

中国中文信息学会战略研讨会，江西婺源

互联网时代的中文信息处理

孙乐

中国科学院软件研究所
中国中文信息学会

2012年4月13日


提纲

- 背景
- 互联网时代
- 中文信息处理再认识

背景

- **信息**是当前知识经济社会的基础支柱，信息将成为自然资源、土地、资本和劳动力之外创造财富的重要来源
- 人类创造和传承文明的最主要载体是**语言和文字**
- **中文信息处理技术**是以计算机为工具对中文（包括各种少数民族语言）信息（语音和文本）进行输入、存储、传输、输出、识别、转换、压缩、检索、分析、理解和生成等各种类型处理和加工的技术

互联网时代



Morgan Stanley, Internet Trends, June 7, 2010

30年来的演化



30年来的演化

- 用户界面：文本 → 图形 → 触摸

趋势：**自然**

- 功能：信息生成 → 信息交流 → 信息分享

趋势：**社会化**

提纲

- 背景
- 互联网时代
- 中文信息处理再认识

重要成果

- **汉字激光照排系统** 王选 / 北京大学
 - 国家最高科学技术奖 2001年
 - 联合国教科文组织科学奖 1995年
- **国家科技进步一等奖 5 项**
 - 华光Ⅲ型中文电子出版系统 (1987年 北京大学)
 - 联想式汉字微型机系统LX-PC (1988年 中科院计算所)
 - 北大方正电子出版系统 (1995年 北京大学)
 - 智能型英汉机器翻译系统 (1995年 中科院计算所)
 - 汉王形变练笔的手写识别方法与系统
(2001年 北京汉王科技有限公司)
- **国家技术发明奖二等奖**
 - 亚伟中文速录机技术

时间	“国家科技进步二等奖” 获奖项目
1989年	译星机器翻译系统（中软译星智能技术公司）
1997年	TRS 中文全文检索系统（易宝北信信息技术公司）
1999年	THOCR - 97综合集成汉字识别系统（清华大学）
1999年	藏汉双语信息处理系统（西北民族学院）
1999年	计算机全汉字信息处理系统集成（北京中易电子公司、中国标准技术开发公司、北京中易郑码新技术公司、北京大正电子有限公司）
2000年	WPS2000智能集成办公系统(金山电脑有限公司)
2001年	维汉声图文一体化信息处理综合系统(新疆大学)
2001年	藏文视窗平台、字处理软件和藏文网站(西北民族学院、西北民族语言文字信息技术研究所、甘肃同元信息系统技术有限责任公司)
2002年	KD系列汉语文语转换系统（科大讯飞）
2003年	高性能东方文字文档智能全信息数字化系统（清华大学）
2004年	藏文计算机键盘和输入编码方法研究（青海师范大学等）
2006年	汉王OCR技术及应用（汉王科技）
2011年	智能语音交互关键技术及应用开发平台（中国科学技术大学，科大讯飞）
2011年	综合型语言知识库（北京大学）
2011年	藏文软件研发与推广应用（西藏大学）

重要成果（个人计算时代）

- 汉字输入技术
(速录、手写识别、语音、汉字识别、少数民族语言编码)
- 汉字输出技术
(汉字激光照排)
- 其他
(全文检索、机器翻译、知识库等)

30年来的演化

- 用户界面：文本 → 图形 → 触摸

趋势：**自然**

- 功能：信息生成 → 信息交流 → 信息分享

趋势：**社会化**

中文信息处理再认识

■ 从自然的角度看

输入 → 语音
 手写
 图形→文字

输出 → 字形(书法、文化传承)
 趋势分析 (从数据/文本→图形转换)
 查询结果的多维度展示
 熟悉的语言 (翻译)

中文信息处理再认识

■ 从社会化的角度看

信息分享的**前提**：统一语义描述

信息分享的**基础**：

实体与实体之间的关系：大规模知识库

人与人之间以及真实世界的关联：社会计算

实体与真实世界的关联：实体链接

信息分享的**方式**：

信息推荐/过滤

动态数据

信息检索/问答系统

静态数据

中文信息处理再认识

- **中文信息技术**是以计算机为工具对中文（包括各种少数民族语言）信息（语音和文本）进行输入、存储、传输、输出、识别、转换、压缩、**检索、分析、理解**和生成等各种类型处理和加工的技术

- **中文信息技术**

是**中文语言世界与真实世界的桥梁**，

是**信息时代中国文化遗产与发扬的基础**，

是**互联网时代保护数字化国土的重要手段**，

是**知识经济时代获取财富（信息资源）的工具**。

为建设**创新型国家**
提供基础技术支撑

网络舆情监控、
社会化网络
群体智慧...

Web
演变

产业
推动

中文
信息
处理

知识
资源

国家
战略

中文

多学科
融合

行业：速记、教育、
情报、航空、
公共安全...

透析中文本质，
构建计算机用
中文语义理论

计算机科学、脑科学、
认知科学、智能科学、
哲学、数学

Web资源挖掘

谢谢！

恳请批评指正！

sunle@iscas.ac.cn