期 **null** **9** 青华大学 **null** **16** 坏 环

# 研究工作—RNN自动古诗生成

- 解决方案及功能
  - 利用RNN（循环神经网络）进行绝句自动生成
  - 支持五言绝句和七言绝句
  - 训练集：1000首五言绝句和1000首七言绝句
- 自动生成效果
  - 床前大风车 雨以此独甘 旧为玉所中 不为君恩开
  - 河曲回千里 鸣月隐世多 水水相苏乐 我以无金流
  - 风雪送春归 风水在征緋 至风有月人 今人几上情
- Demo

# 研究工作—RNN相似问句判别

- 解决方案及功能
  - 利用RNN（循环神经网络）进行相似问句判别
  - 系统用于自动模板扩充和问句相似度判别
  - 训练集：300多万QA对
- 相似度判别效果
  - Q:芜湖的计算机软件水平考试在什么地方报名？  
A:你可以到安徽师大呀。  
相似度为：0.823901910035
  - Q:芜湖的计算机软件水平考试在什么地方报名？  
A:1.找到卖你电脑发的磁盘 2.把磁盘放进光驱 3.按照向导安装  
相似度为：0.759943815081