



数据结构与算法（十一）

张铭 主讲

采用教材：张铭，王腾蛟，赵海燕 编写
高等教育出版社，2008.6（“十一五”国家级规划教材）

<http://www.jpk.pku.edu.cn/pkujpk/course/sjjg>



主要内容

- 基本概念
- 11.1 线性索引
- 11.2 静态索引
- 11.3 倒排索引
- 11.4 动态索引
- 11.5 位索引技术
- 11.6 红黑树



11.3 倒排索引 (Inverted Index)

- 11.3.1 基于属性的倒排
 - 要求检索结构中某个或若干个属性满足一定条件的结点 (不是按关键码的值检索)
 - 按照属性建立索引
- 11.3.2 对正文文件的倒排
 - 以文中的词 (word) 为索引项建立的索引



教师数据库主表

EMP#	NAME	Department	Profession	Specialty	Address
0155	李宇	数学	教授	代数	C105
0421	刘阳	外语	助教	英语	E310
0208	赵亮	物理	助教	力学	C211
0211	张伟	物理	讲师	原子物理	D508
0132	王亮	数学	助教	几何	E220
0119	王卓	数学	讲师	代数	B102
0330	孙丽	计算机	教授	软件	A108
0455	刘珍	外语	讲师	法语	A225
0310	周兵	计算机	讲师	英语	B423
0341	何江	计算机	助教	计算机	F406
.....					



11.3.1 基于属性的倒排

- 对某属性按属性值建立索引表，称倒排表
- “属性 - 指针”对 (attr, ptrList)
 - （属性值，具有该属性值的各记录指针）
 - 指针可以是关键码，或该记录的主文件地址
- 颠覆主文件的顺序，因而称为倒排索引
- 属性往往是离散型的
 - 对于连续型的索引，往往用B树
- 倒排文件：带有倒排索引的文件

11.3.1 基于属性的倒排

教师数据库倒排表

Department list	EMP#
数学	0155, 0132, 0119
物理	0208, 0211
计算机	0330, 0310, 0341
外语	0421, 0455
Profession list	EMP#
教授	0155, 0330
讲师	0211, 0119, 0455, 0310
助教	0421, 0208, 0132, 0341
Specialty list	EMP#
代数	0155, 0119
几何	0132
力学	0208
原子物理	0211
软件	0330, 0341
英语	0421, 0310
法语	0455



优缺点

- 优点：
 - 能够对于基于属性的检索进行较高效率的处理
- 缺点：
 - 花费了保存倒排表的存储代价
 - 降低了更新运算的效率



11.3.2 对正文文件的倒排

- 正文索引 (Text Indexing) 处理的就是“建立一个数据结构以提供对文本内容的快速检索”
- 方法
 - 词索引 (word index)
 - 全文索引 (full-text index)



词索引

- 基本思想：
 - 把正文看作由符号和词所组成的集合，从正文中抽取关键词，然后用这些关键词组成一些适合快速检索的数据结构。
- 适用于多种文本类型，特别是那些可以很容易就解析成一组词的集合的文本
 - 适用于英文
 - 中文等东方文字要经过“切词”处理



全文索引

- 基本思想：
 - 把正文看作一个长的字符串
 - 在数据结构中记录的是子字符串的开始位置
 - 查询就可以针对正文中的任何子字符串
- 可以对每一个字符建立索引，从而使查询词不再限于关键词
- 需要更大的空间



倒排文件使用最广泛的是词索引

- 词索引使用 **最广泛**
- 一个已经排过序的关键词的列表
 - 其中每个关键词指向一个倒排 (posting list)
 - 指向该关键词出现文档集合
 - 在文档中的位置



倒排索引建立示例

正文文件：由6个文档组成，每个文档都是长字符串

文档编号	文本内容
1	Pease porridge hot, please 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.

文档编号	文本内容
1	Pease porridge hot, please 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.

类似处理1中的其他词语

同理，处理2中的词语

依次处理所有文档

倒排索引

编号	词语	(文档编号 , 位置)
1	cold	(1,6)
2	days	
3	hot	(1,3)
4	in	
5	it	
6	like	
7	nine	
8	old	
9	pease	(1,1) (1,4) (2,1)
10	porridge	(1,2) (1,5)
11	pot	
12	some	
13	the	



建立正文倒排文件

1. 对文档集中的所有文件都进行分割处理，把正文分成多条记录文档

切分正文记录取决于程序的需要

定长的块、段落、章节，甚至一组文档



建立正文倒排文件（续1）

2. 给每条记录赋一组关键词

以人工或者自动的方式从记录中抽取关键词

停用词(Stopword)

抽词干(Stemming)

切词 (Segmentation)



中文切词 Chinese Segmentation

我知道你不知道我知道你不知道我知道你不知道

- 我知道，你不知道。我知道，你不知道我知道，你不知道
- 我知道你，不知道我。知道你不知道我，知道你不知道
- 我，知道你不知道我知道。你，不知道我知道你不知道



教育部部长周济说，今后若干年内，毕业生总量将会持续增加，每年都有数十万的增量，对毕业生就业工作无疑是巨大的挑战。2005年高校毕业生总量大、增幅高，各地和高校工作进展情况差异较大，并且还存在许多深层次的矛盾和问题。在全社会就业形势十分严峻的形势下，2005年高校毕业生就业工作压力十分突出。

操作选项

☒ 词语切分☐ 一级标注☐ 二级标注

输出格式

☒ 北大标准☐ 973标准☐ XML

运行

处理文件...

退出

关于...

1

结果

平滑参数:

0

当前结果评分:

-101.911148

处理用时:

10

ms

教育部 部长 周济 说 ， 今后 若干 年 内 ， 毕业生 总量 将 会 的 持续 增加 ， 每年 都 有 数十 万 的 增量 ， 对 毕业生 就业 工作 无疑 是 巨大 的 挑战 。 2005 年 高 校 毕业 生 总量 大 、 增幅 高 ， 各地 和 高校 工作 进展 情况 差异 较 大 ， 并 且 还 存在 许多 深 层次 的 矛盾 和 问题 。 在 全 社会 就业 形势 十分 严峻 的 形势 下 ， 2005 年 高 校 毕业 生 就业 工作 压力 十分 突出 。



建立正文倒排文件（续2）

3. 建立正文倒排表、倒排文件
得到各个关键词的集合
对于每一个关键词得到其倒排表
然后把所有的倒排表存入文件



对关键词的检索

- 第一步，在倒排文件中检索关键词
- 第二步，如果找到了关键词，那么获取文件中的对应的倒排表，并获取倒排表中的记录
- 通常使用另一个索引结构（字典）进一步对关键词表进行 **有效索引**
 - Trie
 - 散列



倒排文件优劣

- 高效检索，用于文本数据库系统
- 支持的检索类型有限
 - 检索词有限（只能用索引文件中的关键词）
 - 倒排文件中的索引效率可能不高
 - 需要的空间代价往往很高



思考

- 怎样有效地组织属性倒排索引表？
- 一个关键词如果在同一个文本中多次出现，它在倒排文件中的索引项是否能进行合并？



数据结构与算法

谢谢聆听

国家精品课“数据结构与算法”

<http://www.jpk.pku.edu.cn/pkujpk/course/sjjg/>

张铭，王腾蛟，赵海燕

高等教育出版社，2008. 6。“十一五”国家级规划教材