



JZSearch大数据精准搜索关键技术

JZSearch Big Data Precise Search Key Technology



张华平 博士 副教授
大数据搜索与挖掘实验室
kevinzhang@bit.edu.cn
@ICTCLAS张华平博士
2016.10



纲要

大数据 搜索

I 简单Web搜索引擎基本原理


II 当前搜索技术的主要不足

III JZSearch大数据精准搜索引擎

IV JZSearch大数据搜索应用案例





Web Search Engine Using IR



最简单的搜索引擎


➤ 搜索引擎结构





倒排索引

文档分析，编码
识别，词语切分，
去停用词等



Document	Text
1	Pease porridge hot, pease porridge cold,
2	Pease porridge in the pot,
3	Nine days old.
4	Some like it hot, some like it cold,
5	Some like it in the pot,
6	Nine days old.


文档倒排，生成Inverted Files

Number	Term	(Document; Words)
1	cold	(1; 6), (4; 8)
2	days	(3; 2), (6; 2)
3	hot	(1; 3), (4; 4)
4	in	(2; 3), (5; 4)
5	it	(4; 3, 7), (5; 3)
6	like	(4; 2, 6), (5; 2)
7	nine	(3; 1), (6; 1)
8	old	(3; 3), (6; 3)
9	pease	(1; 1, 4), (2; 1)
10	porridge	(1; 2, 5), (2; 2)
11	pot	(2; 5), (5; 6)
12	some	(4; 1, 5), (5; 1)
13	the	(2; 4), (5; 5)



倒排索引结构

➤ 索引文件结构：不管怎么变化基本都由这几部分组成






倒排索引的挑战

- Fast: 如何快速构造倒排索引?
- Fast: 如何构造索引使检索尽可能的快?
- Minimized: 如何使索引尽可能小?
- Online Indexing: 如何构造动态文档集的索引(增量, 差量索引和索引更新)?
- Scalable: 如何在资源有限的情况下构造海量数据的索引?





信息检索






布尔查询

- 一种简单的检索模型，建立在经典的集合论和布尔代数的基础上。
- 遵循两条基本规则： 每个索引词在一篇文章中只有两种状态：出现或不出现，对应权值为 0 或 1。
- 查询是由三种布尔逻辑运算符 and, or, not 连接索引词组成的布尔表达式。





合取布尔查询处理





Ranking和信息检索

- 经典布尔模型能精确判断文档是否出现某一查询，但并不能给出相关性排序
- 信息检索是一个查询 Q 和文档 D_d 相似度计算过程：

$$M(Q, D_d) = Q \bullet D_d = \sum_{t=1}^n w_{q,t} \bullet w_{d,t} = \sum_{t \in Q} w_{q,t} \bullet w_{d,t}$$

- 存在一个问题：当 Q 包含常用词 t 时，那些包含比较多 t 的文档总是排在前面，其他的非常用词根本不起作用，所以需要根据inverse document frequency (IDF) 计算Term的权重 w_t ：

$$w_t = \frac{1}{f_t}$$

f_t 是包含term t 的文档数



北京理工大学
BEIJING INSTITUTE OF TECHNOLOGY

向量

$$\vec{x} \quad \overrightarrow{M_1 M_2}$$


➤ **向量**(矢量, vector): 既有大小又有方向的量, 通常用有向线段表示, 记作 $\vec{x}$ 或者

➤ 考虑从空间坐标系原点出发(其他向量可以平移到原点出发)的向量 $\vec{x}$, 终点坐标为 $\langle x_1, x_2, \dots, x_n \rangle$, 我们称之为一个 **n维向量**

➤ 向量的运算: 加、减、倍数、内积

$$\vec{x} \pm \vec{y} = \langle x_1 \pm y_1, x_2 \pm y_2, \dots, x_n \pm y_n \rangle$$

$$\lambda \vec{x} = \langle \lambda x_1, \lambda x_2, \dots, \lambda x_n \rangle$$





向量的模、距离和夹角

$$|\vec{x}| = \|\vec{x}\| = \sqrt{x_1^2 + x_2^2 + \dots + x_n^2}$$

➤ 向量的模(大小):

➤ 向量的(欧氏)距离

$$\text{dist}(\vec{x}, \vec{y}) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2}$$

➤ 夹角 α

$$\cos \alpha = \frac{\vec{x} \bullet \vec{y}}{|\vec{x}| \times |\vec{y}|}$$





向量空间模型

- 向量空间模型(Vector Space Model, VSM)是康奈尔大学 Salton等人上世纪70年代提出并倡导，原型系统SMART*
- term独立性假设：term在文档中的出现是独立、互不影响的。
- 查询和文档都可转化成term及其权重组成的向量表示，都可以看成空间中的点。向量之间通过距离计算得到查询和每个文档的相似度。





文档-标引项矩阵(Doc-Term Matrix)

n 篇文档， m 个标引项构成的矩阵 $A_{m \times n}$ ，每列可以看成每篇文档的向量表示，同时，每行也可以看成标引项的向量表示。

$$A_{m \times n} = \begin{matrix} & d_1 & d_2 & \dots & d_n \\ \begin{matrix} t_1 \\ t_2 \\ \vdots \\ t_m \end{matrix} & \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & \dots & \vdots \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{bmatrix} \end{matrix}$$





一个例子

- 查询 q : ($\langle 2006, 1 \rangle, \langle \text{世界杯}, 2 \rangle$)
- 文档 d_1 : ($\langle 2006, 1 \rangle, \langle \text{世界杯}, 3 \rangle, \langle \text{德国}, 1 \rangle, \langle \text{举行}, 1 \rangle$)
- 文档 d_2 : ($\langle 2002, 1 \rangle, \langle \text{世界杯}, 2 \rangle, \langle \text{韩国}, 1 \rangle, \langle \text{日本}, 1 \rangle, \langle \text{举行}, 1 \rangle$)

	d_1	d_2	q
2002	0	1	0
2006	1	0	1
世界杯	3	2	2
德国	1	0	0
韩国	0	1	0
日本	0	1	0
举行	1	1	0



➤ 查询和文档进行向量的相似度计算：

■ 采用内积：

⑩ 文档 d_1 与 q 的内积： $1*1+3*2=7$

⑩ 文档 d_2 与 q 的内积： $2*2=4$

■ 夹角余弦：

⑩ 文档 d_1 与 q 的夹角余弦：

$$\frac{7}{\sqrt{12 \times 5}} \approx 0.90$$

⑩ 文档 d_2 与 q 的夹角余弦：

$$\frac{4}{\sqrt{5 \times 8}} \approx 0.63$$



典型的静态信息检索





图 1-1 文档检索

典型的动态信息流过滤过程





信息检索vs.信息流过滤的差异

➤ 文档集：

■ 规模有限，相对静态 vs. 规模巨大、动态变化

➤ 用户需求：

■ 多变多样，海量用户 vs. 相对稳定、用户受限

➤ 技术方法：

■ 对文档进行倒排索引并检索 vs. 查询生成自动机，进行快速扫描过滤





信息检索vs.信息流过滤的共同

➤ 同一理论支持；

➤ 相同的支持技术：自然语言处理、机器学习、大规模架构设计

➤ 小规模的信息安全可以直接规约为信息检索问题。



信息检索需研究的五大问题

- 搜索排序问题: 信息检索模型, 解决搜索的根本问题;
- 效果提升问题: 信息检索策略, 提高效果的策略与技巧;
- 性能问题: 倒排、索引压缩;
- 架构问题: 并行、分布式、云计算;
- 拓展问题: 多语言、跨语言等。



纲要

大数据 搜索

I 简单Web搜索引擎基本原理

II 当前搜索技术的主要不足

III JZSearch大数据精准搜索引擎

IV JZSearch大数据搜索应用案例



当前不足初探

➤ 信息重复冗余



普通搜索

关键字:

搜索类型:

栏目类别:

地区:

行业:

日期:

搜 索

当前位置: 中国招标网 >> 普通搜索

共16条记录 没有查到所需的信息?

信息标题	地区	日期	收藏
关于驻马店市园林管理局绿地养护项目采购公告	河南省	2012-09-17	收藏
关于驻马店市园林管理局绿地养护项目招标公告	河南省	2012-09-17	收藏
询价公告(绿化苗木、12-14-37)	新疆	2012-09-17	收藏
神新能源公司2012年秋季绿化工程招标公告	新疆	2012-09-14	收藏
滦河东路绿化景观改造工程(六标段)滦河东路绿化景观改造工程(六标段)招...	河北省	2012-09-11	收藏
滦河东路绿化景观改造工程(六标段)招标公告	河北	2012-09-11	收藏
黄骅港联轴节、维修车间维修工具采购-采购公告	河北	2012-09-07	收藏
兴辰道道路及配套管线工程监理招标公告	天津市	2012-09-07	收藏
宜白路道路及配套管线工程监理招标	天津市	2012-09-07	收藏
宁夏银川市贺兰县农业综合开发办秋季造林苗木竞争性谈判招标公告	宁夏	2012-09-06	收藏
宁夏银川市贺兰县农业综合开发办秋季造林苗木竞争性谈判招标公告	宁夏	2012-09-06	收藏



当前不足初探

➤ 白腊-石蜡 是专业同义词，缺乏专业知识
关联



关键字: 石蜡

搜索类型: 按全文搜索

栏目类别: 全部类别

地区: -地区-

行业: -请选择-

日期: 近一月

搜索

当前位置: 中国招标网 >> 普通搜索

共32条记录 没有查到所需的信息?

信息标题	地区	日期	收藏
广州市番禺区政府采购医疗设备项目招标公告	广东	2012-09-21	收藏
天津市南开医院全自动组织脱水机等设备采购项目招标公告	天津市	2012-09-21	收藏
巴中市中心医院一批医疗设备采购招标公告	四川省	2012-09-20	收藏
四川省: 泸州医学院教学、科研设备第二批采购项目(第二次)中标公告	四川省	2012-09-20	收藏
北京市密云水库医院病理科医疗设备购置政府采购项目招标公告	北京市	2012-09-17	收藏
北京市密云水库医院病理科医疗设备购置政府采购项目招标公告	北京	2012-09-17	收藏
盐亭县电化教育馆教学仪器采购招标公告	四川省	2012-09-13	收藏
四川省: 泸州医学院教学、科研设备第二批采购项目(第二次)中标公示	四川省	2012-09-12	收藏
四川省人民医院试剂比选通知	四川省	2012-09-12	收藏
9月份超期老品	山东省	2012-09-11	收藏

当前不足初探

➤ 搜索禁用语禁而不止，搜索结果完全无关



[返回首页](#) [帮助中心](#) [旧版本入口](#) [RSS订阅](#)

市场热线: 010-82744908 82744968 82743201



关键字: 法轮

搜索类型: 按全文搜索

栏目类别: 全部类别

地区: -地区-

行业: 请选择-

日期: 近一月

搜索

当前位置: 中国招标网 >> 普通搜索

共1条记录 没有查到所需的信息?

信息标题

地区

日期

收藏

盐亭县政务外网接入服务采购中标公告

四川省

2012-09-14

收藏

更多相关信息，可通过选择时间段来查找，如有疑问请咨询客服：010-82744908

| < 首页 | 末页 > |

共1条记录

[关于招标网](#) | [会员服务](#) | [合作咨询](#) | [友情链接](#) | [网站地图](#) | [意见建议](#) | [征稿启事](#) | [诚聘英才](#) | [法律声明](#) | [隐私保护](#) | [服务条款](#) | [联系我们](#)

独家服务: [商务室](#) | [招标网](#) | [项目通](#) | [招标监测](#) | [项目跟踪](#) | [高级搜索](#) | [信息订阅](#) | [发布信息](#) | [个性化定制](#) | [研究报告](#) | [行业月报](#) | [标书下载](#) | [更多](#)

推荐资讯: [招标动态](#) | [项目动态](#) | [采购动态](#) | [热点专题](#) | [开标直播](#) | [采招实务](#) | [高端访谈](#) | [政策法规](#) | [诚信记录](#) | [更多](#)

市场热线: 010-82744908 82744968 82743201 合作咨询: 010-82744228

Copyright © 2005-2009 中国招标网 All Rights Reserved. 京ICP证070104号 北京市公安局海淀分局备案编号1101081890

大数据分析与应用/张华平



北京理工大学
BEIJING INSTITUTE OF TECHNOLOGY



通用搜索 vs. 大数据专业搜索

- 召回率不是通用搜索的考量范围，只关注P@10, P@30:
 - 体量大，一大遮百丑
 - 查询：中国证监会所有的负面信息；
- 体量大，但返回给用户的有限；
 - 返回给用户的信息不足2000条
 - 查询：新疆极端势力的动态情报；
- 专业垂直整合缺乏
 - 专业业务的逻辑不在通用搜索的业务范畴内；
 - 中关村东路80号5楼1203室的邮编是多少？联想集团的信息汇总





关于作业： 最近三年(ACL, SIGIR, CIKM, WWW, SMP) 最经典的Tutorial



纲要

大数据 搜索

I 简单Web搜索引擎基本原理

II 当前搜索技术的主要不足

III JZSearch大数据精准搜索引擎

IV JZSearch大数据搜索应用案例





JZSearch大数据精准搜索

- 搜索基本功能：
 - 多字段关联搜索、指定字段排序、精确搜索与模糊搜索
- 搜索特色功能：
 - 内嵌正负面情感等极性分析、语义联想搜索、临近搜索、搜索结果去重；
 - 内嵌了ICTCLAS智能分词系统；
 - 数据库实时同步：数据库增删改10秒内即可同步到搜索；
- 搜索维护功能：
 - 单点故障容错；支持增量索引；自动备份与恢复机制；自动缓存机制；自动优化机制；搜索屏蔽与恢复；






JZSearch内部语法示例

- [FIELD] * [NEAR] 尚福林 ##负面JZSearch## 12
- [FIELD] price [RANG] 1.0 9.0 [FIELD] name [AND] 牛奶
儿童
- [FIELD] name [PREF] 张
 - 姓名字段name必须以“张”作为前缀开头
- [FIELD] id [PREC] 123
 - 字段id必须以“123”精准匹配，如“1234”或者“0123”均不作为匹配结果；
- [field] content [complex] 统计局||中国统计局||CPI 骗人||
砖家 10
 - 要求content字段内，同时出现{统计局||中国统计局||CPI }{骗人||砖家},且两者之间的距离必须在10个词内。




JZSearch Big Data Search Engine Architecture





JZSearch 状态转移图



- 倒排索引中倒排表的大小可以通过齐普夫分布来估计。
- 它描述了自然语言中每个词的词频分布情况：如果把词出现的频率按由大到小排列，那么每个词的词频与它排序序号的乘积是一个常量。
- 常量取1时齐普夫分布中前5个词的词频分布如下：

排序序号 _i	频率 _i	常量 _i
1 _i	1.00 _i	1 _i
2 _i	0.50 _i	1 _i
3 _i	0.33 _i	1 _i
4 _i	0.25 _i	1 _i
5 _i	0.20 _i	1 _i



索引压缩:哈夫曼编码

➤ 在英文中，e的出现概率很高，而z的出现概率则最低。当利用哈夫曼编码对一篇英文进行压缩时，e极有可能用一个位(bit)来表示，而z则可能花去25个位（不是26）。用普通的表示方法时，每个英文字母均占用一个字节(byte)，即8个位。二者相比，e使用了一般编码的1/8的长度，z则使用了3倍多。倘若我们能实现对于英文中各个字母出现概率的较准确的估算，就可以大幅度提高无损压缩的比例。





JZSearch索引压缩

➤ 字节对齐压缩 (Byte-Aligned)

- 0-63 00xxxxxx
- 64-(16K-1) 01xxxxxx xxxxxxxx
- 16K-(4M-1) 10xxxxxx xxxxxxxx xxxxxxxx
- 4M-(1G-1) 11xxxxxx xxxxxxxx xxxxxxxx xxxxxxxx
-
- 0 00000000
- 1 00000001
-
- 63 00111111
- 64 01000000 01000000
- 65 01000000 01000001

➤ 通过使用字节边界来实现BA压缩，运行时会付出些许代价，但可以获得一定的压缩比。BA算法易于实现，而且压缩比较高（使用停用词后，压缩文件大小占未压缩索引文件大小的比例大约是15%）。



➤ 固定长度的索引压缩示例

- 给定任意一个索引词 t_1 ，我们考虑其索引的条目，假定 t_1 在文档1、文档3、文档7、文档70和文档250中出现。
- BA压缩使用最高的两个比特位来表明存储该值需要的字节数。对于前4个值，只需要一个字节就可以表示；对于最后一个值——180，需要两个字节来表示。需要注意的是：我们只需要计算倒排表中每一项的差。最后的差值为： $250-70=180$ 。我们需要计算所有的最终数值。这些数值和压缩后的相应比特字符串见下表。（字节对齐方式压缩）

值 _i	压缩的比特串 _i
1 _i	00 000001 _i
2 _i	00 000010 _i
4 _i	00 000100 _i
63 _i	00 111111 _i
180 _i	01 000000 10110100 _i

➤ 固定长度的索引压缩示例

- 在没有压缩之前，倒排表中的每条记录需要4字节，5条记录总共需要20个字节。这些数值和它们对应压缩前的比特字符串详见下表。
(基准线：压缩前)

值 _i	未压缩的比特串 _i
1 _i	00000000 00000000 00000000 00000001 _i
3 _i	00000000 00000000 00000000 00000011 _i
7 _i	00000000 00000000 00000000 00000111 _i
70 _i	00000000 00000000 00000000 01000110 _i
250 _i	00000000 00000000 00000000 11111010 _i

- 结论：在这个例子中，未压缩的数据需要160比特，使用BA压缩后仅需要48比特。

➤ 索引词典动态设计:


- 优点: 可以快速索引新词
- 缺点: 动态词典组织效率远低于静态词典

➤ JZSearch采用静态词典, 主要包含:

- 汉语常用词
- 英文常用词: 词形自动转换
- 英文未知词表示: n -gram拆分
- 数字组合: n -gram拆分



纲要



大数据 搜索

I 简单Web搜索引擎基本原理

II 当前搜索技术的主要不足


III JZSearch大数据精准搜索引擎

IV JZSearch大数据搜索应用案例





软件架构



藏文搜索引擎拓扑图



用户终端



Web服务器

采集区

新闻



采集
Server

网站



采集
Server

论坛



采集
Server

贴吧



采集
Server

博客



采集
Server

DMZ区
数据检索



索引
Server



检索
Server

容灾备份



Hbase
数据库



元信息
Server



文件
Servern

核心区
数据存储



文件
Server1

...



文件
Servern



Hbase
数据库

Hadoop
集群



元信息
Server



管理
Server

搜索引擎-爬虫技术

ELINT网络舆情挖掘系统

最新消息 舆情热点 舆情追踪 舆情报告 系统设置 舆情预警

LOGINOUT

HOME BACK NEXT USER

检索条件

与情监控系统 - 傲游(Maxthon) 2.5.15

http://192.168.1.102:8080/elint/main.html

Maxthon - 傲游今日 presentationprospectssagee... 百度搜索 蒋本珊 北理工 北京理工大学 与情监控系统 微博热词云 谢耘耕的相关微博 - 新浪微博 谢耘耕的微博 新浪微博-随时...

ELINT网络舆情挖掘系统

最新消息 舆情热点 舆情追踪 舆情报告 系统设置 舆情预警

LOGINOUT

HOME BACK NEXT USER

与情追踪

我的追踪

城管

群体事件

腐败

追踪管理

实体追踪

人物追踪

机构追踪

1	 天心在云	一伙 城管 暴徒，殴打人民教师，当局漠视？ //李骁:分享李骁的博文:李骁:暴力拆迁是滋生黑社会的土壤 http://t.cn/b0YqO //于建嵘:这样的事情为何一再发生?根本的原因是由于公权力过于强大,而执掌公权力的人又无任何惧怕。	来源:新浪微博- 评论(2)- 转发(0)-发布时间: 2010-12-23 09:35:42
2	 寒小妖2010	真他妈狗血的又见 城管 ，一大早长沙雨花区 城管 队，发生在红旗区 暴力 执法，殴打农村卖菜妇女， 殴打 水果商，殴打家禽商，真心觉得如此执法没有天理良心，被路人直指‘土匪’！	来源:Android客户端- 评论(1)- 转发(0)-发布时间: 2011-12-03 11:52:38
3	 百科全书V	【揭露 城管暴力 执法一幕视频】 暴力 ，血腥，残暴，冷血，没人性！这是一群畜生而非人类，却被披上 城管 制服；这群畜生涉嫌故意伤害罪，寻衅滋事罪，当地警方必须立案查处；请网友们看见此贴也都转发一次吧。 http://t.cn/hDXQj3	来源:新浪微博- 评论(0)- 转发(0)-发布时间: 2011-05-30 15:16:11
4	 澳門新聞眼Lam	【兩岸消息】穗男子拍 城管暴力 執法遭毆：廣州白雲區1名男子在本月24日晚圍毆 城管 對街邊小販的執法行動時，因見到 城管暴力 執法使用手機拍下照片，但卻突然遭一群男子圍毆，手機亦被強行格式化，最後更要寫檢討。當局解釋事件由誤會引起，會對事主作出道歉及經濟賠償。	来源:新浪微博- 评论(0)- 转发(1)-发布时间: 2011-11-30 17:14:39
5	 观海知心远	求助一次爱心二次生命！父亲为了给白血病的哥哥的求助，每天早起就到“黄兴步行南街”去乞讨，今天却被保安及 城管 的拖拉抢夺，还差一点被打成 重伤 上医院，爸爸本来就身体差，可爸爸说了哥哥就是被打也还会继续去乞讨求助，希望社会爱心人士能帮帮我，求转发下 http://t.cn/SbQpVf	来源:微博相册- 评论(0)- 转发(0)-发布时间: 2011-12-03 11:56:50

网络舆情挖掘系统

完成

840M 100% 缩放:100%

网络舆情挖掘系统

21 故宫建福宫被指成富豪会所 工作人员:不能留宿 新华社北京分社 2011-05-13 09:52 日报 查看

公司搜索

 JZsearchAgentClient

修改配置文件

服务器IP：

端口号：

搜索编号：

每页结果数：

字段文件：

...

显示格式：

确认

默认值



搜索

下一页

上一页

退出

搜索结果：

搜索结果总数:2; 返回结果总数:2; 起始结果序号:0

doc_id

176

id

211

updatetime

2012/09/12 00:00:00

address

推荐中标商: 北京中科泛华测控技术有限公司
制造商: 美国恩艾仪器有限公司
制造商所属国家: 美国
招标内容: 项目名称:电

doc_id

177

id

212

updatetime

2012/09/12 00:00:00

address

推荐中标商: 北京中科泛华测控技术有限公司 制造商: 美国恩艾仪器有限公司 制造商所属国家: 美国 招标内容:
: 项目名称:电学量专用

长句搜索

JJsearchAgentClient

修改配置文件

服务器IP: 端口号: 搜索编号: 每页结果数:

字段文件: ... 显示格式:

 或法人委托书到汉寿县城关镇小南门55号(汉寿县建设局办公楼4楼)购买资格

搜索结果:

搜索结果总数:2; 返回结果总数:2; 起始结果序号:0

doc_id	94
id	118
updatetime	2012/09/12 00:00:00
address	r>常德工程招标代理有限公司受汉寿县土地开发整理中心委托,对其汉寿县围堤湖土地整理(二期工程)项目进行国内公开招标。凡具有建设行政主管部门颁发的房屋建筑工程施工总承包叁级(...00时(北京时间),逾期不予办理。各投标人在网上报名后凭介绍信或法人委托书到汉寿县城关镇小南门55号(汉寿县建设局办公楼4楼)购买资格预...
doc_id	95
id	119
updatetime	2012/09/12 00:00:00
address	常德工程招标代理有限公司受汉寿县土地开发整理中心委托,对其汉寿县围堤湖土地整理(二期工程)项目进行国内公开招标。凡具有建设行政主管部门颁发的房屋建筑工程施工总承包叁级(...00时(北京时间),逾期不予办理。各投标人在网上报名后凭介绍信或法人委托书到汉寿县城关镇小南门55号(汉寿县建设局办公楼4楼)购买资格预...

公司名称表述不准确

JZsearchAgentClient 中%半简

修改配置文件
服务器IP: 127.0.0.1 端口号: 8083 搜索编号: 1 每页结果数: 20
字段文件: E:\Projects\JZSearch\JZSearchInstall\IndexFile\field.dat ... 显示格式: html

确认 默认值

[field] * [fuzzy] 中设江苏机械设备集团公司 搜索 下一页 上一页 退出

搜索结果:

搜索结果总数:173; 返回结果总数:20; 起始结果序号:0

doc_id	2
id	3
updateTime	2012/09/12 00:00:00
address	中设江苏机械设备进出口集团公司受买方委托对下列产品及服务进行国际公开竞争性招标。现邀请合格投标人参加投标。
address	1、招标产品的...地点: 中设江苏机械设备进出口集团公司国际招标中心
address	5、投标截止时间和开标时间: 2005-07-2309:30:00
address	6、开标地点: 中设江苏机械设备进...
doc_id	3
id	4
updateTime	2012/09/12 00:00:00
address	中设江苏机械设备进出口集团公司受买方委托对下列产品及服务进行国际公开竞争性招标。现邀请合格投标人参加投标。 1、招标产品的名称、...地点: 中设江苏机械设备进出口集团公司国际招标中心 5、投标截止时间和开标时间: 2005-07-2309:30:00 6、开标地点: 中设江苏机械设备进...

设备参数精准搜索

➤ 内存 256M的参数要求不等同于两者同时出现

JZsearchAgentClient

修改配置文件
服务器IP: 127.0.0.1 端口号: 8083
字段文件: E:\Projects\JZSearch\JZSearchInstall\IndexFile\field.dat

256M DDR

搜索结果:

搜索结果总数:6; 返回结果总数:6

doc_id	32
id	52
updatetime	2012/09/12 00:00:00
address	(询价编号:
doc_id	33
id	53
updatetime	2012/09/12 00:00:00
address	(询价编号:GZIT2005 报价截止时间: 200
doc_id	128
id	154
updatetime	2012/09/12 00:00:00
address	(询价编号:
doc_id	129

JZsearchAgentClient

英:半简

修改配置文件
服务器IP: 127.0.0.1 端口号: 8083 搜索编号: 1 每页结果数: 20
字段文件: E:\Projects\JZSearch\JZSearchInstall\IndexFile\field.dat 显示格式: html

确认 默认值

[field] * [near] 256M DDR 3 搜索 下一页 上一页 退出

搜索结果:

搜索结果总数:2; 返回结果总数:2; 起始结果序号:0

doc_id	160
id	192
updatetime	2012/09/12 00:00:00
address	/2.8G/256M/DDR/80G/CD-ROM/1.44软驱/集成显卡/100M网卡/Windows XP Pro系统/17寸纯平/ 键盘/光电鼠标, 提供原厂供货证明, 原厂上...
doc_id	161
id	193
updatetime	2012/09/12 00:00:00
address	/2.8G/256M/DDR/80G/CD-ROM/1.44软驱/集成显卡/100M网卡/Windows XP Pro系统/17寸纯平/ 键盘/光电鼠标, 提供原厂供货证明, 原厂上...


语义关联搜索

➤ 俗语洋蜡搜索到专业术语石蜡相关的内容



黑名单搜索屏蔽

➤ 可以屏蔽禁止的公司、产品或反动信息搜索



正文、附件联合查询结果样例

标题：关于陕西某公司采购设备的公告

正文：

... 陕西法士特齿轮有限公司20万台变速器技术改造 3、数控高效滚齿机 1台

附件：

065.txt

... 西安法士特汽车传动有限公司出口齿轮生产线技术改造项目 1、数控滚齿机11台

131.txt

... 陕西法士特齿轮有限公司20万台变速器技术改造 1、数控滚齿机 2台



搜索结果自动分组统计



标准图书馆
www.bzsb.info



加入收藏



设为首页



帮助



关于我们

网站▼ | 登录 | 注册 | 返回首页

标准分类

- 植物检疫、病虫害防治(18)
- 瓜果、蔬菜种植与产品(14)
- 农药管理与使用方法(12)
- 豆类、薯类作物与产品(10)
- 食品卫生(8)
- 农机具(7)
- 基础标准与通用方法(5)
- 农林技术(5)
- 种籽与育种(5)
- 粮食加工与制品(5)
- 经济作物综合(4)
- 畜禽饲料与添加剂(4)
- 植物保护综合(2)
- 一般有机化工原料(2)
- 基础标准与通用方法(2)
- 标志、包装、运输、贮存(2)
- 食品加工与制品综合(2)
- 标准化、质量管理(1)
- 粮食、饲料作物综合(1)
- 标准化、质量管理(1)
- 蔬菜加工与制品(1)
- 调味品(1)
- 蔬菜罐头(1)
- 烟草制品(1)

标准号 关键词:

☒ 按国内标准 ☐ 按国外标准

首页 < **1** 2 3 4 5 6 7 8 > 尾页

标准号	名称	中图分类号
DB13/T 396.7-1999	旱地地膜覆盖栽培技术规程	种籽与育种
DB13/T 398.7-1999	旱地地膜覆盖栽培技术规程	农林技术
DB13/T 865-2007	马铃薯有机栽培技术规程	瓜果、蔬菜种植与产品
DB1302/T 156-2001	无公害马铃薯生产技术规程	瓜果、蔬菜种植与产品
DB1304/T 071-2001	无公害农产品生产技术规程 马铃薯	农林技术
DB1304/T 102-2001	马铃薯脱毒种薯繁育技术规程	农林技术
DB1304/T 136-2004	棉花与土豆(马铃薯)间套复种生产技术规程	瓜果、蔬菜种植与产品
DB1306/T 11-2005	无公害马铃薯生产技术规程	瓜果、蔬菜种植与产品
DB1308/T 007-1999	马铃薯茎尖脱毒技术规程	豆类、薯类作物与产品
DB1308/T 008-1999	脱毒马铃薯微型种薯生产技术规程	豆类、薯类作物与产品
DB1308/T 009-1999	脱毒马铃薯基础种薯生产技术规程	豆类、薯类作物与产品
DB1308/T 010-1999	脱毒马铃薯合格种薯生产技术规程	豆类、薯类作物与产品
DB1308/T 011-1999	马铃薯脱毒种薯质量标准	豆类、薯类作物与产品
DB1308/T 012-1999	马铃薯商品薯(块茎)质量标准	豆类、薯类作物与产品
DB1308/T 088-2005	食用马铃薯淀粉	豆类、薯类作物与产品

我们的工作：JZSearch精准搜索引擎



The screenshot shows the '中国邮政名址网' (China Post Name Address Database) website. The header includes the logo 'DM' and the text '中国邮政名址网' and 'Name Address Database Center Of China Post'. Navigation links include '返回主页', '写信给我们', and '与我们联系'. The main navigation bar has links for '普通用户', '高级用户', '首页', '邮政编码查询', '企事业单位查询', '数据目录', '数据信函业务', '邮政黄页', and '学习园地'.

On the left, there is a login section with fields for '用户名:' and '密码:', and buttons for '登录' and '注册'. Below this is a '名址动态' section with a link '什么是邮政编码' and a 'MORE' button.

The main content area shows the '邮政编码查询' (Postal Code Search) tab selected. The search input field contains '中关村东路80号3号楼1509室'. The search results show a single entry:

邮政编码	行政区划
100190	北京市海淀区中关村东路62~100双

At the bottom, it says 'POWER BY AddreSmart' and '第1页/共1页 共1条记录'.



我们的工作：JZSearch精准搜索引擎

 **内网文档搜索**

[高级搜索](#)

☒ 全部 ☐ TXT ☐ DOC ☐ PDF ☐ HTML ☐ PPT ☐ Excel ☐ 其他

全部共享 全部时间 找到相关结果约5篇，用时2.537秒

 **Unix_vi.doc**

...yw就是复制两个单词 如果要复制第m行到第n行之间的内容，可以在末行模式中输入m，ny例如：3，5y复制第三行到第五行内容到缓存区。粘贴缓冲区中的内容，用p 7.撤销操作 u命令取消最近一次的操作，可以使用多次来恢复原有的操作 U取消所有操作 Ctrl+R可以恢复对使用u命令的操作 8.搜索及替换命令 vi的查找和替换功能主要在末行模式完成：至上而下的查找 / 要查找的字符串，其中/代表从光标所在位置起开始查找，例如：/ work 至下而上的查找 ? 要查找的字符串 例如：/ work 替换 :s/old/new用new替换行...

JoinDOC\file\192.168.1.102\department\Unix_vi... - 2010-11-09 14:44:49

来源:运维部-李新健 权限:所有

 **博士论文_杨少华.doc**

... HYPERLINK \l "_Toc228695035" r \l 图1.4 基于流程图建模的情景应用构造 !! PAGEREf _Toc228695035 \h r \l 214 !! HYPERLINK \l "_Toc228695036" r \l 图1.5 情景应用构造系统的表达能力与易用性分析 !! PAGEREf _Toc228695036 \h r \l 334 !! HYPERLINK \l "_Toc228695037" r \l 图2.1 HTML信息源实例：Amazon图书搜索 !! PAGEREf _Toc228695037 \h r \l 394 !! HYPERLINK \l "_Toc..."

JoinDOC\file\192.168.1.99\public\博士论文_杨少华.doc - 2010-11-09 14:55:45

来源:开发部-刘志华 权限:所有

 **论坛采集.doc**

...，挖掘网上论坛信息不仅可以便利广大网民搜索网络资源，同是对于政府掌握社情民意，构造和谐社会有着重要的意义。与普通网站多以静态网页为主不同，论坛往往都是动态生成的。论坛的数据保存在后台数据库中，根据用户提交的参数不同，动态从数据库中读取相关内容生成网页，因此论坛有其自己的特点。1、链接层次比较深。用户在浏览某一帖子时往往要点击数次才能找到所看的帖子，并且需要翻页数次才能浏览完毕，论坛采集器也要模拟用户动作进行深层链接采集。2、链接种类繁多。论坛中除了有帖子对应的链接外，还存在着大量的功能链接和其他链接等。如“评论”、“回复”等。3、内容重复链接。论坛中往往存在大量链接不同而指向同一...

JoinDOC\file\192.168.1.99\public\论坛采集.doc - 2010-11-09 14:55:50

来源:开发部-刘志华 权限:所有

 **oracle管理.txt**

文档统计

PPT(4)	JPG(4)
GIF(19)	H(27)
HTM(28)	TXT(41)
DOC(51)	CPP(92)
PDF(163)	C(178)
BMP(254)	

[最新文章](#)
[部门统计](#)
[人员统计](#)
[文档TOP10](#)
[贡献TOP10](#)
[阅读TOP10](#)





سابقہ تمام باتوں پر غور کر کے

搜索

[下一页](#)
[尾页](#)
 共有 1380 条记录, 当前第1/92 页

[illegible]

网上通用搜索功能

[2013北京旅游攻略](#) [北京景点线路游记](#) [百度旅游](#)

最新北京旅游攻略, 百度旅游为您准备了北京景点、线路、交通、美食、住宿等旅游攻略信息和实用精美游记, 供赴北京旅游的亲们参考。

lvyou.baidu.com/

[首都之窗-北京市政务门户网站](#)

北海公园 图说北京 魅力公园 北京印象图集 “绿色出行”图片征集 园博会图片征集 2013年北京冬季图片征集 热点关注[会议]市委十一届三次全会于12月22日至12月23...

www.beijing.gov.cn/ 2013-11-27 - [百度快照](#)

[北京旅游攻略](#) [北京北京旅游景点](#) [北京旅游网](#)

北京欣欣旅游网,提供北京北京旅游景点推荐、12月北京旅游攻略、北京旅行社、北京旅游线路、北京酒店预订、北京旅游地图等出行指南及旅游服务●欣欣旅游网 CNCN.com ...

beijing.cncn.com/ 2013-12-07 - [百度快照](#)

[北京汽车](#) [北京车市](#) [北京汽车报价](#) [北京汽车网](#) [汽车之家](#)

汽车之家北京站为您提供北京汽车报价,北京汽车行情,北京汽车经销商推荐,最精彩的北京汽车新闻、评测、导购及二手车信息,是提供北京汽车信息最快的汽车网站

www.autohome.com.cn/beijing/ 2013-12-07 - [百度快照](#)

[2013北京旅游攻略](#) [北京自助游攻略](#) [蚂蜂窝北京出游攻略游记](#) - [蚂蜂窝](#)

胡同是地道北京人的居所,这里充满着丰厚的生活气息,保留着许多文物古迹。当今的胡同,又进驻了许多潮流元素,这种传统与现代的结合,是北京最有魅力的地方之一。 ...

www.mafengwo.cn/travel-scenic-spot/m... 2013-12-06 - [百度快照](#)

[北京网-首都城市综合信息服务平台-北京生活、旅游、交通、文化、...](#)

北京网是北京市政府主导建设,为公众提供首都城市综合信息服务的公益性网站。提供北京地图、交通、旅游、住房、餐饮、医疗、演出、教育、就业等领域的便民服务信息。

www.beijing.cn/ 2013-12-07 - [百度快照](#)





JZSearch语义精准搜索引擎

个人中心



综合搜索 组织结构 电网报 图片 电力地图 统计分析

刘振亚是谁

搜索

热搜词条:


刘振亚是谁

UHV是什么

智能电网

配电网

全球能源互联网



最新消息

国网大事记

- 严格依法治企 坚持以...
- 台风“灿鸿”肆虐 供...
- 奋发有为 扎实工作 ...
- 连续抢修3天
- 风狂雨骤显担当
- 一定把损失降到最低

大数据分析与应用/张华平



北京理工大学
BEIJING INSTITUTE OF TECHNOLOGY



JZSearch语义精准搜索引擎

聚类结果

特高压

教育实践活动

智能电网

公司

全球能源互联网

学习实践活动

经济社会发展

安全生产

语义结果

询问对象：刘振亚，

刘振亚，男，汉族，1952年8月生，山东鄄城人，1984年加入中国共产党，1971年参加工作，山东工学院电力系电力系统及自动化专业毕业，大学学历，山东大学电气工程学院电气工程及其自动化专业硕士研究生毕业，电气工程硕士，教授级高级工程师，享受国务院政府特殊津贴。现任国家电网公司董事长、党组书记。

语义统计分析

分析对象：刘振亚 分析

智能搜索

返回检索结果约1906个结果...

1. 刘振亚总经理调研韩国STX集团大连造船厂项目的用电情况

来自栏目： 无设定栏目 板块： 要闻 发布时间： 2007/05/29 00:00:00 作者： 杜平

27日，刘振亚总经理(前排左四)一行在大连市长夏德仁(前排左三)的陪同下，调研韩国STX集团大连造船厂项目的用电情况。

关键词：刘振亚 命名实体--人物：刘振亚#夏德仁#

2. 刘振亚分别会见花旗集团和通用电气高层

来自栏目： 无设定栏目 板块： 要闻 发布时间： 2009/04/28 00:00:00 作者： 岳文

语义自动计算

相关新概念发现

沙捞

公司党组

电力集团公司

能源互联网

相关人物聚类

习近平/61

李克强/22

舒印彪/17

李荣融/12

郑宝森/11

温家宝/10

俞正声/9

曹志安/9

帅军庆/7

高培/7

相关作者聚类

姚雷/295

陶思遥/108

张超义/54

江莹/41

大数据分析与应用/张华平



北京理工大学
BEIJING INSTITUTE OF TECHNOLOGY



JZSearch语义精准搜索引擎

语义统计分析

分析对象: 刘振亚

分析


分析对象: 刘振亚是谁

时间: 2007-2015

分析机构: 国家电网公司

数据来源: 10年国家电网报

说明: 左图为关键词随着时间的变化, 关键词也在发生变化。



JZSearch语义精准搜索引擎

3. 刘振亚会见马来西亚沙捞越州首席部长

来自栏目: 无设定栏目 板块: 要闻 发布时间: 2010/04/14 00:00:00 作者: 姚雷

总经理刘振亚在公司总部会见了到访的马来西亚沙捞越州首席部长泰益玛目一行, 双方进行了亲切友好的交谈, 并就发挥各自优势加强合作深入交换了意见。刘振亚对马来西亚客人的来访表示热烈欢迎, 并详细介绍了中国电力工业尤其是电网的发展情况。他希望双方能进一步增进了解和信任, 达成合作共识, 并在更广泛领域积极开...

关键词: 刘振亚 命名实体--人物: 刘振亚#哈吉·拉旺#杜至刚#

4. 刘振亚会见东方电气集团董事长

来自栏目: 头条2 板块: 要闻 发布时间: 2009/07/16 00:00:00 作者: 姚雷

刘振亚对王计一行的到访表示热烈欢迎, 对于东方电气广大干部员工在特大地震灾难面前顽强不屈的精神和恢复重建取得的成绩表示钦佩。刘振亚说, 东方电气集团公司是我国最大的发电设备制造企业之一, 国家电网公司一直十分关注东方电气集团灾后重建和发展, 帮助东方电气集团恢复重建是国家电网的社会责任所在。经过大...

关键词: 刘振亚 命名实体--人物: 刘振亚#栾军#

5. 刘振亚会见法国电力集团公司董事长

来自栏目: 无设定栏目 板块: 要闻 发布时间: 2010/12/09 00:00:00 作者: 姚雷

总经理刘振亚在公司总部会见了到访的法国电力集团公司董事长兼首席执行官亨利·普格里奥一行。双方表示, 将巩固合作基础, 加强交流, 进一步拓展双方在电力领域的合作, 实现未来共同进步。刘振亚对亨利·普格里奥一行的来访表示热烈欢迎。他说, 国家电网公司非常重视与法国电力同行的友好关系, 双方已有的合作是双赢...

相关概念词发现



相关人物计算



感谢关注聆听！



张华平

Email: kevinzhang@bit.edu.cn

微博: @ICTCLAS张华平博士

实验室官网:

<http://www.nlpir.org>



大数据千人会

