



# 信息检索

# 讲课内容

- 目前的信息检索(搜索)技术实质上是融合了文本及多媒体检索、数据挖掘、机器学习和自然语言处理的综合学科。
- 因此本课程的内容包括：
  - 信息检索的基本知识
    - 布尔检索
    - 倒排索引
    - 向量空间模型
  - 简单的自然语言处理
    - 语言模型
  - 信息检索/知识发现/机器学习/数据挖掘中的经典算法
    - 分类
    - 聚类

# 参考书籍

- Christopher D. Manning, Prabhakar Raghavan & Hinrich Schütze, **Introduction to Information Retrieval**, Cambridge University Press 2008  
Electronic version (draft) can be downloaded from  
<http://www-csli.stanford.edu/~hinrich/information-retrieval-book.html>
- 王斌译, **信息检索导论 修订版**, 人民邮电出版社出版, 2019年7月。



# 考核方式

- 平时作业 + 期末考试
  - 期末考试 60%
  - 平时40%
    - 不定期考勤 5%
    - 实验：开发一个“轻型搜索引擎” (35%)
    - 只要能想到就能做到，发挥你的奇思妙想，下一个就“微软、Google”诞生在你们中间！！！

# Why 搜索技术?

**信息过载**—数据爆炸性的增长，而人的处理能力有限

- Internet上网站总数

1995	2004	2006	2010	2011	2012	2014
1.8万	500万	1亿	2.55亿	5.55亿	6.34	10亿

- 网页
- 视频

Web页面数量近千亿，数据总量约10万亿GB (均为估计数据)

48	YouTube上每分钟上传视频的小时数
250万	被上传到YouTube新闻相关视频的小时数
883亿	Google sites (incl. YouTube) 每月观看的视频数
2000万	Facebook 上每月上传的视频数
15648303	谷歌视频网站的独立访客访问数量，视频领域排名第一


- 搜索

2012	谷歌的总搜索次数 <b>1.2万亿</b>
2016	百度每天收到搜索请求 <b>60亿次</b> ， 谷歌大约有 <b>55亿次</b>


- 全球智能移动终端互联网用户数量已达到**30亿(2016)**,**13亿(2012年底)**

67亿	手机订阅的数量
31%	美国互联网用户中，有 <b>31%</b> 都在使用平板电脑或电子阅读器
1. 3EB	2012年每月的全球移动数据流量约为 $1.3EB (1EB=2^{10}PB)$
59%	全球移动数据流量 <b>59%</b> 的份额来自于视频
500MB	智能手机平均每月消耗的数据流量为 <b>500MB</b>
504kbps	全球所有手机平均移动网络的连接速度为 <b>504kbps</b>
1820kbps	全球智能手机平均移动网络的连接速度为 <b>1820kbps</b>

# Web数据类型众多



# 国际互联网发展历程




- Facebook的到来意味着社交网络以及Internet2.0发展的成熟，而Twitter以及新浪微博的到来，预示着全球互联网进入Internet3.0时代。
- Internet3.0，意味着：受众消失，微众来临；成为生产消费者之前，个体首先在自组织网络中实时连接起来；微众不再是调查统计意义上抽象的某类群体或者大众分众窄众，微分到个体；而微众联动又足以脱离媒体影响，自主完成交流分享、消费决策过程。这意味着即时的、人人参与的以及移动的智能网络到来。

# Internet3.0特征图谱


微众首先在自组织网络中实时连接起来，在此过程中**微内容**与信息能够得到自由整合与聚合

**可信度**高的信息将会被信息检索更好的搜索和重视，提供该信息的用户信任度也将提高

网络应用与服务、网络内容与信息将提供高度的**个性化**服务，如个性化的web os



- Web 3.0
  - 大众从消费者变成生产者
  - 社会网络兴起
- 人类跑步进入大数据(Big Data)时代！！！
- 一转身又跑步进入人工智能(AI)时代！！！



# 大数据的4V特性



体量 Volume

非结构化数据的超大规模和增长  
总数据量的80~90%  
比结构化数据增长快10倍到50倍  
是传统数据仓库的10倍到50倍

多样性 Variety

大数据的异构和多样性  
很多不同形式（文本、图像、视频、机器数据）  
无模式或者模式不明显  
不连贯的语法或句义

价值密度 Value

大量的不相关信息  
对未来趋势与模式的可预测分析  
深度复杂分析（机器学习、人工智能Vs传统商务智能  
(咨询、报告等)


速度 Velocity

实时分析而非批量式分析  
数据输入、处理与丢弃  
立竿见影而非事后见效

# 信息过载， 如何解决？



- 搜索技术应运而生！
- 从大规模**非结构化数据**(通常是文本)的集合(通常保存在计算机上)中找出**满足用户信息需求的资料**(通常是文档)的过程
- 作为一门学科，是研究信息的获取(acquisition)、表示(representation)、存储(storage)、组织(organization)和访问(access)的一门学问。



搜索系统 甚至可以是试衣间！



# 本课程的意义

## 市场发展的需求

- 用户需要信息检索技术：互联网的信息量太大，寻找信息耗时耗力
- 公司需要信息检索技术：信息检索技术可以挣大钱，搜索引擎改变了人们获取信息的方式，Google、Microsoft、Baidu，还有一些公司如Tencent、Sina、Sohu、360、神马都加入到这个搜索技术的竞争
- 人才的竞争：搜索人才人数出现缺口，非常抢手，待遇如日中天
- 是不是泡沫？：2000年左右出现的网络泡沫和现在的互联网有什么不同，搜索引擎在其中占什么位置(2010)？

# 课程特点

- 不是教如何使用信息检索工具(学校有专门的课程)，而是了解信息检索工具背后的基本原理和技术，并且能够进行深层的研究或开发相关的应用。
- 基本原理 + 广泛实践

# 搜索技术的历史

## 历史分段

- 计算机出现以前
- 计算机出现以后
- Internet出现以后

**SIGIR2020** - The **43<sup>rd</sup>** International ACM SIGIR  
Conference on Research and Development in Information  
Retrieval

- **计算机出现以前**
  - 约4000年前，人类就开始有目的地组织信息，一个典型的例子就是图书中的目录。
  - 随后，逐渐出现索引的概念，即从一些词和概念指向相关信息或者文档的指针。
  - 计算机问世以前，人们主要通过手工方式来建立索引。
  - 例子：词典(拼音检字、部首笔画检字等)

- **1948**
  - C. N. Mooers在其MIT的硕士论文中第一次创造了“**Information Retrieval**”这个术语。
- **1960—70年代**
  - 人们开始使用计算机为一些小规模科技和商业文献的摘要建立文本检索系统。
  - 产生了布尔模型(Boolean Model)、向量空间模型(Vector Space Model)和概率检索模型(Probabilistic Model)。康奈尔大学的Salton领导的研究小组是该领域研究的佼佼者。
  - 伦敦城市大学的Robertson及剑桥大学的Sparck Jones是概率模型的倡导者。

- **1980年代**

- 出现了一些商用的较大规模数据库检索系统
- Lexis-Nexis
- Dialog
- MEDLINE


- **1986**: Internet正式形成
- **1990's**
  - 第一个网络搜索工具: 1990年加拿大蒙特利尔麦吉尔(McGill)大学开发的FTP搜索工具 Archie
  - 第一个Web搜索引擎: 1994年美国CMU开发的Lycos
  - 1995: 斯坦福大学博士生开发的**Yahoo**
  - 1998: 斯坦福大学博士生开发的**Google**, 提出PageRank计算公式。
  - 1998: 基于语言模型的IR模型提出。

- **2000's**

- 信息抽取
- Whizbang
- Fetch
- Burning Glass
- 问答系统
- TREC Q/A track
- 2000年，**百度**成立


- 2000以来的其它重要事件
  - 多媒体 IR
    - Image
    - Video
    - Audio and music
  - 跨语言 IR
    - DARPA Tides
  - 文本摘要
    - DUC评测
  - 自动问答
  - 自动对话

# 2012年12月全球搜索市场份额




# 2013年8月国内搜索市场份额

■ 百度 ■ 360搜索 ■ 搜狗 ■ 搜搜 ■ 谷歌 ■ 必应 ■ 雅虎 ■ 有道 ■ 其他




# 2015年11月至2016年4月全球搜索市场份额走势

2015年11月至2016年4月全球搜索引擎市场份额走势图




# 2016年4月全球搜索市场份额

2016年4月全球搜索引擎市场份额分布图



# 2016年8月国内搜索市场份额

StatCounter Global Stats  
Top 5 Search Engines in China on Aug 2016



# 2017年1月全球搜索市场份额

StatCounter Global Stats  
Desktop, Mobile & Tablet Search Engine Market Share Worldwide on Jan 2017



# 2019年1月全球搜索市场份额



## 国内搜索市场份额




# 搜索的基本概念

- **用户需求(User Need, UN)**: 用户需要获得的信息
  - 严格地说, UN只存在于用户的内心, 但是通常用文本来描述, 如查找与2016奥运会相关的新闻, 有时也称为主题(Topic)
  - UN提交给检索系统时称为查询(Query), 如 2016 奥运会, 对同一个UN, 不同人不同时候可以构造出不同的Query, 比如上述需求也可表示成 2016奥运会新闻, Query在IR系统中往往还有内部表示

- **文档(Document):** 检索的对象
  - 可以是文本，也可以是图像、视频、语音等多媒体文档，text retrieval / image retrieval / video retrieval / speech retrieval / multimedia retrieval
  - 可以是无格式、半格式、有格式的
- **文档集合(Collection):** 所有待检索的文档构成的集合
  - 也称为Repository, Corpus, Dataset


- **相关(Relevant)、相关度(Relevance)、相似度(Similarity)**
  - 相关取决于用户的判断，是一个主观概念
  - 不同用户做出的判断很难保证一致
  - 即使是同一用户在不同时期、不同环境下做出的判断也不尽相同

- 定义“相关性”的两个角度：
  - 系统角度：系统输出结果，用户是信息的接受者。
    - 这种理解置用户于被动的地位，研究的重心落在系统本身。
    - **主题相关性**：检索系统检出的文档的主题即核心内容与用户的信息需求相匹配。
    - 系统角度相关并不和用户脱节。系统角度定义的相关简单可以计算。
  - 用户角度：观察用户对检索结果的反应，是系统输出向用户需求的投射。
    - 相关性被认为是用户方面的属性。
    - 用户角度定义的相关目前仍然难以计算。
- 现代信息检索研究中仍然主要采用系统角度定义的主题相关性概念，当然也强调考虑用户的认知因素。



- 形式上说，信息检索中的相关度是一个函数 $f$ ，输入是查询 $Q$ 、文档 $D$ 和文档集合 $C$ ，返回的是一个实数值  $R$ ,  $R = f(Q, D, C)$
- 信息搜索: 给定一个查询 $Q$ ，从文档集合 $C$ 中计算每篇文档 $D$ 与 $Q$ 的相关度并排序(Ranking)。
- 相关度通常只有相对意义，对一个 $Q$ ，不同文档的相关度可以比较，而对于不同的 $Q$ 的相关度不便比较。
- 相关度的输入信息可以更多，比如用户的背景信息、用户的查询历史等等。
- 现代信息检索中相关度不是唯一度量，如还有：重要度、权威度、新颖度等度量。或者说这些因子都影响“相关度”。

# 信息检索系统的基本组成



- 用户接口(User Interface): 用户和IR系统的人机接口
  - 输入查询(Query)
  - 返回排序后的结果文档(Ranked Docs)并对其进行可视化(Visualization)
  - 支持用户进行相关反馈(Feedback)
- 用户的两种任务: retrieval 或者 browsing
- IR的两种模式: pull (ad hoc) 或者 push (filtering)
  - **Pull**: 用户主动发起请求，在一个相对稳定的数据集合上进行查询，比如百度搜索
  - **Push**: 用户事先定义自己的兴趣，系统在不断到来的流动数据上进行操作，将满足用户兴趣的数据推送给用户。典型就是推荐系统，比如今日头条。

- **文本处理(Text Operations):** 对查询和文本进行的预处理操作
  - 中文分词(Chinese Word Segmentation)
  - 词干还原(Stemming)
  - 停用词消除(Stop Word Removal)
- **查询处理(Query Operations):** 对经过文本处理后的查询进行进一步处理，得到查询的内部表示(Query Representation)
  - **查询扩展(Query Expansion):** 利用同义词或者近义词对查询进行扩展
  - **查询重构(Query Reconstruction):** 利用用户的相关反馈信息对查询进行修改


- **文本索引(Indexing)**: 对经过文本处理后的文本进行进一步处理，得到文本的内部表示 (Text Representation)，通常基于索引项(Term)来表示
  - 向量化、概率计算
  - 组成倒排表进行存储
- **搜索(Searching)**: 从文本中查找包含查询中索引项的文档
- **排序(Ranking)**: 对搜索出的文档按照某种方式来计算其相关度
- **Logical View**: 指的是查询或者文档的表示，通常采用一些关键词或者索引项(index term)来表示一个查询或者文档。

# 搜索技术的应用

- 垂直搜索

The screenshot shows the Google News interface. At the top, there is a search bar with a magnifying glass icon and a dropdown menu set to '中国版 (China)'. Below the search bar, the word '新闻' (News) is displayed. On the left, a sidebar lists various news categories under '焦点报道' (Top Stories), including International/Hong Kong, Mainland, Finance, Entertainment, Technology, Internet, Sports, Society, Cars, Real Estate, Education, and Hot Reports. Below this, there is a link to '所有内容' (All Content). The main content area features a section titled '焦点报道' with several news items. One item is highlighted with a blue box: '康菲『玩弄』海洋局' (CNOOC 'plays with' the Marine Ministry) from '凤凰网' (Ifeng.com) 22 minutes ago. Other visible news items include: '民政部将在全国范围内入户调查获居民诉求' (Ministry of Civil Affairs will conduct door-to-door surveys across the country to understand residents' demands) from '凤凰网' 6 hours ago; '中国宋庆龄基金会称与地方基金会无隶属关系' (The Chinese Sun Yat-sen Foundation claims no affiliation with local foundations) from '新浪网' 1 hour ago; '卡扎菲被曝或逃往尼日尔(图)' (Kadafi reportedly fled to Niger) from '搜狐' 25 minutes ago; '美国高官称9·11纪念暂无袭击威胁' (U.S. officials say there is no threat to the 9·11 memorial) from '新民网' 2 minutes ago; '温家宝：力推找矿突破战略 积极参与国际合作' (Premier Wen Jiabao: Promote mineral exploration breakthrough strategy, actively participate in international cooperation) from '搜狐' 7 minutes ago; '野田内阁亟需解决经济外交难题' (The Noda cabinet needs to solve economic and diplomatic difficulties) from '新华网' 1 hour ago; '市三医院手术室火灾原因查明 分管消防副院长被免职' (The cause of the fire in the operating room of the third city hospital has been clarified, and the vice president in charge of fire safety has been dismissed) from '新浪网' 2 minutes ago; and '2011中国企业500强发布 国企316家超六成' (The list of China's top 500 enterprises in 2011 was released, with state-owned enterprises accounting for over 60%) from '和讯网' 24 minutes ago.

## • 舆情监控




# • 情报与反恐

## BASICS OF SOCIAL FOR COUNTERTER

By Rebecca Garcia

It is well-known that extremist organizations have embraced the Internet for its vast and immediate worldwide reach for recruitment. In 2006, the University of Haifa's Gabriel Weimann published groundbreaking research in his book *Terror on the Internet: The New Arena, the New Challenges*, and discovered approximately 4,300 terrorist-related websites.



## 美国“棱镜”监控项目曝光

泄密人：爱德华·斯诺登，前美国中情局分析师

- 预测

➤ 实例：2013年奥斯卡大奖花落谁家？



微软纽约研究院专家  
David Rothschild




Oscars Ballot Predictor  
(奥斯卡投票预测器)，为  
所有24个类别的奥斯卡得奖  
奖项提供实时预测

- 谷歌AlphaGo



# • 精准医疗

## “沃森医生”的诊断过程




# Web 搜索技术

- WWW发展迅速， Web文本数据以P=1000T计。而多媒体数据，如图片、视频、音频信息以1000P计，而且正快速增加。
- Web可以看做巨型的、非结构化的、无所不在的数据库，除了传统的书面文档，目前口语形式的文档正在迅速增加(微博、微信、短信等)
- Web的发展要求有效的工具来管理、检索、过滤信息： Data mining
- 结论：信息获取、组织和搜索将成为现代社会的不可缺少的基础服务。


# World Wide Web是什么？

- The world wide web (web) is a network of information **resources**. The web relies on three mechanisms to make these resources readily available to the widest possible audience:
- 1. A **uniform naming scheme** for locating resources on the Web (e.g., **URLs**).
- 2. **Protocols**, for access to named resources over the Web (e.g., **HTTP**).
- 3. Hypertext, for easy navigation among resources (e.g., **HTML**).

# Web资源的拓扑结构(有向图)



网页为节点  
网页中的HyperLink为有向边



## ■ 搜索引擎市场的激烈竞争

- Google, Bing, Baidu, 阿里巴巴, 京东, 360, 搜狗, 神马对搜索引擎市场激烈竞争, 公司上市造就数以百计的千万富翁, 对与搜索相关的人才需求强烈。
- MSRA建立搜索研究中心, 努力追赶, Bing依然差距明显。
- 主要门户网站, 电子商务网站纷纷推出搜索引擎产品, 如阿里巴巴、京东等
  - 面向领域的搜索引擎

# 目前最受北美IT毕业生青睐的公司

- Google
- Apple
- Facebook
- Microsoft
- Yahoo!
- 其中有3个公司的主要业务之一是信息检索。
- 微软已经认为过去没有重视搜索是犯了巨大错误，目前正在飞速追赶。
- 目前Google、微软在美国正在建立巨型的数据处理中心，保存通过Internet、卫星等收集的数据。
- 上述公司的搜索部门在面试时，一般会问关于现代检索的核心算法、概念等。
- 从全球范围看，急需能开发搜索、数据挖掘和大数据分析的人才，招人数量巨大。

# 国内IT

- 百度
- 搜狗
- 360
- 人民搜索
- 一搜
- 爱问
- 阿里巴巴，淘宝
- 腾讯
- 京东
- ... ...
- 中国大学生评出的2008最佳雇主中有半数和搜索有关。

# 市场的需求

- 所有的网站都需要搜索引擎，但目前很多借用Google等，搜索效果不好，因为不专业，Google的排序算法可能并不适合该网站的页面链接分析。
  - 微博、twitter、微信等实时信息检索
  - Facebook等涉及社会网络的实时信息检索以及事件发现
  - Flickr、Youtube 等共享图片和视频信息的检索
  - 医学和生物领域的检索
  - 无论是政府还是商家，都更重视网络上的舆情(商业情报)，包括讨论的热点及反应出的问题。而这些必须基于对网站、论坛、博客、社会网络等媒体内容的搜集和分析。


# 搜索技术现状

- 目前基本认为是处于关键词(bag of words)匹配的阶段
- 未来的远景区
  - 个性化
  - 专业化
  - 多媒体检索
  - 智能化
  - 自动问答
  - 自动对话
- 检索形式的创新，不是输入关键词，可能是任务(Task)，得到的是解决方案(Solution)。

# 和以往IR研究的区别

- 原来是图书馆学的专业方向，但目前的研究和以前的研究相差太大了。
- 目前的研究者来自
  - 数据库、人工智能、计算机算法、人机交互、多媒体、移动通讯、模式识别、地理信息和卫星图像处理等，都加入到这个领域。

# Web search basics



# 进入2000后对 IR 的研究

## ■ 2000's

- 基于网页链接分析技术
  - Google
- 网页的排序技术
  - PageRank
- 网页的分析技术
  - 基于块的分解，内容提取和理解

# IR 新课题1：自然语言理解

- 自动文本摘要或主题的提取
  - 抽取式 Extractive Summarization
  - 生成式 Abstractive Summarization
- 会话体文本的处理
  - 微博，博客，微信
- 自然语言的复杂性
  - 话说普京与奥巴马赛跑，普京第一，奥巴马第二
  - 俄罗斯媒体：在国际领导人赛跑中，普京勇夺冠军，  
奥巴马倒数第一！
  - 美国媒体：在国际领导人赛跑中，奥巴马勇夺亚军，  
普京倒数第二！

- 自然语言的复杂性
  - 南京市长江大桥
  - 南京市长江大桥
  - 南京市长江大桥
- 乒乓球拍卖完了
  - 乒乓球拍卖完了
  - 乒乓球拍卖完了

• 人工智能的终极目标！



# IR 新课题2：多媒体检索

- Multimedia (多媒体的检索技术)
  - Image
  - Video
  - Audio and music
- 图像的自动标注,使得对图像的检索可以借助关键词进行检索


Image				
Original Annotation	people pool swimmers water	cars formula tracks wall	clouds mountain sky water	field foals horses mare
Automatic Annotation	water people swimmers pool	cars tracks wall formula	sky clouds mountain park	field horses foals mare

# IR新课题3：垂直检索技术

- 目前通用的搜索引擎对Internet网页的覆盖率小于50%。未来计算机的存储和运算能力都不可能100%的覆盖，需要面向具体领域的专用搜索引擎
  - 如就业、股票、宾馆饭店、地图、天气、商品查找、任务、旅游，.....
- 垂直检索也是未来利用移动通讯设备检索的支撑技术

# 微软的科技论文垂直检索系统

## Architecture



# IR 新课题4: 移动搜索-Mobile Search

- Google、百度、NEC、微软等早就已经开始了对手机检索系统的研究。
- 解决的科学与技术问题
  - 如何在**小屏幕上**显示用户的检索结果，如何在**小键盘上**输入不方便的情况下进行文本检索？
  - 能否通过语音检索？
  - 能否通过图片进行检索？因为手机更方便语音和图像。



今日头条 让广告成为一条有用的资讯

首页简介 | 广告资源 | 开户流程

今日头条

今日话题 头条号 智能推荐 北京 新闻

你不知道什么梗？许是深入人心，是一时兴起，各生遐想

小预算，大收益！


头条广告资源覆盖7亿+用户，一站式解决本地商家推广、活动推广、APP下载、电话咨询等营销诉求，是获得更多客流的营销神器！

了解头条广告，免费注册

A screenshot of the Toutiao (今日头条) mobile application. The top navigation bar is red with the text "今日头条" and "让广告成为一条有用的资讯". Below the bar are three menu items: "首页简介", "广告资源", and "开户流程". The main content area shows a stack of smartphone screens displaying various news articles and advertisements from the Toutiao platform. A large text overlay on the right side reads "小预算，大收益！" followed by a descriptive paragraph about the advertising resources. At the bottom, there is a red button with the text "了解头条广告，免费注册".

# IR 新课题5：对社交媒体信息检索

- 微博、Twitter等实时信息检索
  - Wordpress(博客)、Yahoo!answers、百度知道(论坛)
  - Flickr、YouTube(共享视频)
  - Facebook、人人(社交网络)
  - Wikipedia(在线百科词典)



# 现实世界和虚拟世界

- 目前我们生活在2个世界
  - 现实世界和网络上的虚拟世界
- 两者的关系是什么，以及如何利用虚拟世界了解现实世界，是目前的研究热点
  - 虚拟世界中用户之间的关系网络及社区划分
  - 虚拟世界中的领袖，利用虚拟世界的信息，发现现实世界的突发事件
    - 地震、疾病的传播、突发事件的发现、追踪和分析


# 如何利用虚拟世界研究现实世界

- 网上人气榜的排名
- 网上对产品、任务、事件的评论
- 网上所反映的最关心的热点和焦点是什么？
- 网上对事物、人物、事件的正面和反面评价的比例是什么？
- 作弊(Spam)网页、重复(Duplicate)网页及水军(Water Army)网页的发现

# 行为分析-用户画像

## 活跃互联网保民典型画像

注：对最为活跃的30%互联网保民进行的画像分析




# IR新课题7：自动问答(Question-Answer)

- 定义：允许用户以自然语言方式询问，系统从单语或多语文档集中查找并返回确切答案或者蕴含答案文本片段，是一种新型信息检索方式。
  - 姚明的身高是多少？
  - 从青岛校区院到火车站怎么走？
  - 树上有三只鸟，又飞来了两只，现在有多少只？
- 问答系统是下一代搜索引擎的基本形态



## IR-based QA

基于关键词匹配 + 信息抽取，仍然是基于浅层语义分析




## Community QA

依赖于网民贡献，问答过程仍然依赖于关键词检索技术



## KB-based QA

Knowledge Base



# 沃森智能问答IBM Watson

- 沃森(Watson): 2011年, IBM研发的超级计算机“沃森”在美国知识竞赛节目《危险边缘Jeopardy!》中上演“人机问答大战”, 战胜人类选手Ken和Brad



辅助医疗



金融辅助决策




企业服务

# IR新课题8：知识发现


知识图谱的构建是目前的最大热门领域之一

- Wiki 百科
- Freebase
- DBpedia
- Yago
- 百度百科
- 互动百科




# 知识图谱→实体与关系

- 知识图谱包括实体与关系
  - 节点代表实体
  - 连边代表关系
- 事实可以用三元组表示
  - (head, relation, tail):
- 代表知识图谱
  - WordNet: 语言知识
  - Freebase: 世界知识



# 知识图谱的生命周期



# 知识图谱应用

业务需求



语义理解




数据关联探索



业务动态扩展



智能检索与问答



技术方案



数据结构化



数据融合



自由扩展数据模式



行业智能问答



数据挑战

非结构化数据  
计算机难以理解



多源异构数据  
难以融合



数据模式动态变  
迁困难



数据使用专业程  
度过高

# 行业知识图谱应用一览


## 股票问回



## 金融证券




知识库顶层设计



## 生物医疗

Complete Ontology (knowledge) for Lacking Nitrogen




Palantir government



## 农业


## 图书情报

Turn Massive Raw Data Into Business Concepts



## 政府

## 电信



## 出版

# 知识图谱应用→自动推理

## • 梁启超的儿子的老婆的情人的父亲

梁启超的儿子的老婆的情人的父亲

网页 论坛 知识 新闻 博客 百科 更多 什么是分类搜索 找到约 173,657 条结果

梁启超的儿子的老婆的情人的父亲：

 徐申如

**推理说明：**梁启超的儿子是梁思成。梁思成的妻子是林徽因。林徽因的情人是徐志摩。徐志摩的父亲是徐申如


[梁启超的儿子的老婆的情人的老婆-读书-DoNews.COM](#)  
2004年6月15日... 作者 帖子主题：知道是谁不？ 作者 帖子主题：RE：梁启超的儿子的老婆的情人的老婆【(shengfang)回复(cool)的大作】陆小慢 作者 帖子主题：RE:...  
[donews IT门户 - home.donews.com/.../477746.html - 2004-6-15 - 快照 - 预览](#)

[梁启超的儿子的老婆的情人的父亲 最佳答案 搜狗知识搜索](#)

梁启超的儿子的老婆的情人的老婆是谁 - 已解决 [搜搜问问](#) 2007-11-25  
答：梁启超的儿子是中国的著名建筑师梁思成 梁思成的老婆呢叫林徽因看过《人间四月天》的人应该知道啊 那么林徽因的情人呢就是大名鼎鼎的徐志摩啦 那么徐志摩的老婆...  
梁启超的儿子的老婆的情人的老婆是谁？？？ - 已解决 [搜搜问问](#) 2011-3-4  
梁启超的儿子的太太的情人的太太分别是谁 - 已解决 [搜搜问问](#) 2007-12-9  
梁启超的儿子的妻子的情人的老婆是谁？ [百度知道](#) 2006-10-4


**梁启超**  
 梁启超(1873.2.23—1929.1.19)，生于广东新会。1894年，梁启超提倡变法，并于上海主撰《时务报》，著《变法通议》，刊布报端，启发国人之革新思想。与谭嗣同...  
相关阅读 ▾  
出生：1873-02-23 / 广东新会  
逝世：1929-01-19  
妻子：李蕙仙 (正室) / 王桂荃 (老婆)  
人物关系：梁宝琪 (父亲) / 梁思达 (儿子) / 梁思忠 (儿子) / 梁思懿 (女儿) / 梁思成 (儿子)  
个人名言：享受工作的同时享受生活

**著作** [更多>>](#)

 中国近三百年学史...  
 中国历史研究法  
 新大陆游记  
 李鸿章传  
 清代学术概论

# 知识的表示学习-Represent Learning


- Distributed Representation (Word Embeddings)
- 每个词被表示成**稠密、实值、低维向量**



- 男人-女人=国王-皇后


# 分布式表示的意义

- 解决大数据NLP的**数据稀疏**问题
- 实现**跨领域、跨对象**的知识迁移
- 提供**多任务学习**的统一底层表示



# 表示学习对知识图谱的表示

- 对每个事实 (head, relation, tail), 将其中的 relation 作为从 head 到 tail 的翻译操作



# IR新课题9：行为分析、舆情监控

- 通过对网络上的信息收集，了解公众对某种社会现象或社会问题的具有一定影响力和倾向性的共同意见。
- 网络环境下舆情信息的主要来源有
  - 新闻评论、BBS、聊天室、博客、聚合新闻(RSS)、微博、微信等
- 利用Facebook、Twitter等发现人类自身活动等
- 利用Twitter、Facebook等发现野生动物的分布等

# IR新课题10：自动对话

- 聊天机器人，是一种通过自然语言模拟人类进行对话的程序。
- 研究源于图灵(Alan M. Turing)在1950年在《Mind》上发表的文章《Computing Machinery and Intelligence》，提出了“机器能思考吗？”(“Can machines think?”)的设问，并且通过让机器参与一个模仿游戏(Imitation Game)来验证“机器”能否“思考”，进而提出了经典的图灵测试(Turing Test)。
  - 图灵测试是指测试者在与被测试者(一个人和一台机器)隔开的情况下，通过一些装置(如键盘)向被测试者随意提问。进行多次测试后，如果有超过30%的测试者不能确定出被测试者是人还是机器，那么这台机器就通过了测试，并被认为具有人类智能。
- 图灵测试被认为是人工智能的终极目标，图灵本人因此也被称作“人工智能之父”。

图灵测试额外加分项：  
说服测试者，令他认为  
自己是电脑。


你知道吗，你说的这些话  
真的很有道理。

我……我已经不知道  
自己究竟是谁了。



- 从应用场景的角度来看，可以分为在线客服、娱乐、教育、个人助理和智能问答五个种类。

- 微软：小冰
- 微软：Cortana
- 百度：小度
- Facebook：M
- 苹果：SIRI




# 结论

## 信息检索技术

- 是一项飞速发展的科学技术。
- 是一项和人们生活密切相关的技术。
- 是计算机科学研究领域中为数不多的理论和应用密切相关的研究领域，即理论研究可直接导致应用系统的产生。
- 由于研究内容比较新，容易出成果。
- 和搜索技术相关的研究是易于自主创业的研究领域之一！

# IR及相关研究领域重要会议



\*From Prof. Chengxiang Zhai

# 重要工具

- Lemur、Indri : 包含各种IR模型的实验平台, C++
- SMART : 向量空间模型工具, C编写
- Weka : 数据挖掘工具, Java编写
- Lucene : 开源检索工具, Java版本受维护, 存在各种语言编写的其他版本
- Nutch : 开源爬虫, Java版本
- ElasticSearch : 基于Lucene的企业级搜索引擎
- Sphinx : 开源检索工具, C++
- Larbin : 采集工具, C++
- Firtex : 检索平台, C++, 计算所开发
- 更 多 : <http://www.searchtools.com/tools/tools-opensource.html>