



北京大学

中国中文信息学会战略研讨会

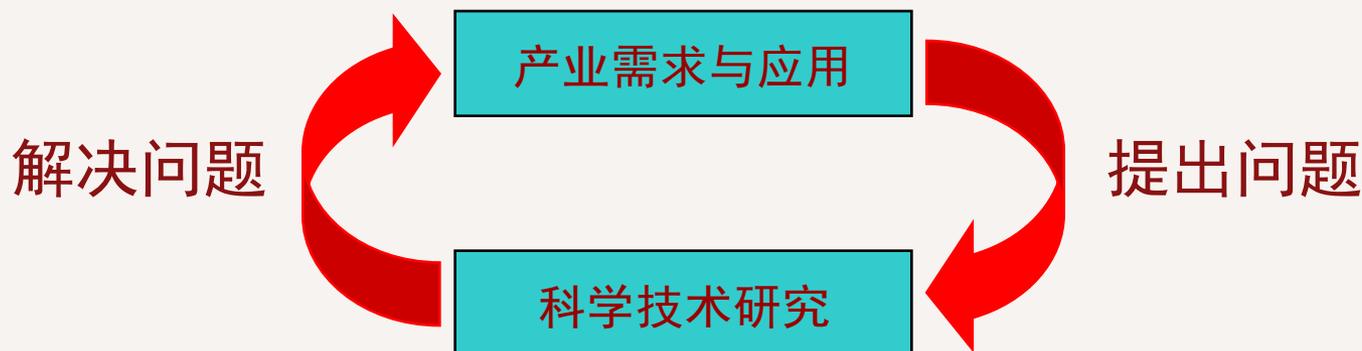
需求和应用是中文信息处理事业 发展的动力源泉

陈晓鸥 2012. 4. 13



主要内容

- 一. 在新的历史条件下的定义和理解
- 二. 产业发展方向及产业价值链分析
- 三. 主要的着眼点和着力点应在哪里
- 四. 领域的重要原始创新可能在哪里





一、在新的历史条件下的定义和理解



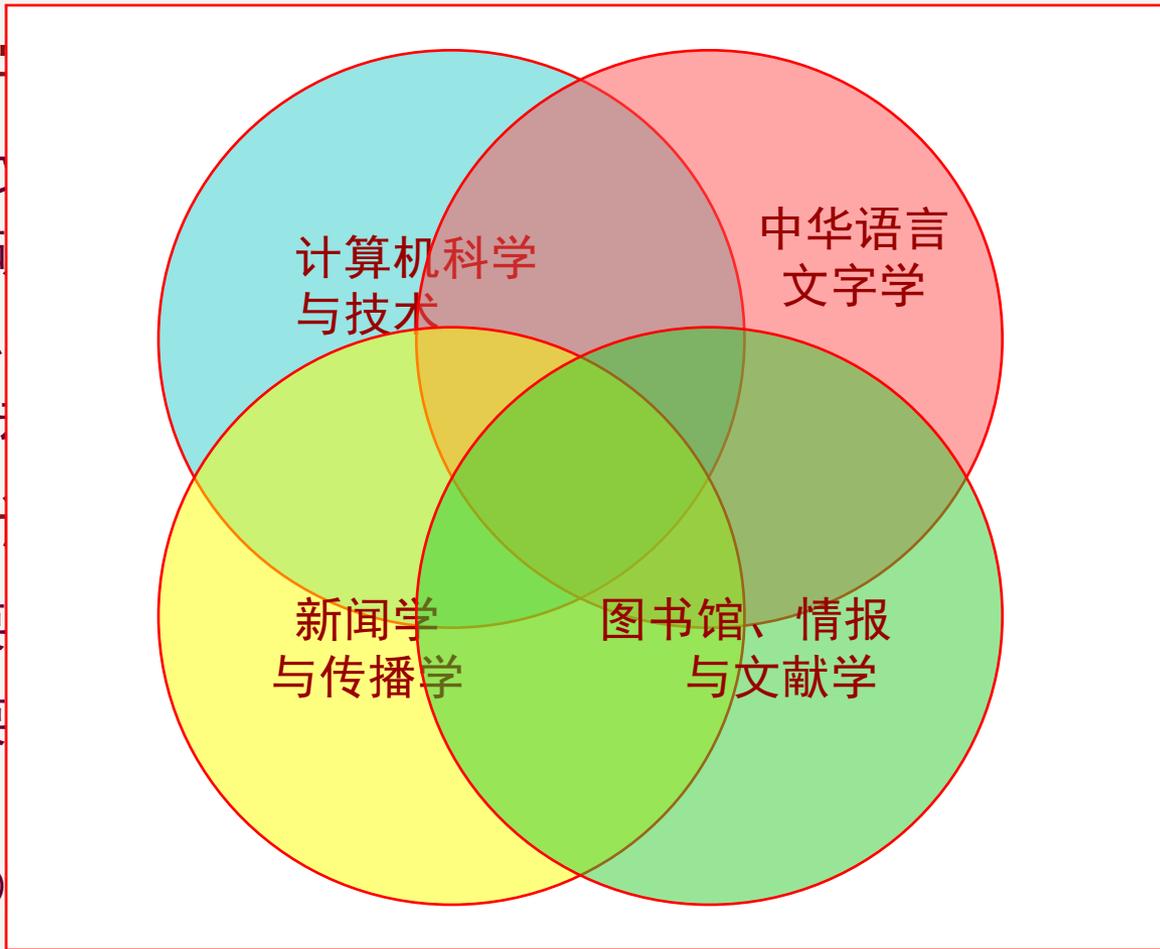
丢了文字学！

中文信息处理 \in 语言信息处理 \subset 计算语言学 = 计算机科学 \cap 应用语言学



一、在新的历史条件下的定义和理解

- 如果用文...
 - 中...
 - 科，是研...
 - 、识别、...
 - 论、方法...
- 抛出两个...
 - 要不要...
 - 要不要...
 - 信息学，...
 - 级学科)



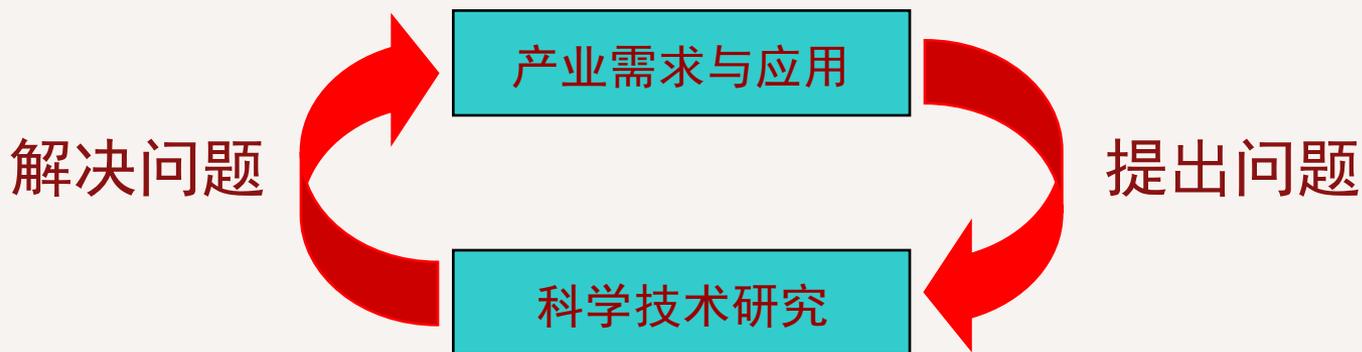
学的交叉学
、传输、输出
处理问题的理

比如加入人类
这两个都是一



二、产业发展方向及产业价值链分析

- 新的历史条件下中文信息处理面临的问题
 - 下一步的发展和研究失去强劲动力和重量级的话题
 - ◆ 理想的研究环境是

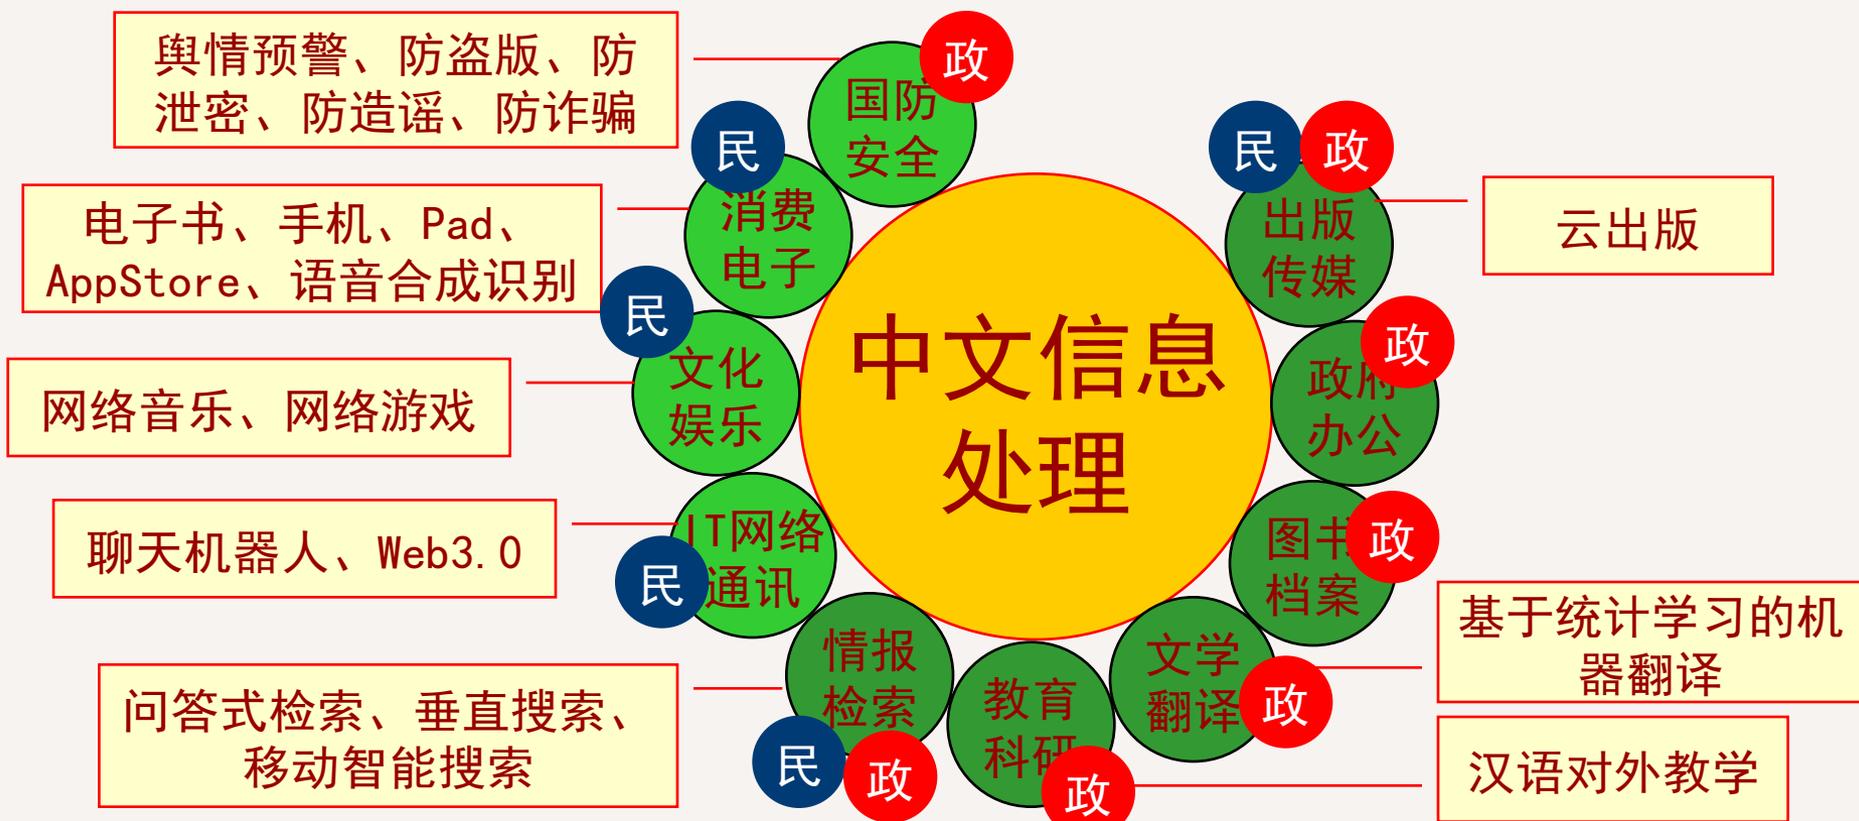


- ◆ 而中文信息处理的研究环境
 - 产业需求与应用的推动力比较弱
 - 新的研究成果在应用上表现不彰



二、产业发展方向及产业价值链分析

- 中文信息处理的产业需求和应用方是谁？
 - 产业发展方向、相关热点话题及投资来源的梳理

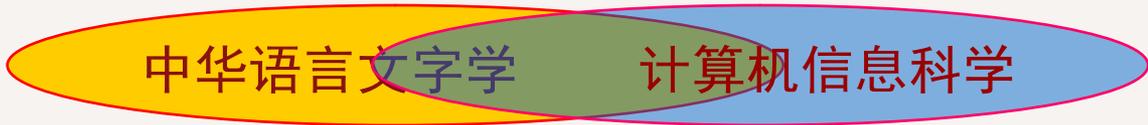




二、产业发展方向及产业价值链分析

■ 中文信息处理产业价值链分析

科学技术研究



| 算法、引擎、标准 | | |
|-------------|-------------|---------------|
| 音：语音识别、语音合成 | 义：搜索、语法语义分析 | 形：排版、字库、识别 |
| 芯片、板卡 | | |
| 音：语音识别、合成芯片 | | 形：RIP、汉卡、图形卡 |
| 终端设备 | | |
| 音：专用设备、移动终端 | | 形：打印机、电子书、PAD |
| 技术服务 | | |
| 音：解决方案、集成 | 义：搜索门户、应用软件 | 形：排版软件、集成 |



需求与应用

北京大学计算机科学技术研究所



二、产业发展方向及产业价值链分析

- 中文信息处理产业价值链分析——结论
 - 对中文音和形的产业发展，已经走完了价值链的全过程
 - 对中文义的产业发展，中间有断层
 - ◆ 对“义”的产业发展滞后于音和形的产业发展
 - ◆ 义的产业化应用，不需要芯片、板卡、终端这些产业化过程
 - 我认为重要方向或方面应该在“义”的领域，特别是对Web2.0、3.0相关的产业

| | | |
|-------------|-------------|---------------|
| | 算法、引擎、标准 | |
| 音：语音识别、语音合成 | 义：搜索、语法语义分析 | 形：排版、字库、识别 |
| | 芯片、板卡 | |
| 音：语音识别、合成芯片 | | 形：RIP、汉卡、图形卡 |
| | 终端设备 | |
| 音：专用设备、移动终端 | | 形：打印机、电子书、PAD |
| | 技术服务 | |
| 音：解决方案、集成 | 义：搜索门户、应用软件 | 形：排版软件、集成 |



三、主要的着眼点和着力点应在哪里

- 前三十年着力于——如何让中文进入计算机
- 后三十年着力与——如何让计算机“理解”中

| | | |
|-------------|-------------|---------------|
| | 算法引擎 | |
| 音：语音识别、语音合成 | 义：搜索、语法语义分析 | 形：排版、字库、识别 |
| | 芯片、板卡 | |
| 音：语音识别、语音合成 | | 形：RIP、汉卡、图形卡 |
| | 终端设备 | |
| 音：专用设备、移动终端 | | 形：打印机、电子书、PAD |
| | 技术服务 | |
| 音：解决方案、集成 | 义：搜索引擎、应用软件 | 形：排版软件、集成 |



三、主要的着眼点和着力点应在哪里

- 推荐两个着力点——之一：语义网及关联数据网（云）
 - 中文的Linked Open Data（LOD）在那里？

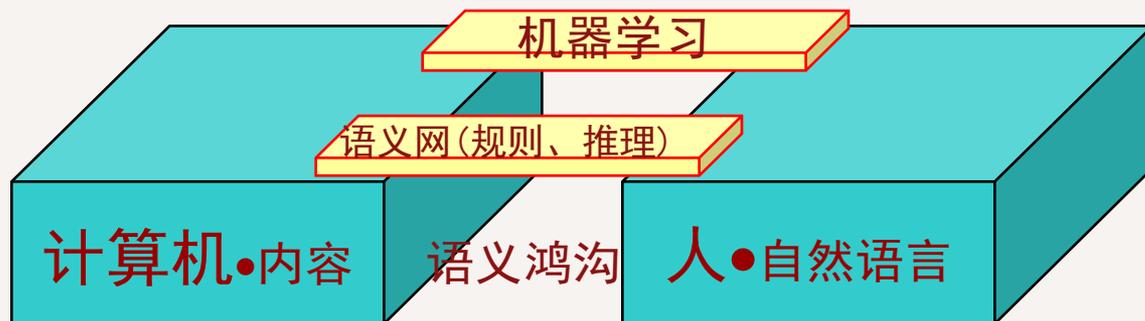
表 4 DBpedia的跨语言摘要^[16]

| 序号 | 语言 | 摘要个数 |
|----|------|-----------|
| 1 | 英语 | 3 144 000 |
| 2 | 德语 | 503 000 |
| 3 | 法语 | 545 000 |
| 4 | 波兰语 | 430 000 |
| 5 | 荷兰语 | 392 000 |
| 6 | 意大利语 | 381 000 |
| 7 | 西班牙语 | 362 000 |
| 8 | 日语 | 275 000 |
| 9 | 葡萄牙语 | 367 000 |
| 10 | 瑞典语 | 213 000 |
| 11 | 汉语 | 179 000 |



三、主要的着眼点和着力点应在哪里

- 推荐两个着力点——之二：基于自然语言的精准检索（问答式检索）
 - 全文检索动辄几十万、几千万的检索结果，人们需要更精准的检索
 - 除了文本内容以外，越来越多的非文本内容需要检索，如图片、视频、音乐、语音等等
 - ◆ 对这些内容的最佳检索条件，非自然语言莫数
 - ◆ 实现基于自然语言的检索，必须解决语义鸿沟问题
 - ◆ 跨越语义鸿沟的常用手段是：机器学习、语义网





四、领域的重要原始创新可能在哪里

- 重要的原始创新可能在云技术与语义网相结合的领域里
 - 回顾一下历史——每一次新的计算平台出现，都对中文信息处理提出新的挑战，带来创新的高潮
 - ◆ 小型机计算时代——使汉字进入计算机
 - ◆ 微型机计算时代——使中文计算机出版走向实用
 - ◆ 互联网计算时代——使中文全文检索得以普及
 - ◆ 移动云计算时代——？使中文自然语言检索得以实现
 - 重要的理论原始创新可能在
 - ◆ 基于中文自然语言的信息检索
 - 搜索引擎升级、框计算、聊天机器人
 - ◆ 互联网中文云安全
 - 舆情预警、防盗版、防泄密、防造谣、防诈骗



北京大学

谢 谢 ！