

# Intranet 搜索索引自动生成工具 WebIndex

沈达阳 于斌 林作铨 (汕头大学计算机科学研究所 515063)

**摘要:**本文在分析几种典型 Internet 搜索引擎的基础上,设计实现了一种面向 Intranet 的信息收集 agent,着重阐述了 WebIndex,一个基于 IICA 体系的 Intranet 搜索索引自动生成工具。该系统克服了现有产品的一些缺点,在系统的可伸缩性、可移植性和中文处理能力方面有明显的改进。

**关键词:**Intranet agent 搜索引擎 索引生成器

针对 Intranet 用户,我们设计实现了一种 Intranet 上的信息收集 agent。与众多同类 agent 不同的是,我们利用自己的搜索索引自动生成器 - WebIndex,通过对有限 Intranet 信息源的访问来建立索引。它既能提供和 Yahoo 类似的高度相关性的信息,使用户能够得到局限于某一网络范围的信息,避免通用搜索引擎所反馈的,十分庞杂的信息干扰,又能自动更新和扩展,可以对指定的 Intranet 范围内进行自动搜索,这些对 Intranet 系统的信息处理和检索具有重要的意义。

## 一、现有搜索索引的建立方法和存在问题

目前,通用 Internet 搜索引擎所用搜索索引的建立方法,主要有以下两种:

1. 人工维护的搜索索引:如 Yahoo! 和一些虚拟图书馆系统,利用大量的人力浏览 Internet 页面,对其进行分类,因此,建立的搜索索引覆盖面较窄,但比较精确,一般只适用于相对小型、静态的信息(如大学的 Web 信息),因为编辑人员不可能跟上庞杂,快速增长的信息(如个人主页或美国经济新闻,某个主题的学术文章等)。

2. Internet 搜索蜘蛛 (Internet spider) 产生的搜索索引:(如 AltaVista, Lycos, Excite 等),这些自动生成的索引覆盖面很广,但在精确性方面却很差。用户往往被迫人工从庞杂的反馈中,过滤出所需的信息。

还有另外一种搜索引擎 - 元搜索引擎。所谓元搜索引擎,实际上是一种本身不具备搜索索引,而依靠其他原始引擎的索引或搜索接口,来完成其搜索任务的引擎。无搜索引擎的研究重点在于,如何在众多原始引擎提供的信息中,以友好的人机界面,精确地挑选出用户所需的信息。因此,虽然元搜索引擎往往能提供比通用引擎相关性更好,覆盖面更广的搜索结果,但由于它依赖于其他

的搜索索引,对于希望为自己的 Intranet 系统建立搜索索引的用户,或者对于希望搜索局限于某个 Intranet 范围的信息的用户,它都是无能为力的[3]。

同时,有一些 Web 服务器,也提供一些简单的 Intranet 搜索产品,如 Microsoft IIS4.0 中的 SiteSearch,它可以提供 Intranet 页面信息的简单搜索。但是 SiteSearch 只能搜索它所在服务器的页面,所以它不能适应包含多台 Web 服务器的 Intranet 体系。

## 二、信息收集 agent 的整体设计

### 1. WebIndex 所索引的 Intranet 信息结构

WebIndex 的应用目标,是通过一些搜索蜘蛛为一定 Internet 范围内的信息建立搜索索引。对搜索蜘蛛而言,Intranet 就是作为它活动范围的一些 Web 服务器,这些服务器的 URL 满足一定的条件。以汕头大学的校园网为例,有下列 Web 服务器:

服务器名称	URL
汕头大学网络中心服务器 1	<a href="http://www.stu.edu.cn/">Http://www.stu.edu.cn/</a>
汕头大学网络中心服务器 2	<a href="http://xjshi.stu.edu.cn/">http://xjshi.stu.edu.cn/</a>
汕头大学计算机科学研究所服务器 1	<a href="http://www.ics.stu.edu.cn/">http://www.ics.stu.edu.cn/</a>
汕头大学计算机科学研究所服务器 2	<a href="http://stuics2.tu.edu.cn/">http://stuics2.tu.edu.cn/</a>
汕头大学智能和模式识别实验室服务器 1	<a href="http://stuaipr2.stu.edu.cn/">http://stuaipr2.stu.edu.cn/</a>
汕头大学智能和模式识别实验室服务器 2	<a href="http://www.aipr.stu.edu.cn/">http://www.aipr.stu.edu.cn/</a>
汕头大学数据研究所服务器 1	<a href="http://www.maths.stu.edu.cn/">http://www.maths.stu.edu.cn/</a>
汕头大学医学院服务器 1	<a href="http://www.med.stu.edu.cn/">http://www.med.stu.edu.cn/</a>

从上表可以发现,所有服务器的 URL (Uniform Resource Locator, 是一个用于标识任何 Internet 信息的字符串) 都是以 "stu.edu.cn" 结尾的,说明它们都是属于汕头大学校园网的服务器。搜索蜘蛛就利用这样的特征,来

限定它漫游的范围。因此, WebIndex 的蜘蛛并不需要提供 Intranet 中所有服务器的 URL, 只要提供一些 URL 的识别特征, 它就能够实现在指定范围内漫游的任务。如果没有提供任何特征, 它就根据常识, 从给定的漫游起始 URL 中抽取。例如:

- 给定“<http://www.stu.edu.cn/>”为起始 URL, 蜘蛛就默认识别特征为“stu.edu.cn”, 搜索范围就限定在汕头大学校园网。

- 给定“<http://www.stu.edu.cn/chinese/xueyuan/>”为起始 URL, 蜘蛛就默认识别特征为“stu.edu.cn/chinese/xueyuan/”, 搜索范围就限定在汕头大学学院主页。

- 给定“<http://www.edu.cn/>”为起始 URL, 蜘蛛就默认识别特征为“edu.cn/”, 搜索范围就限定在中国科研和教育网(CERNET)。

可见, 对 WebIndex 的蜘蛛而言, Intranet 的概念十分灵活, 这使 WebIndex 生成的索引系统具有较好的可伸缩性。

## 2. WebIndex 的搜索蜘蛛

搜索蜘蛛 (Spider, 也称为 Web Wanderers, Web Crawlers, Web Robots 等) 实际上是一个程序, 它从一批给定的 URL 开始, 根据一定的算法在 Internet 上漫游, 对它从服务器上取回信息(一般是 HTML 文本)进行分析, 抽取出新的 URL, 作为以后漫游的目标。

漫游的基本算法有两种: 宽度优先算法和深度优先算法[2]。虽然 IICA 实现了这两种算法及其变种, 但由于 WebIndex 索引的目标是 Intranet, 对蜘蛛来说, 也就是某个 WebIndex 采用宽度优先的算法, 同时采用许多启发式知识来限制搜索的内容和深度, 如协议, 服务器名称, 目录名称和目录深度等。

在 IICA 体系中, 搜索蜘蛛是一个以 Java 线程形式运行的 Agent, 它包含 3 记忆状态: ToDo(将要处理的工作), Done(已经完成的工作)和 Doing(它正在做什么工作):

- ToDo 队列: 蜘蛛以宽度优先的方式搜索 Web 服务器, 由于并发线程数量有限, 它往往不能同时完成几个页面所有 Internet 连接的分析工作, ToDo 是一个先进先出队列, 其目的是, 保存所有没有被完成的连接的 URL, 以便蜘蛛下一步工作的需要。

- Done 哈希表: Internet 的 Web 页面往往是互相连接, 因此蜘蛛在漫游过程中会碰到许多已经经历过的 URL, Done 哈希表的目的是记录蜘蛛经历过的所有 URL, 从而避免 URL 的重游。由于经历过的 URL 很多,

需要利用哈希表在漫游的过程中, 提供快速的检索。

- Doing URL: 记录蜘蛛正在处理的 URL, 在 IICA 体系中, 蜘蛛有一个函数指针, 指向默认的处理函数, 其他驱动蜘蛛的 Agent 可以把它喜欢的处理方法, 以函数的形式传送给蜘蛛, 从而改变蜘蛛对该 URL 的处理行为。

同时, 它也包含了一些辅助性的 Agent, 如:


- Robotics 检查器: 根据 Robot Exclusion Standard(这是一个蜘蛛搜索的工业规范), 查找 Web 服务器的 Robot Exclusion 限制, 以规范蜘蛛的漫游行为。

- HTML 分析器: 分析 HTML 文本, 抽取出蜘蛛所需的信息。

## 3. 搜索过程中索引的建立方法

和英文的 Internet 搜索索引相比, 中文 Internet 信息检索系统的发展相对比较慢, 目前已有的中文搜索引擎大部分还处于“字”的索引阶段。不仅效率较低, 而且信息检索的精度很差。究其原因, 是中文信息检索有自身的特点: 中文词之间没有标记(如英文中的空格), 也没有显式的标记来辨识人名、地名等未登录词(如英文中的大写字母), 另外, 中文的词性标注难度也较高(没有英文动词时态变化这样的形态特征)[4]。

因此, 如果要对中文词建索引, 首先, 要对中文文本进行自动分词和未登录词的辨识, 其次, 对词法和短语的进一步处理也有助于提高索引的有效性。WebIndex 建立索引的过程如下图:



### 信息预处理包括:

- 分析信息源的类型, 区分协议类型(目前支持 http 和 ftp 两种), 目录和文件, 以及文件的类型(目前支持 HTML 文本, 一般 TEXT 文本和 GIF、JPG 两种图形格式)[2]。

- 把 HTML 文本分析为标记和文本的向量空间形式[2]。

对 HTML 文本的文本空间和一般 TEXT 文本进行

汉语自动分词。其目的是：

- 减少索引所需的空间(一般来说,词索引量比字索引量要少)

- 提高索引的效率(词索引的检索速度比字索引要快得多)

- 提高检索的精确度(歧义可以引起小于3%的分词错误,未登录词有可能引起7%的分词错误)[4]

#### 4. 索引特征库的结构

一般全文检索系统典型的倒排检索索引的结构如下

检索词 1	URL <sub>i</sub>	W <sub>i</sub>	URL <sub>i+1</sub>	...	URL <sub>m</sub>	W <sub>m</sub>
检索词 2	URL <sub>j</sub>	W <sub>j</sub>	URL <sub>j+1</sub>	...	URL <sub>n</sub>	W <sub>n</sub>
...						
...						
...						

在某一检索词所对应的检索项中,可以查到包含该检索词的所有信息源的 URL 以及相关的权重。由于 WebIndex 不但要求能提供相关检索词信息源的 URL,也要提供该信息源的摘要,而且,由于一个 URL 往往被多个索引项所使用,非常浪费系统资源,所以,我们改进了以上的结构。把倒排索引分为三部分:基本索引、URL 索引、摘要文件。基本索引的结构如下:

检索词:计算机					
文件 & 地址	权重	前导词	前导地址	后继词	后继地址
A560	3	常识问题	0	研究	223
A560	3	超协调限制逻辑	133	学报	40
A560	3	可废除推理研究	247	科学	818
A570	1	青年	0	学术	65
...					

上表是检索词“计算机”的一些索项,例如,在第一个检索项中:

- 文件 & 地址域:“A560”,既代表该检索项所在 URL 的摘要文件的文件名,其数字部分“560”,又是该索引项在 URL 索引中的偏移地址,利用该域就可以得到该检索项所对应 URL 的名称和摘要。

- 权重域:代表该检索词在该 URL 出现的权重(不一定是简单的出现频度,而是根据 HTML 标记调整)。


- 前导词:该检索词在此 URL 出现时,出现在其前面的词或短语

- 前导词地址:此前导词所对应检索项的偏移地址

- 后继词:该检索词在此 URL 出现时,出现在其后面的词或短语

·后继词地址:此后继词所对应检索项的偏移地址

根据后四个域,对于某个检索项,可以复原出 URL 所对应信息源的文本的片段,如下所示:




这使 WebIndex 在没有该 URL 全文的情况下,能够对该 URL 所对应的信息源实现全文检索。

#### 5. 信息收集 Agent 的结构

在 Internet 信息检索领域,许多搜索引擎在英文信息检索技术方面发展较为迅速。如 Hotbot,可以利用向量空间表示线索信息内容,并将自然语言处理应用于信息检索,大大提高了信息查询的准确性,Infoseek, Lycos 在检索界面都增加了一些和自然语言有关的搜索功能等。本系统主要针对中文的特点,做了一些改进,其结构如下:

- 信息检索模型 WebIndex 搜索引擎采用布尔逻辑和向量空间相结合的信息检索模型,先把和用户查询有关的结果映射到一个向量空间,再根据相关信息项的权重进行排序和分类(分类的工作目前尚未实现)。

- 查询分析,包括:中英文查询的区分,码表的转换(对中文简体而言,是 GB 码和 Unicode 的转换 0,对要查询的中文字符串进行分词处理(这部分功能目前尚未实现),以及查询的扩展处理。



#### 6. 性能的评价和改进

要判断 web 搜索工具的性能是比较困难的,不过,任何对信息抽取技术的评价都是基于对它的精确率和召回率的测量。精确率测量在搜索过程中返回的相关信息的比例,召回率测量的是存在的相关信息被找到的比例。一般来说,增加召回率必须付出降低精确率的代价,反之

亦然。目前, WebIndex 和其他许多基于 Robot 的搜索索引一样, 通过对信息源相对检索词的权重排序来提高检索结果的精确度, 一般可以保证第一个查询反馈(20个 URL)的精确率在 90% 以上。召回率的提高要复杂得多, 需要进行查询扩展的处理。其中, 包括同义词扩展(如查询“计算机”时, 也同时查询它的其他同义词, 如“电脑”, “微机”等)和语义蕴涵扩展(如查询“动物”时, 查询其他属于此类的主题词, 如“猫”, “狗”等)。这将在以后的工作中, 利用《汉语同义词词林》来实现。

### 三、信息收集 agent 的实现和实验结果

信息收集 Agent 主要由两部分组成, 搜索蜘蛛和引擎界面。


搜索蜘蛛是采用 JDK1.15, 在 SUN Solaris2.5 操作系统上实现。目前运行在 SUN Sparc20 工作站上, 由于 Java 的平台无关性, 很容易移植到别的平台。目前, 我们分别以本单位(汕头大学计算机科学研究所)的 Intranet, 汕头大学网络中心, 汕头大学的校园网, 中国科研和教育网(CERNET)为指定的搜索范围, 搜索蜘蛛的搜索结果如下:

网络范围	搜索深度	页面个数	索引大小 (千字节)	索引/页面 比例
计算机科学研究所	3	37	1,029	27.8
汕头大学网络中心	3	177	6,324	34.0
汕头大学	3	1224	3,4404	28.1
CERNET	2	2580	40,748	15.8

从上表可以看到, WebIndex 所建立的索引的效率还是比较高的, 当页面的个数达到 Internet 级别时, 其索引/页面比例就开始有较大幅度的下降。

搜索引擎是利用 JavaWebServer 的 Servlet 技术实现的。Servlet 是一种服务器端的 Applet(faceless object), 它按照 JavaWebServer 的接口规范, 从而可以和 JavaWebServer 融为一体。其运行效率要比传统的 CGI 技术高得多, 而其实现的方便程度和可移植性, 又比 Microsoft - IIS 或 Netscape Enterprise Server 中的动态链接库或 API 好。目前, JavaWebServer 有 Solaris, Windows NT, Windows95 几个版本, 这保证 WebIndex 的搜索引擎可以运行在以上几个流行的 Internet 服务器平台上。

搜索引擎的 Internet 用户界面如下:



### 四、本系统的特点和以后工作的设想

从上文可见, 由于采用了 IICA 提供的灵活的搜索蜘蛛, Java 语言, 和相关的 Web 服务器 JavaWebServer, 本系统在可伸缩性和可移植性方面具有较大的优势, 其次, 采用了大量中文自然语言的处理技术, 对中文而言, 在索引的精确度和效率方面, 也有一定的优势。

目前, 本系统已经提供的搜索索引生成, 维护和查询的基本框架, 下一步的工作将从以下两个方面同时进行:

- 通过引入中文自然语言处理技术, 在文档分类, 摘要生成和查询分析几个方面, 改进用户的查询效率和反馈信息的精确度和可用性。

- 利用 MetaSearch 技术, 把分别负责几个信息领域的 WebIndex 搜索引擎集成起来, 在不降低系统信息的精确度的前提下, 探讨进一步提供 WebIndex 通用性的方法。

### 参考文献

- [1] 沈达阳, 林作钦, Internet 上的软件 agent, 计算机科学, 1997 Vol. 24 No. 4 14 - 19
- [2] Shen Dayang, Lin Zuoquan, Searching Algorithms of Internet 'Information COLlecting Agent, Proceedings of Workshop DAIMAS - 97, Russia St. Petersburg, 1997, 8
- [3] 陈智健, Internet/Intranet 上信息查询的研究与实现, 汕头大学硕士论文, 1998
- [4] Sun Maosong, Shen Dayang, CSeg & Tag1.0: A practical word segmenter and POS tagger, ANLP' 97, the Fifth Conference on Applied Natural Language Processing, USA Washington D. C., ACL, 1997. 3

(来稿时间: 1998 年 9 月)