

## 26 | 搜索引擎架构：如何瞬间完成海量数据检索？

2020-01-22 李智慧

后端技术面试38讲

[进入课程 >](#)



讲述：李智慧

时长 10:17 大小 8.25M



我们在使用搜索引擎的时候，搜索结果页面会展示搜索到的结果数目以及花费时间。比如用 Google 搜索中文“后端技术”这个词，会显示找到约 6.7 亿条结果，用时 0.45 秒。

后端技术



全部

新闻

地图

图片

视频

更多

设置

工具

找到约 670,000,000 条结果（用时 0.45 秒）



我们知道 Google 收录了全世界几乎所有的公开网页，这是一个非常庞大的数目，那么 Google 是如何做到在如此短的时间内完成了如此庞大的数据搜索呢？

## 搜索引擎倒排索引

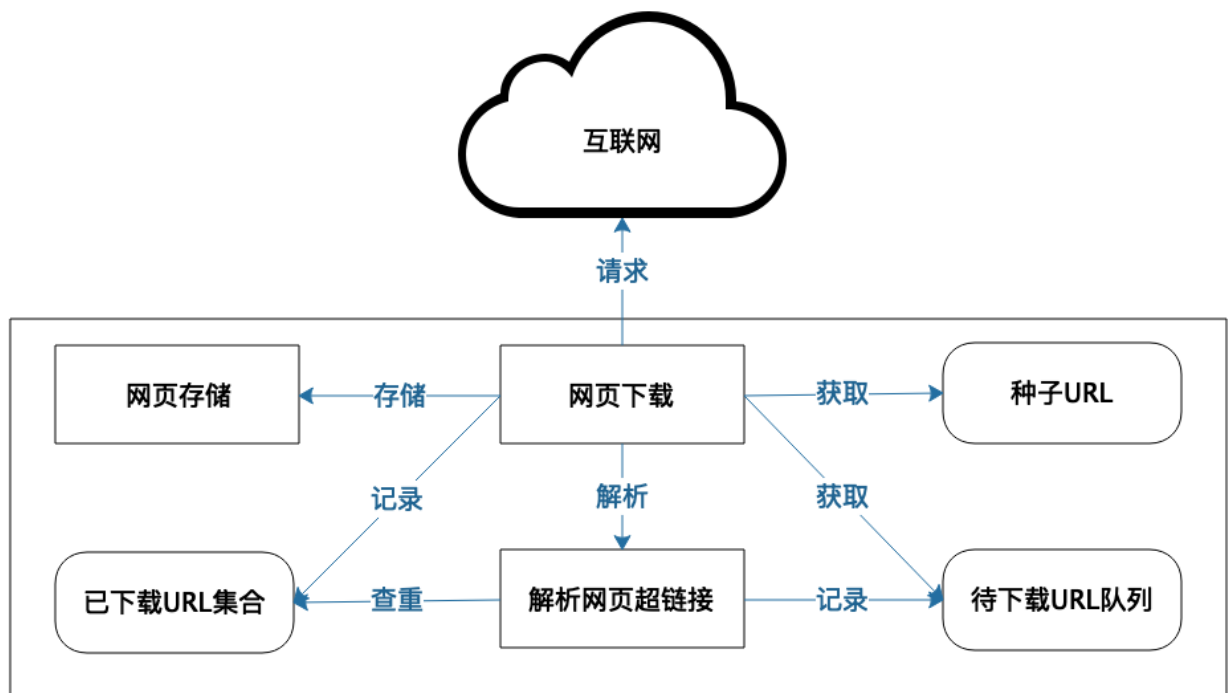
数据的搜索与查找技术是计算机软件的核心算法，这方面已有非常多的技术和实践。而对于搜索引擎来说，要对海量文档进行快速内容检索，主要使用的是倒排索引技术。

像 Google 这样一个互联网搜索引擎，首先需要通过网络爬虫获取全球的公开网页。那么搜索引擎如何知道全世界的网页都在哪里呢？

事实上，互联网一方面是将全世界的人和网络应用联系起来，另一方面，也将全世界的网页通过超链接联系起来，几乎每个网页都包含了一些其他网页的超链接，这些超链接互相链接，就让全世界的互联网构成了一个大的网络。所以，搜索引擎只需要解析这些网页，得到里面的超链接，然后继续下载这些超链接的网页，继续解析，这样就可以得到全世界的网页了。

这个过程具体是这样的。首先选择一些种子 URL，然后通过爬虫将这些 URL 对应的页面爬下来。其实，所谓的爬虫，就是发送 URL 请求，下载相应的 HTML 页面，然后将这些 Web 页面存储在自己的服务器上，并解析这些页面的 HTML 内容，当解析到网页里超链接 URL 的时候，再检查这个超链接是否已经在前面爬取过了，如果没有，就把这个超链接放到一个队列中，后面会请求这个 URL，得到对应的 HTML 页面并解析其包含的超链接.....如此不断重复，就可以将全世界的 Web 页面存储到自己的服务器中。

爬虫系统架构如下：



得到了全部网页以后，需要对每个网页进行编号，得到全部网页的文档集合。然后再解析每个页面，提取文档里的每个单词，如果是英文，那么每个单词都用空格分隔，比较容易；如果是中文，需要使用中文分词器才能提取到每个单词，比如“后端技术”，使用中文分词器得到的就是“后端”、“技术”两个词。

然后考察每个词在哪些文档中出现，比如“后端”在文档 2、4、5、7 中出现，“技术”在文档 1、2、4 中出现，这样我们就可以得到一个单词、文档矩阵：

文档编号 单词	1	2	3	4	5	6	7
后端		√		√	√		√
技术	√	√		√			

把这个单词、文档矩阵按照单词→文档列表的方式组织起来，就是倒排索引了：

单词	文档列表
后端	2、4、5、7
技术	1、2、4

我们这个例子中只有 2 个单词、7 个文档。事实上，Google 数以万亿的网页就是这样通过倒排索引组织起来的，网页数量虽然不可思议地庞大，但是单词数却是比较有限的，所以，整个倒排索引的大小相比网页数量要小得多。Google 将每个单词的文档列表存储在硬盘中，而对于文档数量没那么大的应用而言，文档列表也可以存储在内存中。每个单词记录下硬盘或者内存中的文档列表地址，搜索的时候，只要搜索到单词，就可以快速得到文档地址列表。根据列表中的文档编号，展示对应的文档信息，就完成了海量数据的快速检索。

而搜索单词的时候，我们可以将所有单词构成一个 Hash 表，根据搜索词直接查找 Hash 表，就可以得到单词了。如果搜索词是“后端”，那么快速得到文档列表，有 4 个；如果搜索词是“后端技术”，那么首先需要对搜索词进行分词，得到“后端”、“技术”两个搜索单词，分别得到这两个单词的文档列表，然后将这两个文档列表求交集，也很快可以得到搜索结果，有两个。

虽然搜索引擎利用倒排索引已经可以很快得到搜索结果了，但是实践中，搜索引擎应用还会使用缓存对搜索进行加速，将整个搜索词对应的搜索结果直接放入缓存，以减少倒排索引的访问压力，以及不必要的集合计算。


## 搜索引擎结果排序

有了倒排索引，虽然可以快速得到搜索结果了，但是，如果搜索结果比较多，哪些文档应该优先展示给用户呢？我们使用 Google 搜索“后端技术”的时候，虽然 Google 告诉我们，搜索结果有 6.7 亿个，但是我们通常在搜索结果列表的头几个，就能找到想要的结果，而列表越往后，结果也越不是我们想要的。Google 是如何知道我们想要的结果是哪些呢？这样的搜索结果展示显然是排过序的，那搜索引擎的结果是如何排序的呢？

事实上，Google 使用了一种叫 PageRank 的算法，计算每个网页的权重，搜索结果就按照权重排序，权重高的网页在最终结果显示的时候排在前面。为什么权重高的网页正好就是

用户想要看到的呢？我们先看下这个网页权重算法，即 PageRank 算法。

PageRank 算法认为，如果一个网页里包含了某个网页的超链接，那么就表示该网页认可某个网页，或者说，该网页给某个网页投了一票。如下 A、B、C、D 四个网页，箭头指向的方向就是表示超链接的方向，B 的箭头指向 A，表示 B 网页包含 A 网页的超链接，也就是 B 网页给 A 网页投了一票。



开始的时候，所有网页都初始化权重值为 1，然后根据超链接关系计算新的权重。比如 B 页面包含了 A 和 D 两个页面的超链接，那么自己的权重 1 就被分成两个  $1/2$  分别投给 A 和 D。而 A 页面的超链接包含在 B、C、D 三个页面中，那么 A 页面新的权重值就是这个三个页面投给它的权重值之和： $1/2 + 1/3 + 1 = 11/6$ 。

经过一轮 PageRank 计算后，每个页面都有了新的权重，然后基于这个新的权重再继续一轮计算，直到所有的网页权重稳定下来，就得到最终所有网页的权重，即最终的 PageRank 值。

通常，在一个网页中包含了另一个网页，是对另一个网页的认可，认为这个网页质量高，值得推荐。而被重要网页推荐的网页也应该是重要的，PageRank 算法就是对这一设想的实现，PageRank 值代表了一个网页受到的推荐程度，越受推荐越重要，就越为用户想看到

的。基于每个网页的 PageRank 值对倒排索引中的文档列表进行排序，排在前面的文档通常也是用户想要看到的文档。

PageRank 算法对于互联网网页排序效果很好，但是，对于那些用户生成内容（UGC）的网站而言，比如豆瓣、知乎，或者我们的 [InfoQ](#)，如果想在这些网站内部进行搜索，PageRank 算法就没什么效果了。因为豆瓣的影评，知乎的回答，InfoQ 的技术文章之间很少通过超链接进行推荐。

那么，要相对这些站内搜索引擎的结果进行排序，就需要利用其它一些信息以及算法，比如可以利用文章获得的点赞数进行排序，点赞越多，表示越获得其它用户的认可，越应该在搜索结果中排在前面。利用点赞数排序，或者 PageRank 排序，都是利用内容中存在的推荐信息排序，而这些推荐信息来自于广大参与其中的人，因此这些算法实现也被称作“集体智慧编程”。

除了用点赞数进行排序，有时候，我们更期望搜索结果按照内容和搜索词的相关性进行排序，比如我在 [infoq.cn](#) 搜索 PageRank，我其实并不想看那些点赞很多，但是只提到一点 PageRank 的文章，而想看主要讲 PageRank 算法的文章。

这种情况可以使用词频 TF 进行排序，词频表示某个词在该文档中出现的频繁程度，也代表了这个词和该文档的相关程度。词频公式如下：

$$TF = \frac{\text{某个词在该文档中出现的次数}}{\text{该文档总词数}}$$

使用豆瓣电影进行搜索的时候，豆瓣的搜索结果主要是电影名中包含了搜索词的电影，比如我们搜索“黑客”这个词，豆瓣的搜索结果列表就是以“黑客”为电影名的电影。



## 搜索 黑客



## 黑客 Hackers (1995) [可播放]

★★★★☆ 6.4 (942人评价)

美国 / 动作 / 犯罪 / 剧情 / 惊悚 / 黑客 / 107分钟

Iain Softley / 约翰尼·李·米勒 / 安吉丽娜·朱莉 / 杰西·布拉德福特 / 马修·里沃德 / Laurence Mason / Renoly Santiag...



## 黑客 Hacker (2016)

★★★★☆ 5.7 (379人评价)

加拿大 Canada / 剧情 / 犯罪 / 惊悚 / 駭客交鋒(台) / 95分钟

阿坎·萨塔耶夫 / 卡兰·麦克奥莉菲 / 洛琳·尼科尔森 / 丹尼尔·艾瑞克·高德 / 小克利夫顿·克林斯 / 扎卡里·贝内特



## 黑客 Hacker (2019)

★★★★★ (暂无评分)

丹麦 / 瑞典 / 动作 / 家庭 / Hacker / <http://www.renrendianyingwang.cn/>

Poul Berg / Mille Dinesen / Morten Suurballe / Signe Egholm Olsen / Claus Riis Østergaard / Esben Dalgaard An...



## 黑客 Groom Lake (2003)

★★★★★ (暂无评分)

美国 / 恐怖 / 科幻 / 外星异种 / The Visitor / 92分钟

威廉·夏特纳 / 丹·盖特纳 / 艾米·阿克 / 汤姆·托尔斯 / 迪克·范·帕滕 / John Prosky / Dan Martin / Rickey Medlocke

但是，如果我想搜索电影内容是关于黑客的，但是标题里可能没有“黑客”两个字的电影，豆瓣的搜索就无能为力了。几年前，我自己专门写了一个电影搜索引擎，利用豆瓣的影评内容建立倒排索引，利用词频算法进行排序，搜索的结果如下，这个结果更符合我对电影搜索引擎的期待。



### 虎胆龙威4 Live Free or Die Hard,\_(2007)

某年7月4日，周末，正在休假的约翰·麦卡伦（布鲁斯·威利斯 饰）接到一个新任务：逮捕黑客马特·法莱尔（贾斯汀·朗 饰），然后送到FBI那 ...

伦·怀斯曼 马克·鲍姆贝格 布鲁斯·威利斯 动作 美国 英语 2007-11-22(中国大陆) 128 分钟  
终极警探4.0 ...

关键词： 虎胆龙威 英雄 布鲁斯 美国 4

评分：7.5 /10



### 剑鱼行动 Swordfish,\_(2001)

间谍加布利尔（约翰·特拉沃塔 John Travolta）在多年特工生涯中，获知政府多年非法收敛了一笔公款。而加布利尔若想实现自己心中的 ...

多米尼克·塞纳 Skip Woods 约翰·特拉沃尔塔 动作 美国 英语 2001-06-08(美国) 99 分钟  
旗鱼行动 ...

关键词： 特拉 约翰 美国 正义 黑客

评分：7.3 /10



### 黑客帝国 The Matrix,\_(1999)

不久的将来，网络黑客尼奥（基奴李维斯 饰）对这个看似正常的现实世界产生了怀疑。他结识了黑客崔妮蒂（凯莉·安·摩丝 饰），并见到了黑客组织 ...

安迪·沃卓斯基 安迪·沃卓斯基 基努·李维斯 动作 美国 英语 1999-03-31(美国) 136分钟 骇客任务 ...

关键词： 人类 世界 matrix 机器 neo

评分：8.7 /10



### 黑客帝国2：重装上阵 The Matrix Reloaded,\_(2003)

上一部结尾，尼奥（基奴李维斯 饰）终于意识到自己的能力和使命，中弹复活后，变成了无所不能的“救世主”。他和女友崔妮蒂（凯莉·安·摩丝 饰）

如果你对这个搜索引擎有兴趣，源代码的地址在这里：

🔗 <https://github.com/itisaid/sokeeper>

## 小结

事实上，搜索引擎技术不只是用在 Google 这样的搜索引擎互联网应用中，对于大多数应用而言，如果想要对稍具规模的数据进行快速检索，都需要使用搜索引擎技术。而对于淘宝这样的平台型应用，搜索引擎技术甚至驱动其核心商业模式。一方面，淘宝海量的商品需要通过搜索引擎完成查找，另一方面，淘宝的主要盈利来自于搜索引擎排名。所以，本质上，淘宝的核心技术和盈利模式跟百度、Google 都是一样的。



## 思考题

文中我们讨论了 PageRank 算法，如果只有几百个网页，那么写一个程序计算每个网页 PageRank 就可以了，但是如果是 Google 这样万亿级的网页，网页之间的超链接关系数量更加庞大，而 PageRank 算法又需要多轮计算，如何才能较快地计算出所有网页的 PageRank 值呢？

欢迎你在评论区写下你的思考，也欢迎把这篇文章分享给你的朋友或者同事，一起交流一下。

点击参加 21 天打卡计划 

## 搞定后端技术基础



扫一扫参与小程序话题



新版升级：点击「 请朋友读」，20位好友免费读，邀请订阅更有**现金**奖励。

© 版权归极客邦科技所有，未经许可不得传播售卖。页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 25 | 数据存储架构：如何改善系统的数据存储能力？

下一篇 27 | 微服务架构：微服务究竟是灵丹还是毒药？

## 精选留言 (3)

 写留言



旅梦开发团

2020-01-29

如果有一些延展就好了 给一些实例的github 链接。 比如 简单PageRank 实现 点赞数排

序....



👍 1



號國技醬

2020-01-30

pagerank和点赞都属于认可类型的推荐属于集体智慧  
词频应该是另一种相关度的类型



Citizen Z

2020-01-26

这个课后题有点难，肯定要把整个过程并行化，预感拆解任务是个有技术含量的事，还是等标准答案吧 Orz

