

中文信息处理战略研讨会

中文信息处理的技术突破口

刘群

江西婺源

2012-4-14

中文信息处理已经取得的突破

- * 显示排版：CCDOS、UCDOS、方正、华光
- * 汉字输入：联想、五笔、微软、搜狗、亚伟
- * 语音合成：讯飞
- * 语音识别：讯飞、自动化所、声学所
- * 文字识别：汉王
- * 中文检索：百度、搜狗、TRS
- * 词语切分：ICTCLAS.....
- * 句法分析：？

与其他语言处理的差距

- * 句法分析
- * 语义角色标注
- * 机器翻译
- * 问答

下一个突破口在哪里？

- * 句法？（技术层面）
- * 语义？（技术层面）
- * 机器翻译？（应用层面）
- * 自动问答？（应用层面）

- * 核心：某种语义！（绕过句法、直达某种语义）

- * 机器翻译和自动问答的成熟都将依赖于语义问题的解决！

语义表示应该是什么样的？

* 词义

- * Ontology? (wordnet)

- * Hownet?

* 结构义

- * 依存? (句法到语义的过渡?)

- * 语义依存? (刘挺)

- * FrameNet?

- * 语义角色?

- * 逻辑?

- * 话题层次 (宋柔)

- * 情境?



最核心
的问题

语义资源建设

- * 资源为王?
- * 是不是有足够的资源就能解决汉语语义问题?
- * 语义资源建设的投入应该投向何方?
- * 众包方式如何应用?

语义分析算法

- * 训练


- * 有监督

- * 无监督


- * 半监督

- * 分析


基于规则的机器翻译研究范式




统计机器翻译研究范式



规则与统计结合的新研究范式



统计为主还是资源为王？



建议

* 资源建设：各种语言理论百花齐放

* Hownet

* Wordnet (北大CCD)

* Framenet (刘开瑛)

* 配价词典 (北大)

* 语义角色标注 (SRL)

* 语义依存 (刘挺)

* 话题层次 (宋柔)



缺口太大!

建议

- * 评测引导

- * 客观任务：不依赖于理论

- * 理论pk

建议

- * 语义资源建设与评测需要进行顶层设计
- 组织召集资源与评测系列会议

谢谢!