



**Hasso  
Plattner  
Institut**

IT Systems Engineering | Universität Potsdam

## Search Engines Chapter 3 – Crawls & Feeds

21.4.2011

Felix Naumann

# What to crawl

2

- Every document answers at least one question:
  - „Now where was that document again?“
- Poor quality documents
  - Swamp index
  - Slow down query answering
- But
  - Have at least some value
  - Have not hindered success of commercial search engines
- Thus: Crawl everything
  
- More important:
  - Keep documents up to date
  - Keep archive of older material

# Overview

3



- Crawling the Web
- The Deep Web
- Document Conversion
- Document Storage
- Duplicate Detection
- Removing Noise



# Web Crawler

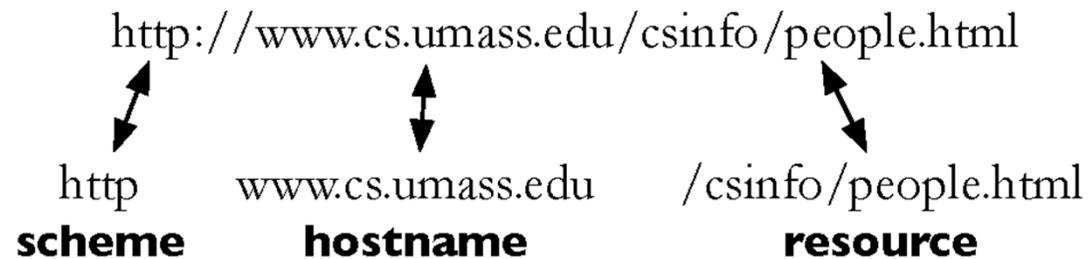
4

- Synonym: A *spider* spiders the Web
- Web crawling is easy: Pages are meant to be found and retrieved
  - Other information is hard to come by.
- Finds and downloads web pages automatically
  - provides the collection for searching
- Web is huge and constantly growing
  - Google knows 1 trillion pages (2008)
    - ◇ Not countable – what constitutes a page?
  - Vast storage is needed
- Web is not under the control of search engine providers
  - Set of pages at a particular web server unknown
  - Owner might not want page to be copied
  - Parallel crawling is impolite
  - Pages are hidden behind form
- Web pages are constantly changing
- Crawlers also used for other types of data

# Retrieving Web Pages

5

- Every page has a unique *uniform resource locator* (URL)
- Web pages are stored on *web servers* that use HTTP to exchange information with client software



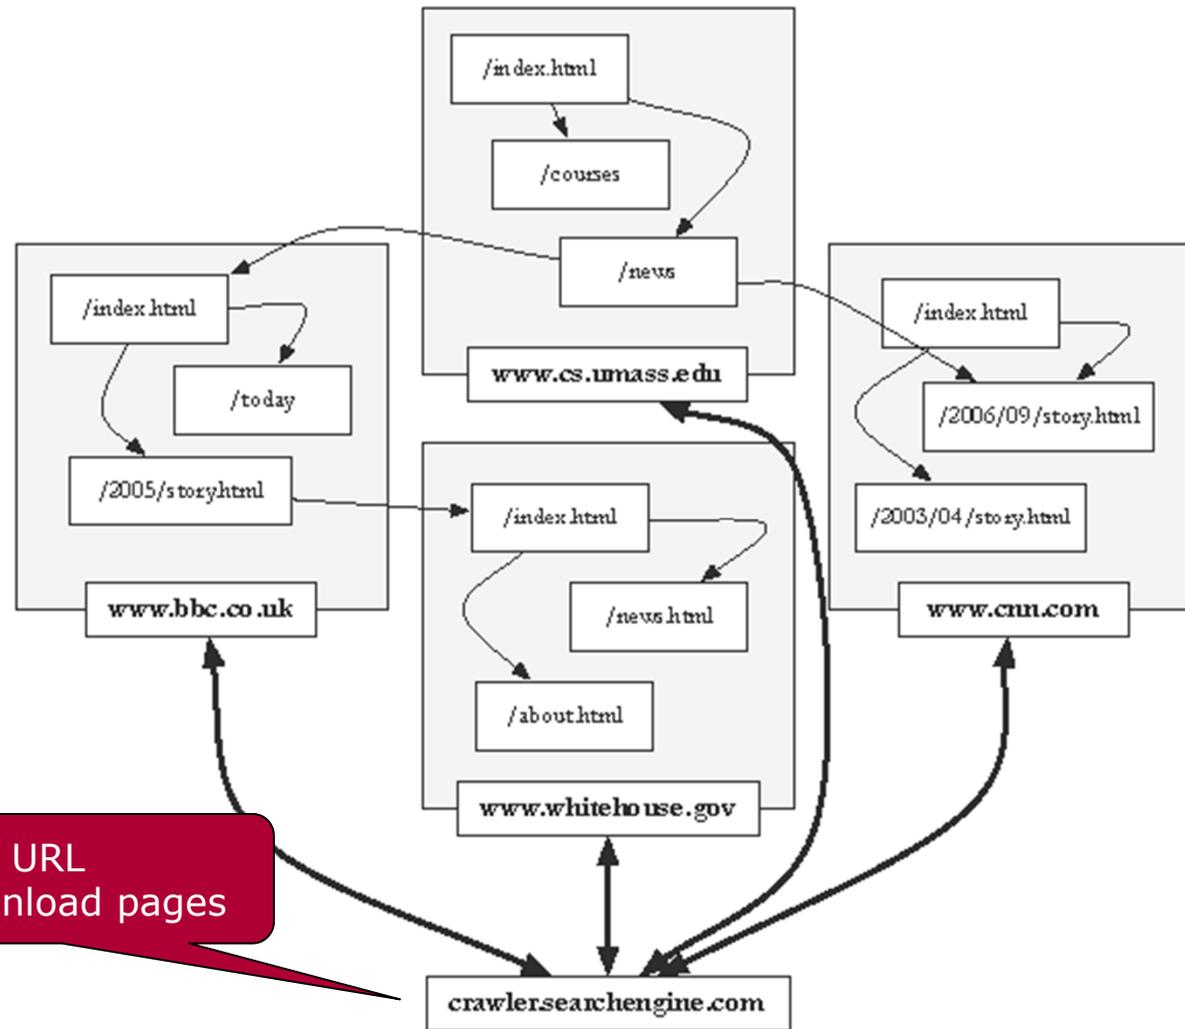
# Retrieving Web Pages

6

- Web crawler is similar to Web browser
  - Web clients that fetch web pages in the same way
- Web crawler client program connects to a *domain name system* (DNS) server
- DNS server translates the hostname into an *internet protocol* (IP) address
- Crawler then attempts to connect to server host using specific *port*
  - Usually port 80
- After connection, crawler sends an HTTP request to the web server to request a page
  - usually a GET request: `GET /csinfo/peope.html HTTP/1.0`

# Crawling the Web

7



# Web Crawler

8

- Start with a set of *seeds*
  - Set of URLs given as parameters
- Seeds are added to a URL request queue
- Crawler starts fetching pages from the request queue
- Downloaded pages are parsed to find link tags
  - Might contain other useful URLs to fetch
- New URLs added to the crawler's request queue, or *frontier*
  - Frontier: Standard queue or priority queue
- Continue until no more new URLs
  - or disk full

# Web Crawling

9

- Web crawlers spend a lot of time waiting for responses to requests
  - DNS server response
  - Connection to web server
  - Page download
- To reduce this inefficiency, web crawlers use threads and fetch hundreds of pages at once
- Crawlers could potentially flood sites with requests for pages
- To avoid this problem, web crawlers use *politeness policies*
  - No parallel requests
  - Delay between requests to same web server
  - Logically: one queue per web server
- Large queue
  - Crawler fetches 100 pages / sec
  - At most 1 page per server per 30 sec
  - => Queue size > 3,000
  - Normally much larger (many URLs in queue from same server)

# Controlling Crawling

10

- Even crawling a site slowly will anger some web server administrators, who object to any copying of their data
- `robots.txt` to control crawlers

```
User-agent: *
```

All crawlers

```
Disallow: /private/
```

```
Disallow: /confidential/
```

```
Disallow: /other/
```

```
Allow: /other/public/
```

```
User-agent: FavoredCrawler
```

Special crawler

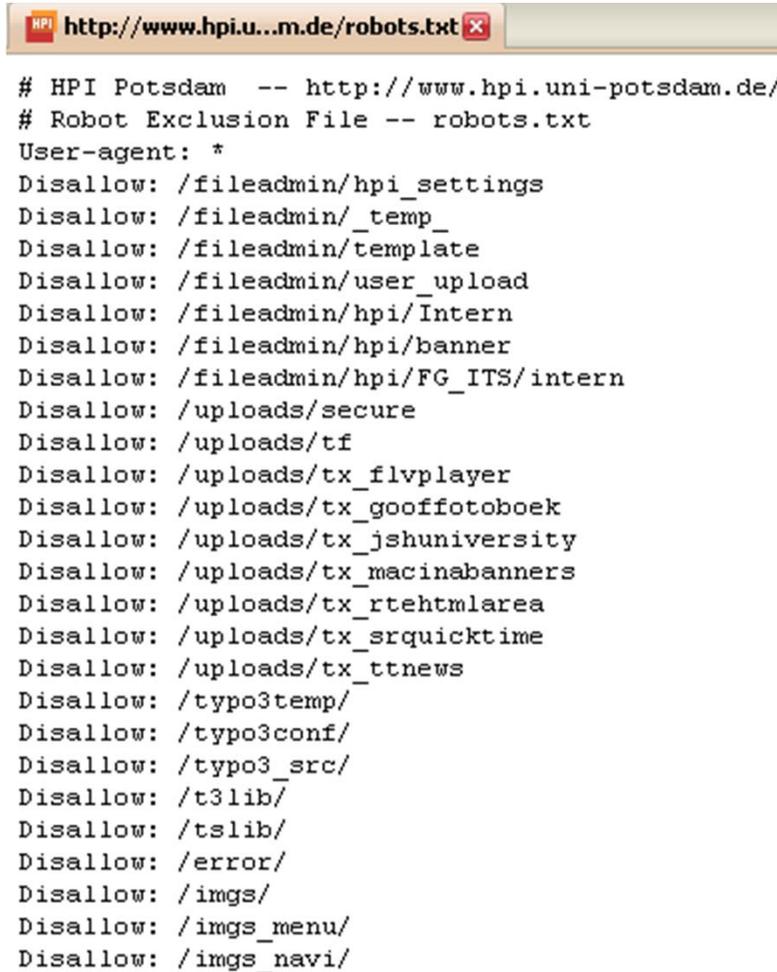
```
Disallow:
```

Reveal hidden web

```
Sitemap: http://mysite.com/sitemap.xml.gz
```

# HPI's robots.txt

11



```
# HPI Potsdam -- http://www.hpi.uni-potsdam.de/  
# Robot Exclusion File -- robots.txt  
User-agent: *  
Disallow: /fileadmin/hpi_settings  
Disallow: /fileadmin/_temp_  
Disallow: /fileadmin/template  
Disallow: /fileadmin/user_upload  
Disallow: /fileadmin/hpi/Intern  
Disallow: /fileadmin/hpi/banner  
Disallow: /fileadmin/hpi/FG_ITS/intern  
Disallow: /uploads/secure  
Disallow: /uploads/tf  
Disallow: /uploads/tx_flvplayer  
Disallow: /uploads/tx_gooffotoboek  
Disallow: /uploads/tx_jshuniversity  
Disallow: /uploads/tx_macinabanners  
Disallow: /uploads/tx_rtehtmlarea  
Disallow: /uploads/tx_srquicktime  
Disallow: /uploads/tx_ttnews  
Disallow: /typo3temp/  
Disallow: /typo3conf/  
Disallow: /typo3_src/  
Disallow: /t3lib/  
Disallow: /t3lib/  
Disallow: /error/  
Disallow: /imgs/  
Disallow: /imgs_menu/  
Disallow: /imgs_navi/
```

# Simple Crawler Thread

12

```
procedure CRAWLERTHREAD(frontier)
  while not frontier.done() do
    website ← frontier.nextSite()
    url ← website.nextURL()
    if website.permitsCrawl(url) then
      text ← retrieveURL(url)
      storeDocument(url, text)
      for each url in parse(text) do
        frontier.addURL(url)
      end for
    end if
    frontier.releaseSite(website)
  end while
end procedure
```



Politeness timer starts here

# Freshness

13

- Web pages are constantly being added, deleted, and modified
- Web crawler must continually revisit pages it has already crawled to see if they have changed in order to maintain the *freshness* of the document collection
  - *Stale* copies no longer reflect the real contents of the web pages

# Freshness

14

- HTTP protocol has a special request type called HEAD
  - Easy to check for page changes
  - Returns information about page, not page itself

```
Client request: HEAD /csinfo/people.html HTTP/1.1
                Host: www.cs.umass.edu
```

```
                HTTP/1.1 200 OK
                Date: Thu, 03 Apr 2008 05:17:54 GMT
                Server: Apache/2.0.52 (CentOS)
                Last-Modified: Fri, 04 Jan 2008 15:28:39 GMT
Server response: ETag: "239c33-2576-2a2837c0"
                Accept-Ranges: bytes
                Content-Length: 9590
                Connection: close
                Content-Type: text/html; charset=ISO-8859-1
```

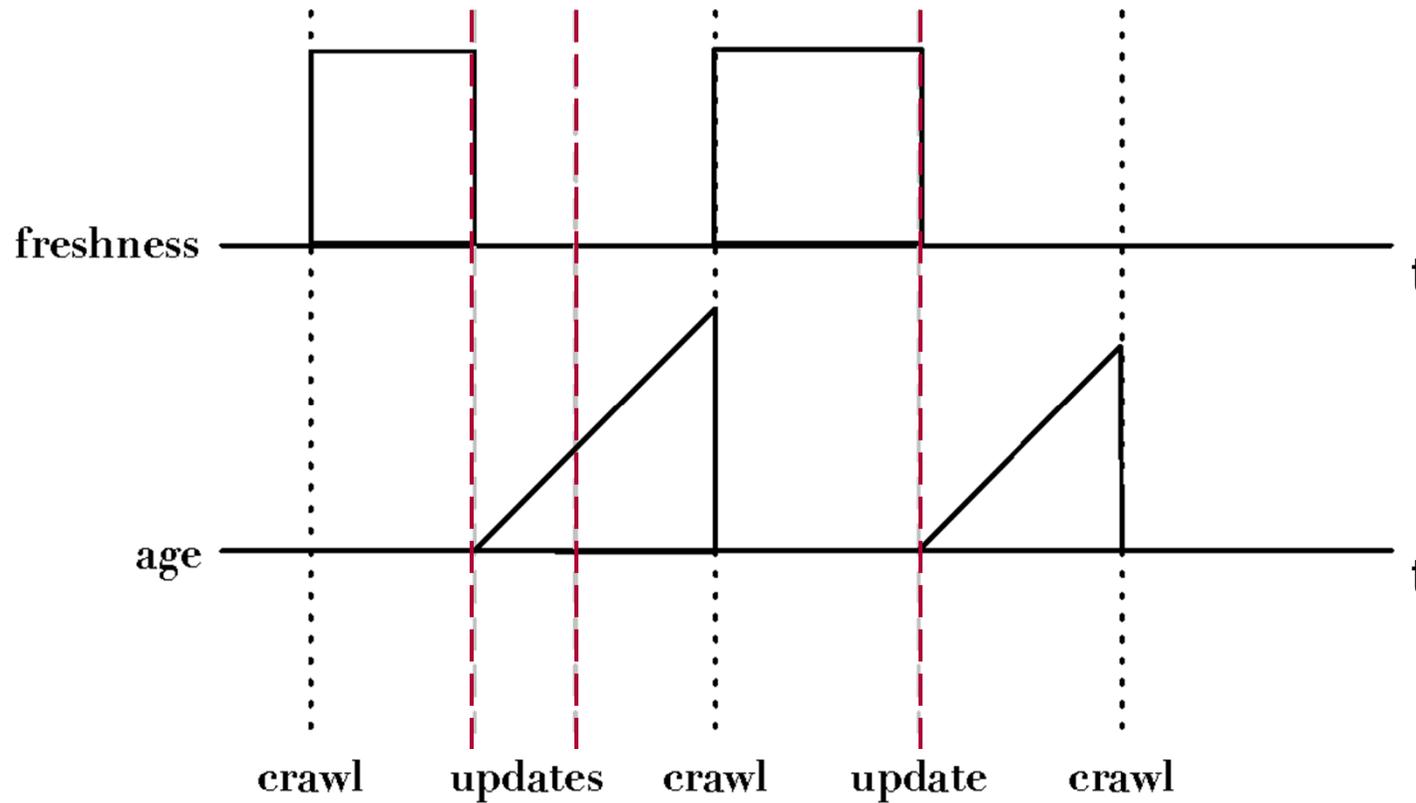
# Freshness

15

- Not possible to constantly check all pages
  - must check important pages and pages that change frequently
  - Different types of pages update at different rates
    - ◇ Homepage vs. news site
  - Differences even within type: Active vs. inactive blog
- Freshness is the proportion of pages that are fresh
  - Fresh = most recent copy
- Optimizing for this metric can lead to bad decisions, such as not crawling popular sites
  - One can never achieve freshness there, thus waste of resources
- *Age* is a better metric

# Freshness vs. Age

16



# Age

17

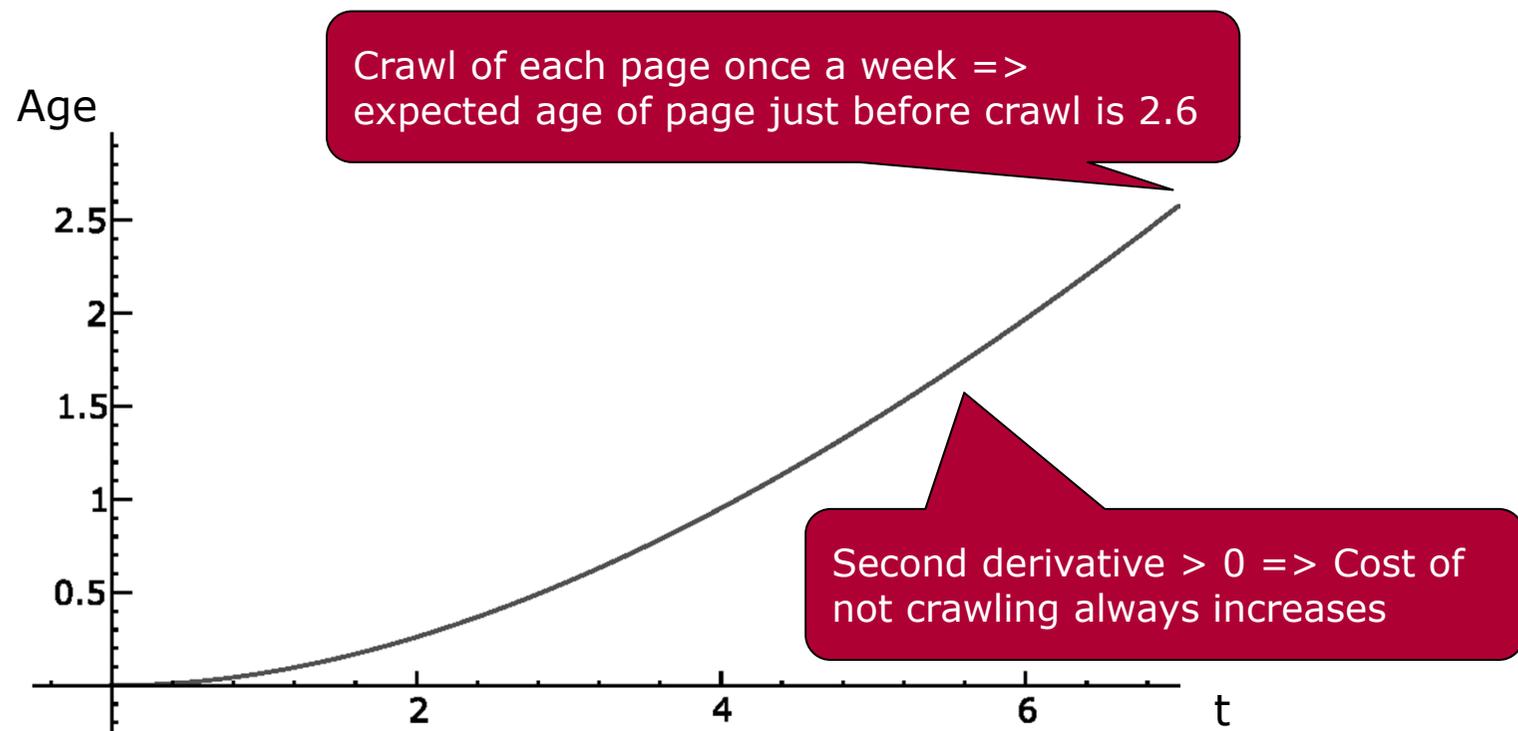
- Expected age of a page,  $t$  days after it was last crawled:

$$\text{Age}(\lambda, t) = \int_0^t P(\text{page changed at time } x)(t - x)dx$$

- where  $\lambda$  is the change frequency per day.
- Page crawled at time  $t$  and changed at time  $x \Rightarrow (t - x)$  is an age
- Web page updates follow the Poisson distribution on average
  - time until the next update is governed by an exponential distribution

$$\text{Age}(\lambda, t) = \int_0^t \lambda e^{-\lambda x} (t - x)dx$$

- Older a page gets, the more it costs not to crawl it
  - e.g., expected age with mean change frequency  $\lambda = 1/7$  (one change per week)



# Focused Crawling

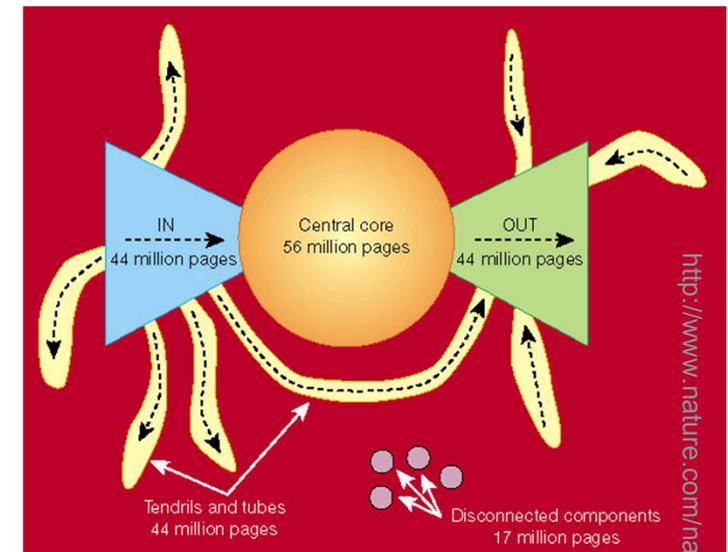
19

- Also: Topical crawling
- Attempts to download only those pages that are about a particular topic
  - Used by *vertical search* applications
- Promise: Higher accuracy
  - User preselects relevance by choosing vertical search engine
  - Index is not cluttered by irrelevant documents
- Rely on the fact that pages about a topic tend to have links to other pages on the same topic
  - Anchor texts help
  - Popular pages for a topic are typically used as seeds
- Crawler uses *text classifier* to decide whether a page is on topic
  - See Chapter 9

# Deep Web

20

- Sites that are difficult for a crawler to find are collectively referred to as the *deep* (or *hidden*) Web
  - much larger than conventional Web
- Three broad categories:
  - Private sites
    - ◇ no incoming links, or may require log in with a valid account
    - ◇ Exception: News sites
  - Form results
    - ◇ Sites that can be reached only after entering some data into a form
    - ◇ Exception: Online stores
  - Scripted pages
    - ◇ Pages that use JavaScript, Flash, or another client-side language to generate links
    - ◇ Possible but difficult for crawler



# Sitemaps

21

- Sitemaps contain lists of URLs and data about those URLs
  - modification time, modification frequency
- Generated by web server administrators
- Tells crawler about pages it might not otherwise find
- Gives crawler a hint about when to check a page for changes

# Sitemap Example

22

```
<?xml version="1.0" encoding="UTF-8"?>
<urlset xmlns="http://www.sitemaps.org/schemas/sitemap/0.9">
  <url>
    <loc>http://www.company.com/</loc>
    <lastmod>2008-01-15</lastmod>
    <changefreq>monthly</changefreq>
    <priority>0.7</priority>
  </url>
  <url>
    <loc>http://www.company.com/items?item=truck</loc>
    <changefreq>weekly</changefreq>
  </url>
  <url>
    <loc>http://www.company.com/items?item=bicycle</loc>
    <changefreq>daily</changefreq>
  </url>
</urlset>
```

Between 0.0 and 1.0 (default 0.5)

always  
hourly  
daily  
weekly  
monthly  
yearly  
never

<https://www.google.com/webmasters/tools/docs/de/protocol.html>

# Distributed Crawling

23

- Three reasons to use multiple computers for crawling
  1. Helps to put the crawler closer to the sites it crawls
    - ◇ Low latency, high throughput
  2. Reduces the number of sites the crawler has to remember
    - ◇ In queue
    - ◇ In index
  3. Reduces computing resources required
    - ◇ Parsing, network bandwidth
- Distributed crawler uses a hash function to assign URLs to crawling computers
  - URLs are sent in batches
  - Hash function should be computed on the host part of each URL
  - Causes imbalance, but
    - ◇ Mostly site-internal links
    - ◇ Abides politeness anyway

# Desktop Crawls

24

- Used for desktop search and enterprise search
- Differences to web crawling:
  - Much easier to find the data
  - Responding quickly to updates is more important
    - ◇ Different expectations than for Web
    - ◇ File systems can send change notifications
  - Many different document formats
    - ◇ → Document conversion
  - Data privacy very important
  - Must be conservative in terms of disk and CPU usage
    - ◇ Copies of documents need not be stored...
    - ◇ GDS?

# Google Desktop Search

25

The screenshot shows the Google Desktop Search interface. At the top, there are navigation links: Web, Bilder, Groups, News, Shopping, Maps, Desktop, and Mehr. A search bar contains the text 'search engines' and a 'Suchen' button. To the right of the search bar are links for 'Desktop-Einstellungen' and 'Erweiterte Suche'. Below the search bar, a header indicates 'Im Cache gespeicherte Versionen' and '1 - 10 von 19 Versionen von SearchEngines\_03\_Crawling.pptx'. The main content area lists ten cached versions of the file, each with a timestamp, the file name, and a 'Verlauf' link.

Web Bilder Groups News Shopping Maps Desktop Mehr »

search engines Suchen Desktop-Einstellungen Erweiterte Suche

**Im Cache gespeicherte Versionen** 1 - 10 von 19 Versionen von [SearchEngines\\_03\\_Crawling.pptx](#)

19 im Cache gespeicherte Versionen von [Y:\Lehre\Sommer09\VL Search Engines\SearchEngines\\_03\\_Crawling.pptx](#):

[29. Apr. 2009 - 21:48](#)  
**Search Engines**Chapter 3 –Crawls &Feeds 30.4.2009 Felix Naumann 1 ..  
 Y:\Lehre\Sommer09\VL **Search Engines**\SearchEngines\_03\_Crawling.pptx 3,5MB - [Verlauf](#)

[29. Apr. 2009 - 21:43](#)  
**Search Engines**Chapter 3 –Crawls &Feeds 30.4.2009 Felix Naumann 1 ..  
 Y:\Lehre\Sommer09\VL **Search Engines**\SearchEngines\_03\_Crawling.pptx 3,5MB - [Verlauf](#)

[29. Apr. 2009 - 21:35](#)  
**Search Engines**Chapter 3 –Crawls &Feeds 30.4.2009 Felix Naumann 1 ..  
 Y:\Lehre\Sommer09\VL **Search Engines**\SearchEngines\_03\_Crawling.pptx 3,4MB - [Verlauf](#)

[29. Apr. 2009 - 21:30](#)  
**Search Engines**Chapter 3 –Crawls &Feeds 30.4.2009 Felix Naumann 1 ..  
 Y:\Lehre\Sommer09\VL **Search Engines**\SearchEngines\_03\_Crawling.pptx 3,4MB - [Verlauf](#)

[29. Apr. 2009 - 21:26](#)  
**Search Engines**Chapter 3 –Crawls &Feeds 30.4.2009 Felix Naumann 1 ..  
 Y:\Lehre\Sommer09\VL **Search Engines**\SearchEngines\_03\_Crawling.pptx 2,9MB - [Verlauf](#)

[29. Apr. 2009 - 21:14](#)  
**Search Engines**Chapter 3 –Crawls &Feeds 30.4.2009 Felix Naumann 1 ..  
 Y:\Lehre\Sommer09\VL **Search Engines**\SearchEngines\_03\_Crawling.pptx 2,1MB - [Verlauf](#)

[29. Apr. 2009 - 21:01](#)  
**Search Engines**Chapter 3 –Crawls &Feeds 30.4.2009 Felix Naumann 1 ..  
 Y:\Lehre\Sommer09\VL **Search Engines**\SearchEngines\_03\_Crawling.pptx 1,9MB - [Verlauf](#)

[29. Apr. 2009 - 20:47](#)  
**Search Engines**Chapter 3 –Crawls &Feeds 30.4.2009 Felix Naumann 1 ..  
 Y:\Lehre\Sommer09\VL **Search Engines**\SearchEngines\_03\_Crawling.pptx 1,9MB - [Verlauf](#)

[29. Apr. 2009 - 20:43](#)  
**Search Engines**Chapter 3 –Crawls &Feeds 30.4.2009 Felix Naumann 1 ..

# Document Feeds

26

- Many documents are *published*
  - Created at a fixed time and rarely updated again
  - e.g., news articles, blog posts, press releases, email
  - In general time-sensitive content
- Published documents from a single source can be ordered in a sequence called a *document feed*
  - New documents found by examining the end of the feed
  - Single place, no crawling necessary
  - using HTTP GET requests to web servers that host them
- Two types:
  - A *push feed* alerts the subscriber to new documents (phone)
    - ◇ Expensive; news agencies (“Ticker”)
  - A *pull feed* requires the subscriber to check periodically for new documents (email)
- Most common format for pull feeds is called *RSS*
  - Really Simple Syndication, RDF Site Summary, Rich Site Summary

## RSS Example

27

```
<?xml version="1.0"?>
<rss version="2.0">
  <channel>
    <title>Search Engine News</title>
    <link>http://www.search-engine-news.org/</link>
    <description>News about search engines.</description>
    <language>en-us</language>
    <pubDate>Tue, 19 Jun 2008 05:17:00 GMT</pubDate>
    <ttml>60</ttml>
  </channel>
  <item>
    <title>Upcoming SIGIR Conference</title>
    <link>http://www.sigir.org/conference</link>
    <description>The annual SIGIR conference is coming!
      Mark your calendars and check for cheap
      flights.</description>
    <pubDate>Tue, 05 Jun 2008 09:50:11 GMT</pubDate>
    <guid>http://search-engine-news.org#500</guid>
  </item>
```

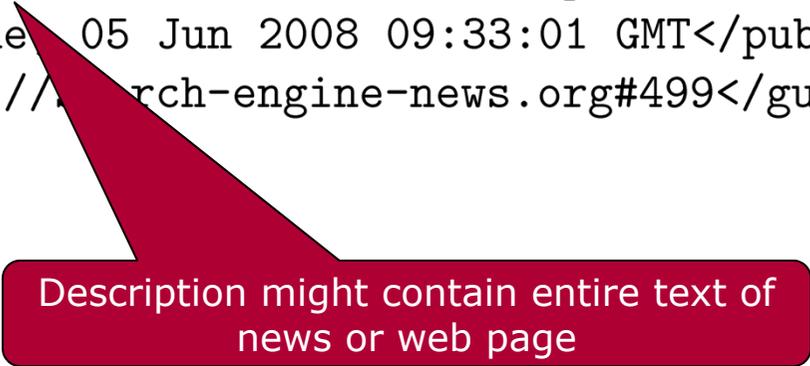


Time to live (minutes)

# RSS Example

28

```
...  
<item>  
  <title>New Search Engine Textbook</title>  
  <link>http://www.cs.umass.edu/search-book</link>  
  <description>A new textbook about search engines  
    will be published soon.</description>  
  <pubDate>Tue 05 Jun 2008 09:33:01 GMT</pubDate>  
  <guid>http://search-engine-news.org#499</guid>  
</item>  
</channel>  
</rss>
```

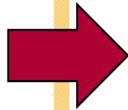


Description might contain entire text of news or web page

# Overview

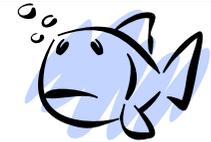
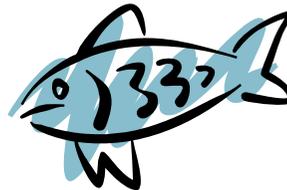
29

- Crawling the Web
- The Deep Web
- Document Conversion
- Document Storage
- Duplicate Detection
- Removing Noise



## Surface web

### Shallow web

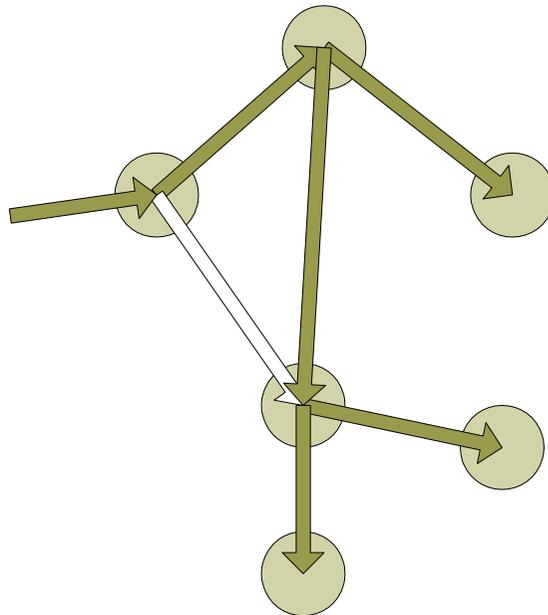


### Deep web

Quelle: [To01]

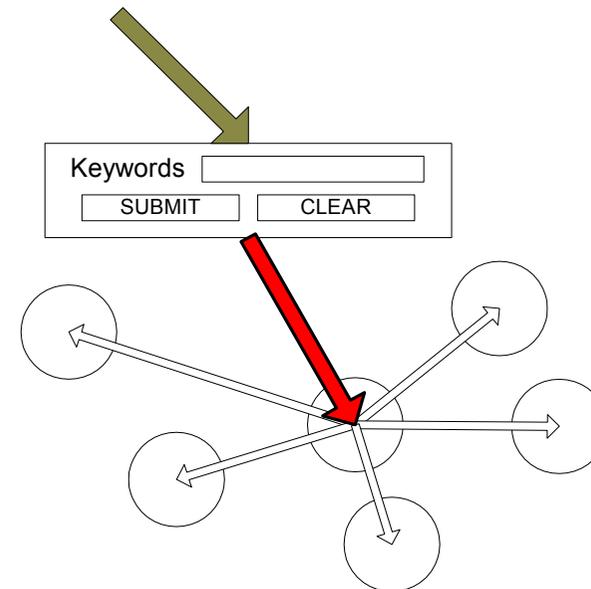
# Surface Web vs. Hidden Web

31



## Surface Web

- Link-Struktur
- Kann *gecrawled* werden
- Dokumente durch Suchmaschinen indiziert
- **Anfragen auf viele Websites gleichzeitig**



## Hidden Web

- Keine Link-Struktur
- Dokumente verborgen in DBMS
- Dokumente nicht durch Internet-Suchmaschinen indiziert
- Dokumente eventl. durch Intranet-Suchmaschinen indiziert
- **Anfragen auf jede Sammlung einzeln**

## Begriffe / Synonyme

32

- Surface Web (Oberflächen-Web)
  - Inhalt für „normale“ Suchmaschinen sichtbar
- Shallow Web (Flaches Web)
  - „Normale“ Web-Seiten, die dynamisch generiert werden
  - Anfragen durch Klicken auf Links
- Hidden Web (verborgenes Web)
  - Inhalt für „normale“ Suchmaschinen unsichtbar
  - Invisible Web (unsichtbares Web)
    - ◇ Synonym mit Hidden web
  - Deep Web (tiefes Web)
    - ◇ nach BrightPlanet,
    - ◇ Synonym mit Hidden Web

Quelle: [To01]

# Hidden Web: Beispiel

33

- Suche in PubMed nach "diabetes"
  - 178,975 Treffer
- Google Suche: "diabetes site:www.ncbi.nlm.nih.gov"
  - nur 119 matches
- Weitere Beispiele:

Database	Query	Matches	Google
PubMed	diabetes	178,975	119
U.S. Patents	wireless network	16,741	0
Library of Congress	visa regulations	>10,000	0
...	...	...	...

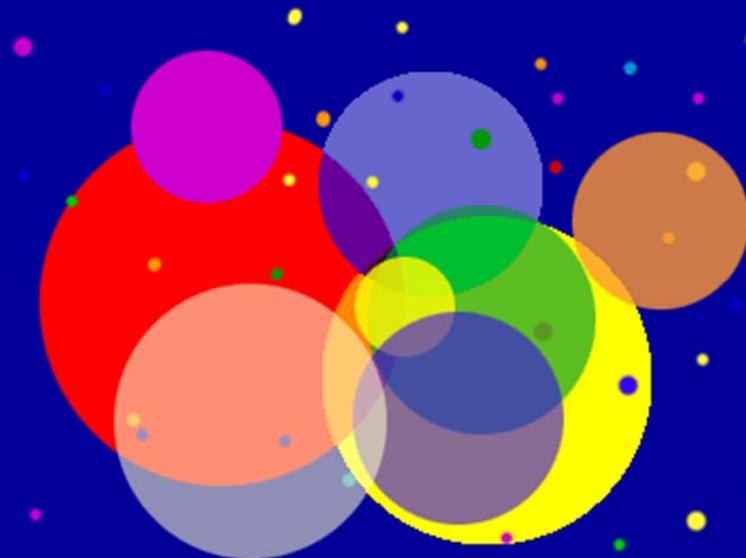
- Gegenbeispiel
  - Amazon: Hilft explizit bei Verlinkung

Quelle: Folie aus [IGS01]

# Invisible/Hidden/Deep Web

34

Deep/Hidden/Invisible Web  
(represented by slide background)

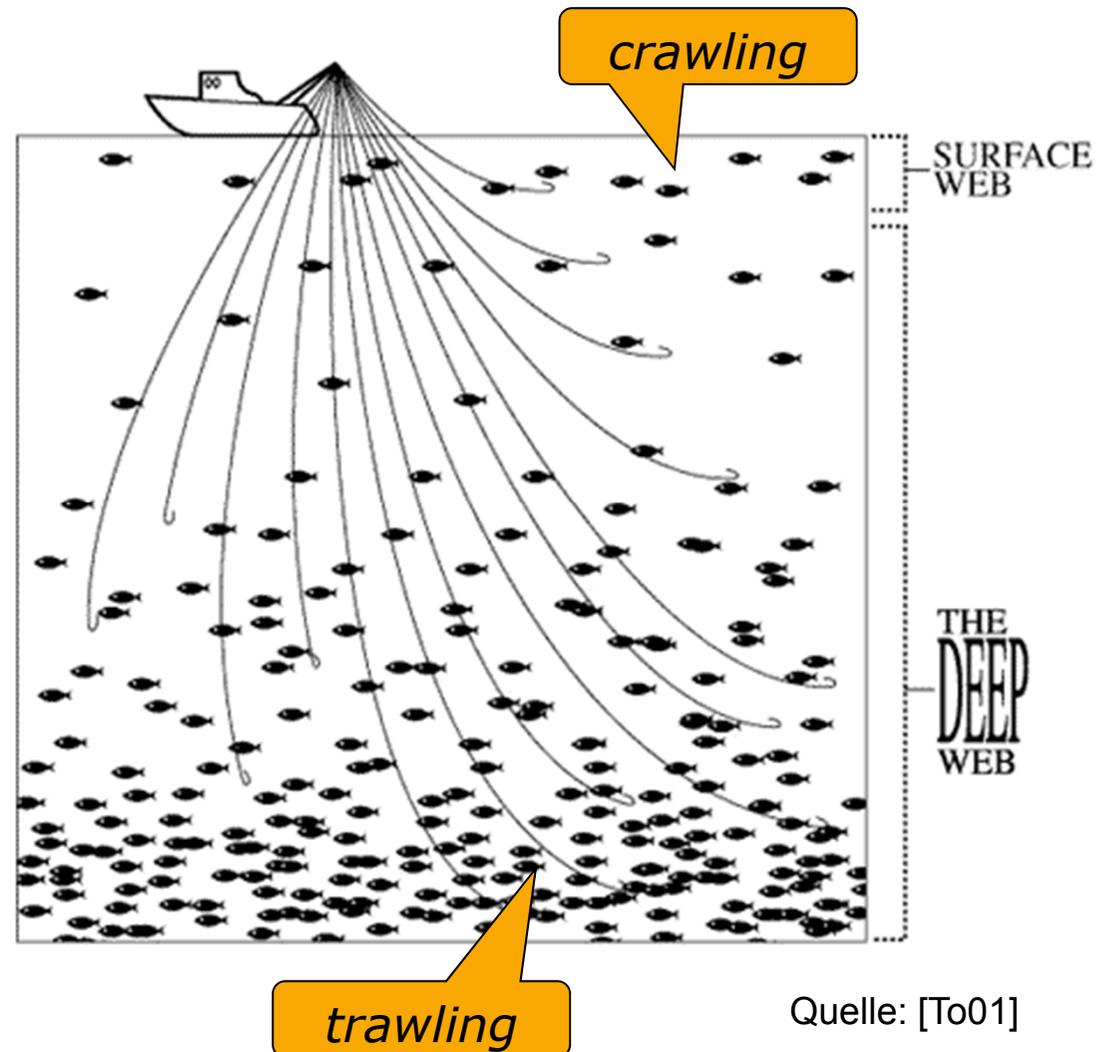


Quelle: [To01]

# Surface vs. Hidden Web [Be01]

35

- "Der Inhalt des Surface Web ist persistent auf statischen Seiten, die mittels crawling von Suchmaschinen entdeckt werden kann. Inhalt des Hidden Web wird dynamisch präsentiert in Antwort auf eine konkrete Anfrage."
- "...der größte Anteil Inhalts des Hidden Web wird unterhalb der Oberfläche bleiben und kann nur im Kontext einer bestimmten Anfrage entdeckt werden."



Quelle: [To01]

# Das Verborgene Web

36

- Der Teil des Webs, der nicht durch Suchmaschinen indiziert wird
  - Oft gespeichert in Datenbanken
  - Dynamisch generierte Web Seiten durch Anwendungen im Server
    - ◇ jsp, cgi, ...
  - Sites und Seiten mit Passwort-geschütztem Inhalt
  - Früher: Inhalt von Dateien, die nicht in Standard-Formaten gespeichert werden
    - ◇ \*.pdf, \*.ppt, \*.doc
    - ◇ Grafikformate

Quelle: [To01]

# Statistiken [Be01]

37

- 400 bis 550 fach größer als Surface Web
  - 7,500 Terabytes Informationen im Hidden Web
  - 19 Terabytes Information im Surface Web
  - 550 Milliarden Dokumente im Hidden Web
  - 1 Milliarde Dokumente im Surface Web
  - je nach dem, was man zählt...
    - ◇ Dynamische Seiten...
- 100,000 Hidden Websites
- ca. 84% sind auf Text-Dokumente spezialisiert
- ca. 95% des Hidden Web ist öffentlich verfügbar.

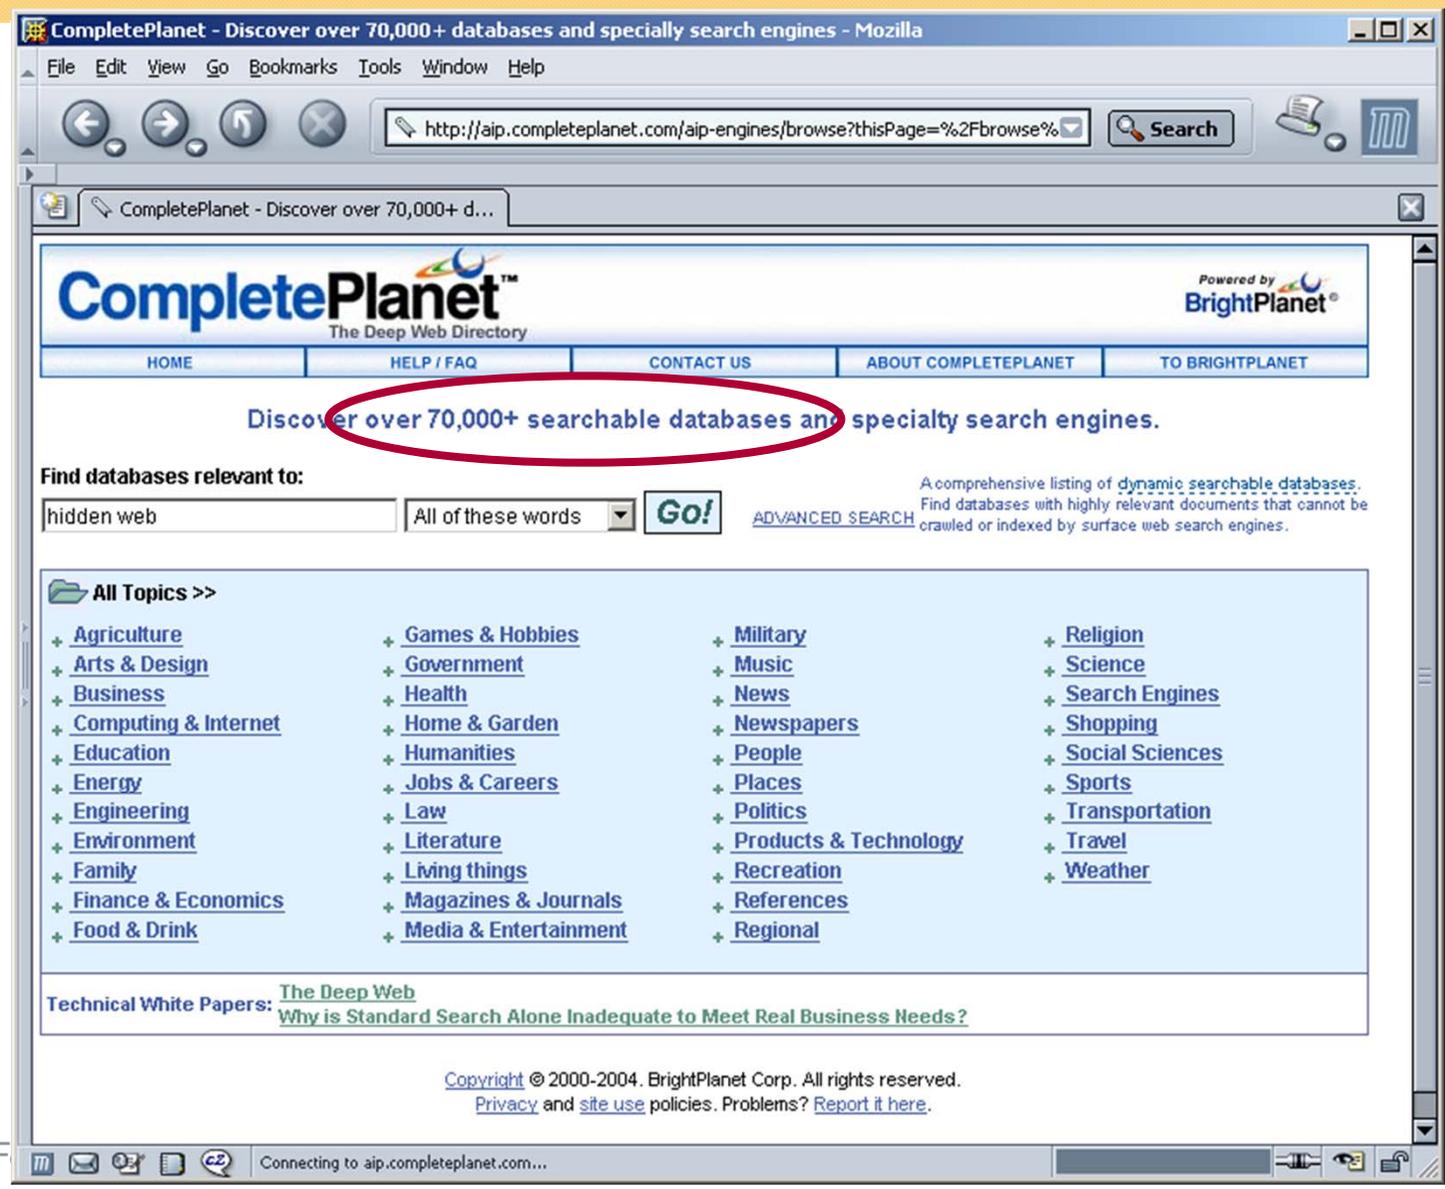
## Eigenschaften [Be01]

38

- Hidden Websites haben thematisch oft „schmaleren“, aber „tieferen“ Inhalt.
- Oft qualitativ bessere Informationen
- Meist relevanter Inhalt
  - Kein Spam
- Über die Hälfte aller Hidden Websites sind thematisch spezialisiert.
- Am schnellsten wachsende Kategorie neuer Informationen im Internet

# Beispiel: CompletePlanet.com

39



# Beispiel: CompletePlanet.com

40

**CompletePlanet™**  
The Deep Web Directory

Powered by **BrightPlanet®**

HOME    HELP / FAQ    CONTACT US    ABOUT COMPLETEPLANET    TO BRIGHTPLANET

Discover over **70,000+** searchable databases and specialty search engines.

Find databases relevant to:

All of these words  [ADVANCED SEARCH](#)

A comprehensive listing of dynamic searchable databases. Find databases with highly relevant documents that cannot be crawled or indexed by surface web search engines.

**All Topics >>**

- + [Agriculture](#)
- + [Arts & Design](#)
- + [Business](#)
- + [Computing & Internet](#)
- + [Education](#)
- + [Energy](#)
- + [Engineering](#)
- + [Environment](#)
- + [Family](#)
- + [Finance & Economics](#)
- + [Food & Drink](#)
- + [Games & Hobbies](#)
- + [Government](#)
- + [Health](#)
- + [Home & Garden](#)
- + [Humanities](#)
- + [Jobs & Careers](#)
- + [Law](#)
- + [Literature](#)
- + [Living things](#)
- + [Magazines & Journals](#)
- + [Media & Entertainment](#)
- + [Military](#)
- + [Music](#)
- + [News](#)
- + [Newspapers](#)
- + [People](#)
- + [Places](#)
- + [Politics](#)
- + [Products & Technology](#)
- + [Recreation](#)
- + [References](#)
- + [Regional](#)
- + [Religion](#)
- + [Science](#)
- + [Search Engines](#)
- + [Shopping](#)
- + [Social Sciences](#)
- + [Sports](#)
- + [Transportation](#)
- + [Travel](#)
- + [Weather](#)

Technical White Papers: [The Deep Web: Why is Standard Search Alone Inadequate to Meet Real Business Needs?](#)

# Beispiel: Search Engine Guide

41

Small Biz Guide to Search Marketing | Advertise | Newsletters | About/Contact | Site Map

Google Custom S



## Search Engine Guide

The small business guide to search marketing.

RSS

Search Engine Marketing | Small Business Conference | Search Marketing Ebook | Internet Search Engines | Search Engine News

Ads by Google 

**Meta Search Engine**  
Free Technical Search Engine Search Thousands of Catalogs Today  
[www.globalspec.com](http://www.globalspec.com)

**Quick URL Submission**  
Blast your URL to hundreds of search engines in a few minutes!  
[www.unlimitedtraffic.ne](http://www.unlimitedtraffic.ne)

**Free demo of new search**  
New search technology. Search with structured suggestions. Free demn

### Search Engines Directory

Internet search engines are categorized by topic in our searchable directory of general and specialty search engines. Also listed are resources and tools for exploring the deep web, performing advanced research, and for learning about using search engine tools and technology.

**Free Search Engine Tool**  
Top the Search Results Pages - Try WordStream's Keyword Tool Free!  
[www.WordStream.com/keyword-search](http://www.WordStream.com/keyword-search)

 Ads by Google

**Browse topical search engines by category.**

**Arts Search Engines**  
[Architecture](#)  
[Artists](#)  
[Crafts](#)  
[Humanities](#)  
[Performing Arts](#)  
[Photography](#)  
[More Arts Search Engines...](#)

**Business Search Engines**  
[Affiliate Search](#)

**Job Search Engines**  
[Attorney Jobs](#)  
[Insurance Jobs](#)  
[Truck Driver Job](#)  
[More Job Search Engines...](#)

**News and Media Search Engines**  
[Magazines](#)  
[Newspapers](#)  
[Radio](#)  
[More News and Media Search Engines...](#)

**Free Search**  
Top the Searc  
WordStream's  
[www.WordStream.c](http://www.WordStream.c)

**Prime Web H**  
Your number i  
Online Web T  
[www.PrimeWebHits](http://www.PrimeWebHits)

**Wordtracke**  
customers g  
more visitors  
their website  
**Find out how**

# Auffinden von Hidden Web Quellen [BC04]

42

- Ziel: Finde Webseiten, die als Einstiegspunkt ins Hidden Web dienen.
  - Seiten mit HTML Formular
- Einschränkungen
  - Textuelle Formulare
    - ◇ mindestens ein Textinput
    - ◇ Gegenbeispiele?
      - Nur radio buttons, menus, checkboxen...
  - Anfrageformulare
    - ◇ Formulare, die Anfragen entgegennehmen und Informationen liefern
    - ◇ Gegenbeispiele?
      - Login Seiten
  - „Hidden Web Formulare“
    - ◇ Keine Seiten mit komplexen Formularen (mehr als ein Inputfeld)
- Aufgabe: Automatisches Finden und Erkennen von Hidden Web Formularen

# Auffinden von Hidden Web Quellen

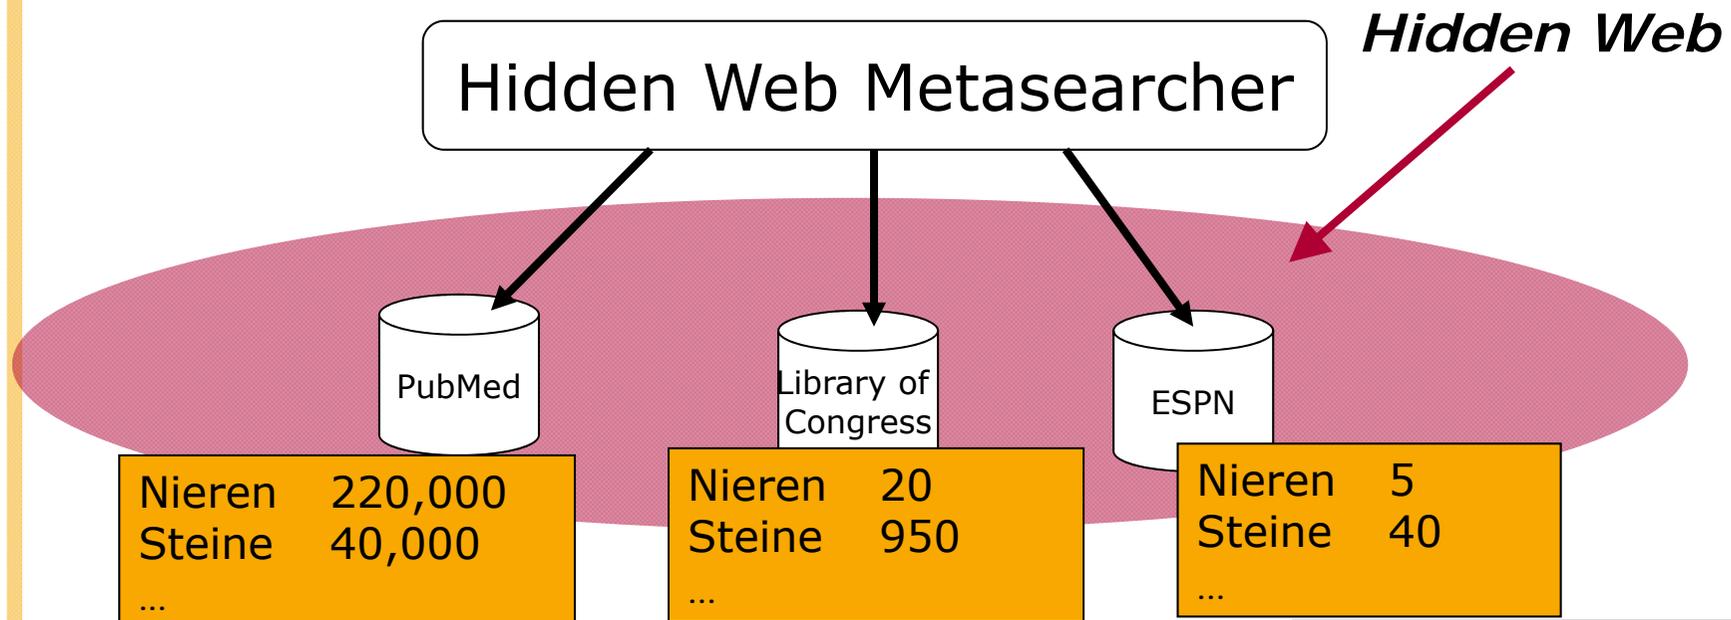
43

- Manuell ☹️
- Automatisches Auffinden von Formularen
  1. Google-Suche (nach Themen)
  2. Lokales *breadth-first* Crawling bis Formular gefunden
    - ◇ Innerhalb einer Site
    - ◇ Bis zu einer festen Tiefe
- Automatisches Erkennen von Hidden Web Formularen (Heuristiken)
  - Testanfragen mit positiven und negativen Suchwörtern
    - ◇ Positiv: „passende“ Worte
    - ◇ Negativ: Fantasieworte
  - Ergebnisse negativer Suchwörter immer gleich groß (Byte)
  - Ergebnisse positiver Suchwörter immer größer als negative
    - ◇ Berechnung der Größe durch „Subtraktion“ von Webseiten (als Baum)

# Suche im Hidden Web – Probleme

44

- Auswahl relevanter Quellen für Anfrage
  - Themen extrahieren
    - ◇ *Content summary*
  - Nach Themen klassifizieren



# Content Summaries

45

- Statistiken, die den Inhalt einer Hidden Web Quelle beschreiben
- Document-cardinality  $dc$ 
  - Anzahl der Dokumente insgesamt
- Document-frequency  $df(w)$ 
  - Pro Wort: Anzahl der Dokumente, die dieses Wort enthalten

KrebsDB	
Document cardinality: 148.944	
Wort	Document frequency
Darm	121.134
Krebs	91.688
...	...

Vorschau zur Verwendung von content summaries

- Anfrage „Darm-Krebs“
- Anzahl Treffer =  $dc * df(\text{Darm})/dc * df(\text{Krebs})/dc = 74569$

# Extraktion von Content Summaries – Probleme

46

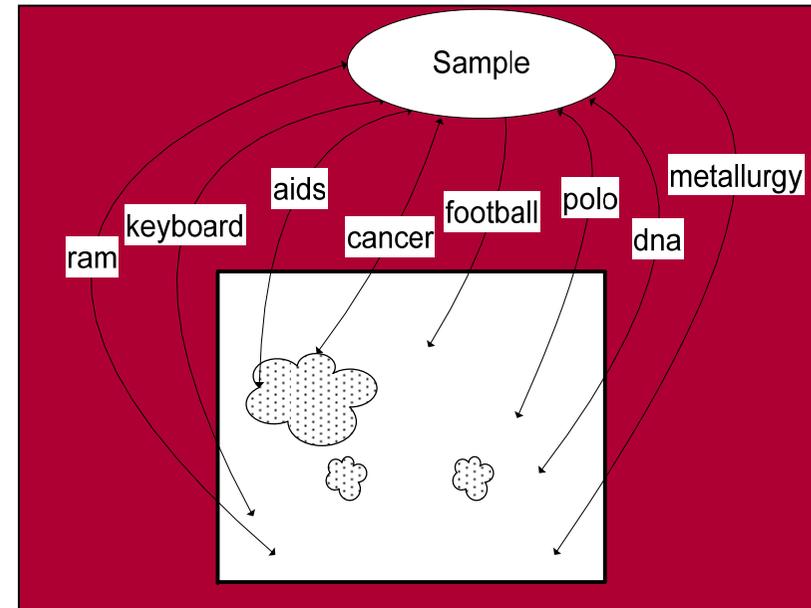
- Kein direkter Zugang zu den Dokumenten ohne konkrete Anfrage
  - Gebundene Variablen
- Deswegen: Anfrage-basiertes Dokument-Sampling:
  1. „Sinnvolle“ Anfragen an Datenbank schicken (*focussed probing*)
    - ◇ Ergebnisliste mit Links
  2. Ergebnisdokumente aus Liste einholen (das „Sample“)
  3. Sample verwenden um *content summary* zu erstellen

Quelle: Folie aus [IGS01]

# “Zufälliges” Anfrage-basiertes Sampling

47

1. Start mit leerem *content summary*
  - Jedes Wort hat  $df(w) = 0$ .
2. Wähle ein Wort und schicke es als Anfrage an Hidden Web Quelle.
3. Wähle top- $k$  Dokumente der Antwort (z.B.  $k=4$ ).
4. Zähle  $df(w)$  für alle  $w$  in Sample um *content summary* zu füllen.
5. Wiederhole bis „genug“ (z.B. 300) Dokumente empfangen wurden



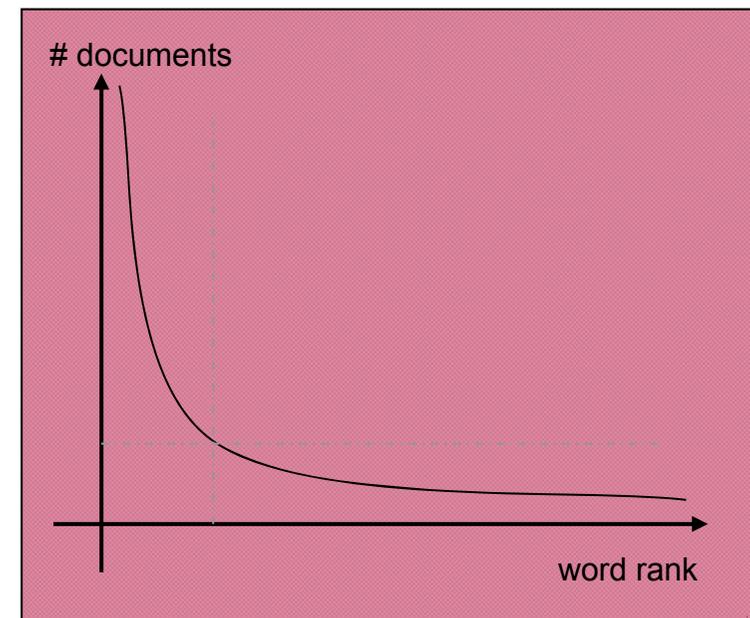
Wort	Häufigkeit in Sample
Krebs	150 (out of 300)
aids	114 (out of 300)
Herz	98 (out of 300)
...	
Basketball	2 (out of 300)

Quelle: Folie aus [IGS01]

# Zufälliges Sampling – Probleme

48

- $df(w)$  zwischen 1 und Anzahl der Dokumente
- Es wird nicht Document-frequency ermittelt, sondern Sample-frequency.
  - Absolute Zahlen sind nicht aussagekräftig.
  - Große Quellen haben ähnliche *content summary* wie kleine Quellen.
  - Zahlen sind nur relativ zu interpretieren (als ranking).
- Viele Anfragen ohne oder nur mit kleinem Ergebnis (Zipf's law)
- Viele, seltene Worte fehlen in der *content summary*.



Zipf's law

Deshalb jetzt verbesserte Lösung

Quelle: Folie aus [IGS01]

# Zufälliges Sampling – Verbesserung

49

## Algorithmus: Überblick

1. Trainiere Dokument-Klassifikatoren
  - Finde repräsentative Wörter für jede Kategorie.
2. Verwende Klassifikationsregeln um ein themenspezifisches Sample aus Quelle zu erhalten.
3. Schätze  $df(w)$  aller entdeckten Wörter.

Quelle: Folie aus [IGS01]

# Fokussiertes Sampling: Trainingsphase

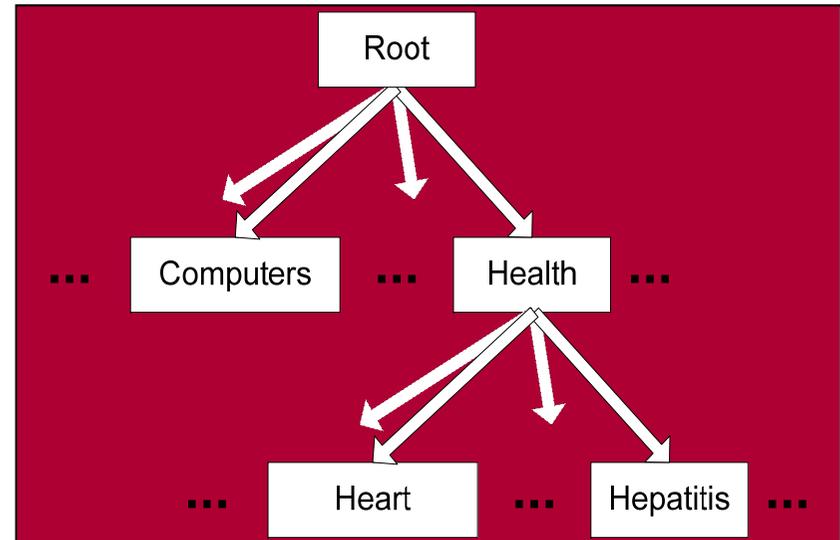
50

- Start mit vordefinierter Themen-Hierarchie und bereits klassifizierten Dokumenten
  - Bsp: Yahoo, dmoz Open Directory, Google ...
- Trainiere Dokument-Klassifikatoren für jeden Knoten der Hierarchie.
  - Mittels der bekannten Dokumente
- Extrahiere automatisch Regeln aus den Klassifikatoren:

- ibm AND computers → Computers
- lung AND cancer → Health
- ...
- angina → Heart
- hepatitis AND liver → Hepatitis
- ...

} Root

} Health

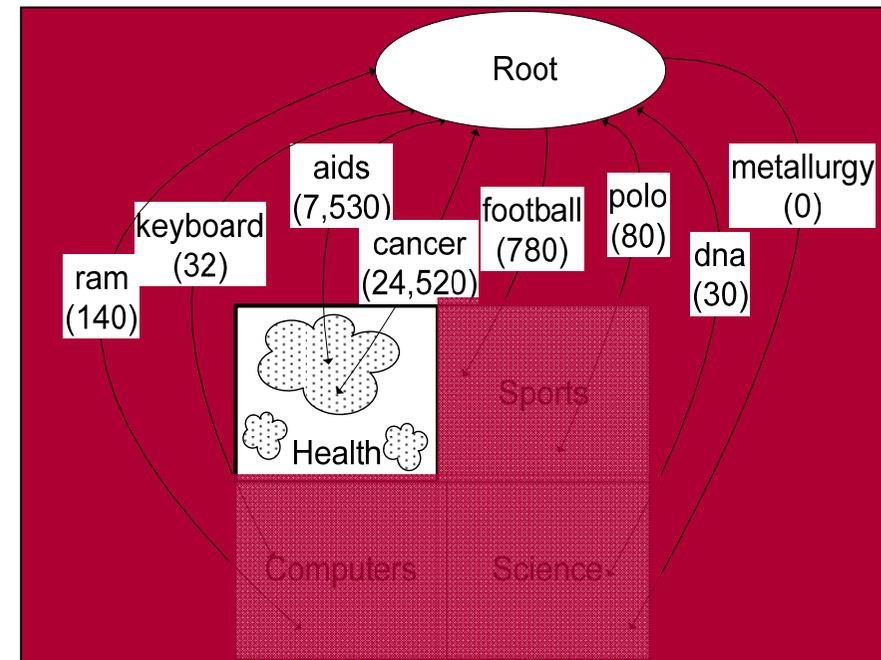


Quelle: Folie aus [IGS01]

# Fokussiertes Sampling

51

- Transformiere jede Regel in eine Boolesche Anfrage.
- Für jede Anfrage:
  - Schicke Anfrage an Quelle
  - Merke Anzahl der Ergebnisse
    - ◇ Parsing
  - Hole top-*k* Dokumente ein.
- Am Ende einer Runde:
  - Analysiere Ergebnisse für jede Kategorie (zählen).
  - Wähle Kategorie zum fokussieren in nächster Runde.

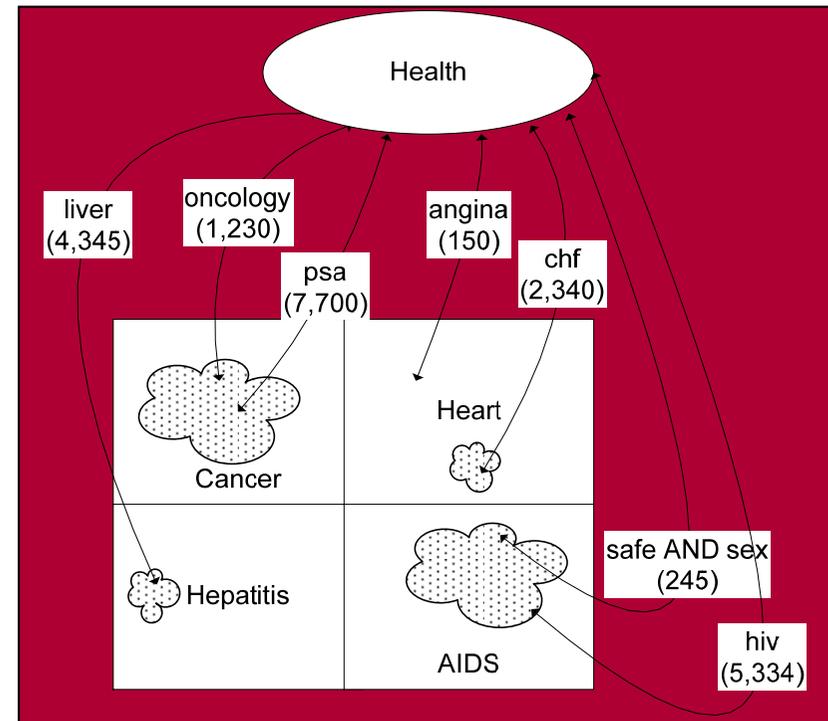


Quelle: Folie aus [IGS01]

# Fokussiertes Sampling

52

- Fokus nun auf Subkategorie
- Neue Regelmenge, deshalb neue Anfragemenge
- Vorteile
  - Weniger Anfragen
  - Fokussierte Anfragen



Quelle: Folie aus [IGS01]

**GetContentSummary(Category  $C$ , Database  $D$ )**

$\alpha$ :  $\langle SampleDF, ActualDF, Classif \rangle = \langle \emptyset, \emptyset, \emptyset \rangle$

if  $C$  is a leaf node

then return  $\langle SampleDF, ActualDF, \{C\} \rangle$

Probe database  $D$  with the query probes derived from the classifier for the subcategories of  $C$

$newdocs = \emptyset$

foreach query probe  $q$

$newdocs = newdocs \cup$   
 $\{top-k \text{ documents returned for } q\}$

$\beta$ : if  $q$  consists of a single word  $w$

then  $ActualDF(w) = \# \text{matches returned for } q$

foreach word  $w$  in  $newdocs$

$SampleDF(w) = \# \text{documents in } newdocs$   
that contain  $w$

Calculate *Coverage* and *Specificity*

from the number of matches for the probes

foreach subcategory  $C_i$  of  $C$

if ( $Specificity(C_i) > \tau_s$  AND  $Coverage(C_i) > \tau_c$ )

then

$\langle SampleDF', ActualDF', Classif' \rangle =$   
 $GetContentSummary(C_i, D)$

$\gamma$ : Merge  $\langle SampleDF', ActualDF' \rangle$   
into  $\langle SampleDF, ActualDF \rangle$

$Classif = Classif \cup Classif'$

return  $\langle SampleDF, ActualDF, Classif \rangle$

Aufruf für jede Kategorie und Subkategorie

Anfragen entsprechend der Regeln des Klassifikators

Sammele Dokumente ein

Bei Ein-Wort Anfragen erlernen wir die tatsächliche  $df(w)$

Zähle sample-frequency für jedes Wort

Maße zur Berechnung des Grades der Zugehörigkeit zu einer Kategorie

Falls hinreichend zu einer Subkategorie zugehörig

Wiederhole für Subkategorie

Vereinige gesammelte Metadaten

Quelle: [IG02]

# Sample-frequency vs. Document-frequency

54

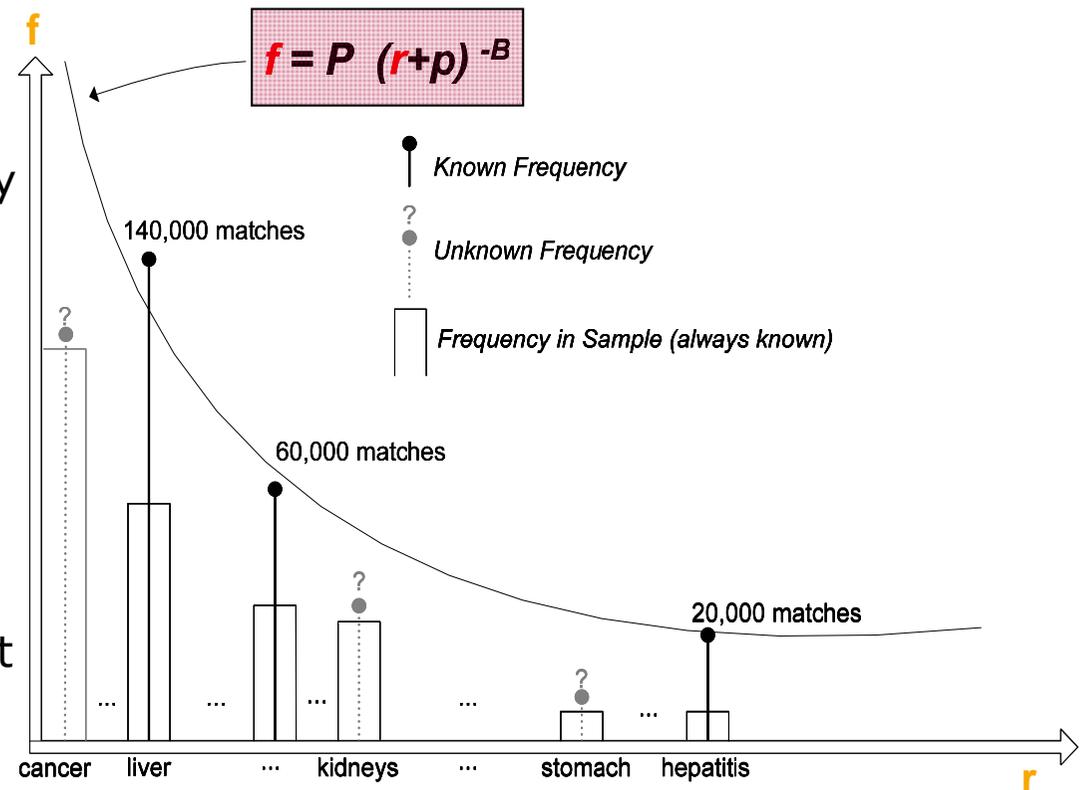
- Motivation:
  - Sample-frequencies sind nur relativ.
  - Quelle mit ähnlichem Inhalt aber unterschiedlicher Größe haben gleiche content summary.
- Sample Frequencies
  - "Leber" erscheint in 200 von 300 Dokumenten im Sample.
  - "Niere" erscheint in 100 von 300 Dokumenten im Sample.
  - "Hepatitis" erscheint in 30 von 300 Dokumenten im Sample.
- Document-frequencies
  - Anfrage "Leber" ergibt 140,000 Matches.
  - Anfrage "Hepatitis" ergibt 20,000 Matches.
  - "Niere": keine Ahnung - war kein Trainingswort...
  - "Darm" und "Krebs" waren zwar Trainingsworte, aber nur gemeinsam.

Zur Abschätzung der (besseren) Document-frequencies werden Infos der Ein-Wort Anfragen verwendet.

# Abschätzen der Document-frequencies

55

- Bekannt aus Algorithmus
  - Ranking  $r$  der Worte nach Sample-frequencies
  - Document-frequency  $f$  der Worte aus Ein-Wort Anfragen
- Mandelbrot's Formel verfeinert Zipfs Formel:
  - $f = P (r+p)^{-B}$
  - $P, p$  und  $B$  sind Parameter der Quelle
  - Niedriger *rank* ergibt hohe *frequency*
- Dann: Kurvenanpassung
  - z.B.:  $P = 8 \cdot 10^5, p = .25, B = 1.15$



[http://www.math.yale.edu/mandelbrot/web\\_pdfs/9\\_E7rankSizePlots.pdf](http://www.math.yale.edu/mandelbrot/web_pdfs/9_E7rankSizePlots.pdf)

Quelle: Folie aus [IGS01]

# Abschätzen der Document-frequencies

56

- Algorithmus also
  1. Sortiere Wörter absteigend nach Sample-frequency
  2. Ermittle  $P$ ,  $p$  und  $B$  durch Fokus auf Wörter mit bekannter Document-frequency. (Kurvenanpassung)
  3. Berechne  $df(w_i) = P (r_i + p)^{-B}$  für alle anderen Wörter.

Quelle: Folie aus [IGS01]

# Vorteile des Fokussierten Sampling

57

- Wenige Anfragen (Fokus auf Thema)
- Vielversprechende Anfragen
- Klassifikation „*along the way*“
  - Nützlich für Auswahl relevanter Quellen
- Schätzung Document-frequency statt nur Sample-frequency.

Quelle: Folie aus [IGS01]

# Overview

58

- Crawling the Web
- The Deep Web
- Document Conversion
- Document Storage
- Duplicate Detection
- Removing Noise



# Conversion

59

- Text is stored in hundreds of incompatible file formats
  - Raw text, RTF, HTML, XML, Microsoft Word, ODF, PDF
- Other types of files also important
  - PowerPoint, Excel
  - Old, obsolete file formats
- Typically use a conversion tool
  - Converts the document content into a tagged text format
    - ◇ such as HTML or XML
    - ◇ => Readable in browser
    - ◇ => Retains some of the important formatting information
  - But often barely readable

# These slides as seen by GDS

60

Dies ist eine Version von [Y:\Lehre\Sommer09\VL\\_SearchEngines\SearchEngines\\_03\\_Crawling.pptx](#) von Ihrem persönlichen [Cache](#). Die Datei hat sich eventuell seit dieser Zeit geändert. Klicken Sie hier, um die [aktuelle Datei](#) anzuzeigen.  
Da diese Datei in Ihrem Computer gespeichert ist, funktionieren keine öffentlichen Links auf diese Datei.

Google steht unter Umständen nicht in Verbindung mit den Autoren dieser Seite und ist nicht verantwortlich für den Inhalt dieser Seite. Diese Seite ist eventuell urheberrechtlich geschützt.

## Search Engines

Chapter 3 – Crawls & Feeds

30.4.2009

Felix Naumann

1

What to crawl

Every document answers at least one question:

„Now where was that document again?“

Poor quality documents

Swamp index

Slow down query answering

But

Have at least some value

Have not hindered success of commercial search engines

Thus: Crawl everything

More important:

Keep documents up to date

Keep archive of older material

Felix Naumann | Search Engines | SoSe 2009

2

2

Overview

Classification of Web

Felix Naumann | Search Engines | Summer 2009

58

Conversion

Text is stored in hundreds of incompatible file formats

e.g., raw text, RTF, HTML, XML, Microsoft Word, ODF, PDF

Other types of files also important

e.g., PowerPoint, Excel

Typically use a conversion tool

converts the document content into a tagged text format such as HTML or XML

retains some of the important formatting information

Felix Naumann | Search Engines | SoSe 2009

59

59

Character Encoding

A character encoding is a mapping between bits and glyphs

i.e., getting from bits in a file to characters on a screen

Can be a major source of incompatibility

ASCII is basic character encoding scheme for English

encodes 128 letters, numbers, special characters, and control characters in 7 bits,

extended with an extra bit for storage in bytes

Felix Naumann | Search Engines | SoSe 2009

60

60

Character Encoding

Other languages can have many more glyphs

e.g., Chinese has more than 40,000 characters, with over 3,000 in common use

Many languages have multiple encoding schemes

e.g., CJK (Chinese-Japanese-Korean) family of East Asian languages, Hindi, Arabic

must specify encoding

can't have multiple languages in one file

Unicode developed to address encoding problems

Felix Naumann | Search Engines | SoSe 2009

61

# Character Encoding

61

- A character encoding is a mapping between bits and glyphs
  - i.e., getting from bits in a file to characters on a screen
  - Can be a major source of incompatibility
- ASCII is basic character encoding scheme for English
  - encodes 128 letters, numbers, special characters, and control characters in 7 bits, extended with an extra bit for storage in bytes
- Other languages can have many more glyphs
  - e.g., Chinese has more than 40,000 characters, with over 3,000 in common use
- Many languages have multiple encoding schemes
  - e.g., CJK (Chinese-Japanese-Korean) family of East Asian languages, Hindi, Arabic
  - Must specify encoding (“code pages”)
  - Can’t have multiple languages in one file
- Unicode developed to address encoding problems

- American Standard Code for Information Interchange

Code	...0	...1	...2	...3	...4	...5	...6	...7	...8	...9	...A	...B	...C	...D	...E	...F
0...	NUL	SOH	STX	ETX	EOT	ENQ	ACK	BEL	BS	HT	LF	VT	FF	CR	SO	SI
1...	DLE	DC1	DC2	DC3	DC4	NAK	SYN	ETB	CAN	EM	SUB	ESC	FS	GS	RS	US
2...	SP	!	"	#	\$	%	&	'	(	)	*	+	,	-	.	/
3...	0	1	2	3	4	5	6	7	8	9	:	;	<	=	>	?
4...	@	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
5...	P	Q	R	S	T	U	V	W	X	Y	Z	[	\	]	^	_
6...	`	a	b	c	d	e	f	g	h	i	j	k	l	m	n	o
7...	p	q	r	s	t	u	v	w	x	y	z	{		}	~	DEL

[http://de.wikipedia.org/wiki/American\\_Standard\\_Code\\_for\\_Information\\_Interchange](http://de.wikipedia.org/wiki/American_Standard_Code_for_Information_Interchange)

# Unicode

63

- Single mapping from numbers to glyphs that attempts to include all glyphs in common use in all known languages
- Unicode is a mapping between numbers and glyphs
  - Does not uniquely specify bits to glyph mapping!
  - e.g., UTF-8, UTF-16, UTF-32
- Proliferation of encodings comes from a need for compatibility and to save space
  - UTF-8 uses one byte for English (ASCII), as many as 4 bytes for some traditional Chinese characters
  - variable length encoding, more difficult to do string operations
  - UTF-32 uses 4 bytes for every character
- Many applications use UTF-32 for internal text encoding (fast random lookup) and UTF-8 for disk storage (less space)

# Unicode

64

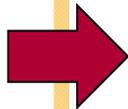
Decimal	Hexadecimal	Encoding			
0–127	0–7F	0xxxxxxx			
128–2047	80–7FF	110xxxxx	10xxxxxx		
2048–55295	800–D7FF	1110xxxx	10xxxxxx	10xxxxxx	
55296–57343	D800–DFFF	Undefined			
57344–65535	E000–FFFF	1110xxxx	10xxxxxx	10xxxxxx	
65536–1114111	10000–10FFFF	11110xxx	10xxxxxx	10xxxxxx	10xxxxxx

- e.g., Greek letter pi ( $\pi$ ) is Unicode symbol number 960
- In binary, 00000011 11000000 (3C0 in hexadecimal)
- Final encoding is **11001111 10000000** (CF80 in hexadecimal)

# Overview

65

- Crawling the Web
- The Deep Web
- Document Conversion
- Document Storage
- Duplicate Detection
- Removing Noise



# Storing the Documents

66

- Many reasons to store converted document text
  - Saves crawling time when page is not updated
    - ◇ When index needs to be re-generated
    - ◇ Compare with HEAD response
  - Provides efficient access to text for
    - ◇ Snippet generation
    - ◇ Information extraction
    - ◇ etc.
- Disadvantages
  - Storage space
  - Longer crawl-time
- Database systems can provide document storage for some applications. But:
  - Too large volume, specialized on small data items
  - Too expensive disks
  - => Web search engines use customized document storage systems

# Storing the Documents

67

- Requirements for document storage system:
  - Random access
    - ◇ But only simple lookups: Request the content of a document based on its URL
    - ◇ Hash function based on URL is typical
      - Hash-number identifies file and/or server
    - ◇ Then: Secondary index to locate page in file.
  - Compression and large files
    - ◇ reducing storage requirements and efficient access
  - Update
    - ◇ handling large volumes of new and modified documents
    - ◇ adding new anchor text

# Large Files

68

- Store many documents in large files, rather than each document in a file
  - Avoids overhead in opening and closing files
  - Reduces seek time relative to read time
    - ◇ Seektime 10ms
    - ◇ Readtime 70kB/ms
- Compound document formats
  - Used to store multiple documents in a file
  - e.g., TREC Web

# TREC Web Format

69

```
<DOC>
<DOCNO>WTX001-B01-10</DOCNO>
<DOCHDR>
http://www.example.com/test.html 204.244.59.33 19970101013145 text/html 440
HTTP/1.0 200 OK
Date: Wed, 01 Jan 1997 01:21:13 GMT
Server: Apache/1.0.3
Content-type: text/html
Content-length: 270
Last-modified: Mon, 25 Nov 1996 05:31:24 GMT
</DOCHDR>
<HTML>
<TITLE>Tropical Fish Store</TITLE>
Coming soon!
</HTML>
</DOC>
<DOC>
<DOCNO>WTX001-B01-109</DOCNO>
<DOCHDR>
http://www.example.com/fish.html 204.244.59.33 19970101013149 text/html 440
HTTP/1.0 200 OK
Date: Wed, 01 Jan 1997 01:21:19 GMT
Server: Apache/1.0.3
Content-type: text/html
Content-length: 270
Last-modified: Mon, 25 Nov 1996 05:31:24 GMT
</DOCHDR>
<HTML>
<TITLE>Fish Information</TITLE>
This page will soon contain interesting
information about tropical fish.
</HTML>
</DOC>
```

# Compression

70

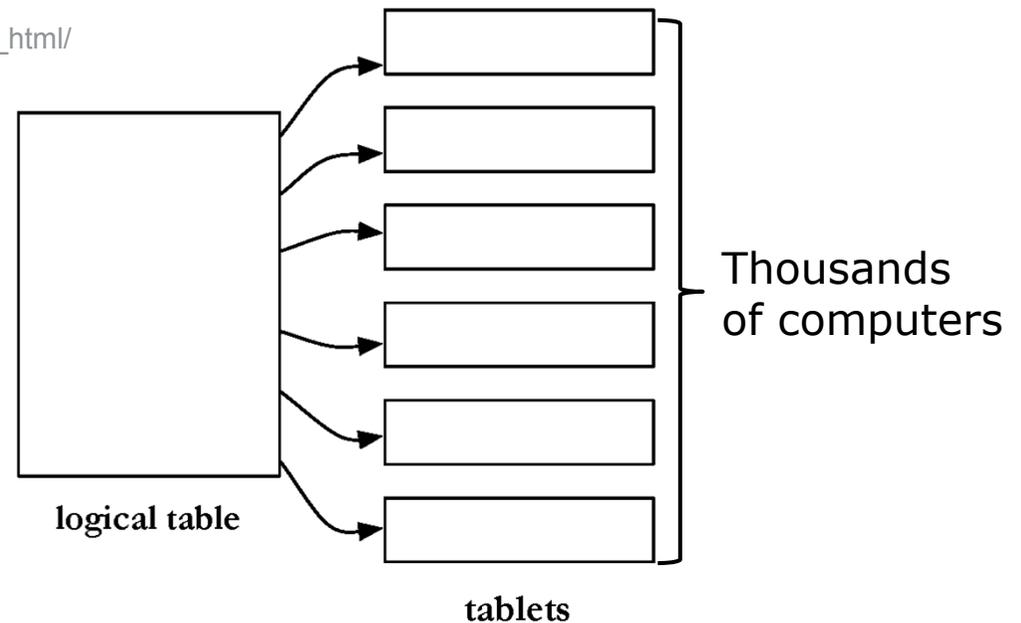
- Text is highly redundant (or predictable)
  - Entropy: Native English speakers guess next letter with 69% accuracy (Shannon 1951: [http://www.princeton.edu/~wbialek/rome/refs/shannon\\_51.pdf](http://www.princeton.edu/~wbialek/rome/refs/shannon_51.pdf))
- Compression techniques exploit this redundancy to make files smaller without losing any of the content.
  - Less disk space
  - Faster read time
- Compression of indexes covered later
- Popular algorithms can compress HTML and XML text by 80%
  - e.g., DEFLATE (zip, gzip) and LZW (UNIX compress, PDF)
  - No random access => May compress large files in blocks to make access faster

# BigTable

71

- Google's document storage system
  - Customized for storing, finding, and updating web pages
  - Handles large collection sizes using inexpensive computers
  - Big = Petabytes, but only single table
- „Bigtable: A Distributed Storage System for Structured Data“
  - Fay Chang, Jeffrey Dean, Sanjay Ghemawat, Wilson C. Hsieh, Deborah A. Wallach  
Mike Burrows, Tushar Chandra, Andrew Fikes, Robert E. Gruber

[http://www.usenix.org/events/osdi06/tech/chang/chang\\_html/](http://www.usenix.org/events/osdi06/tech/chang/chang_html/)



# BigTable

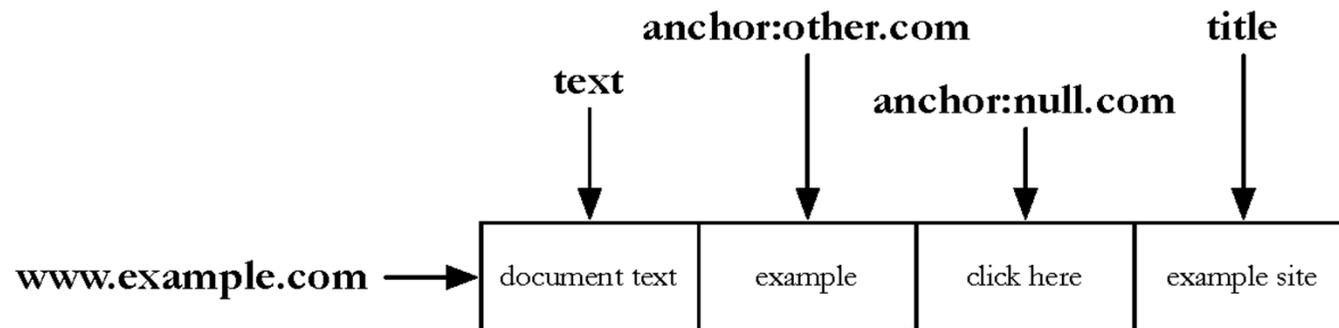
72

- No query language
  - => no complex queries to optimize
- Only row-level transactions
  - => No complex locking mechanisms
- Tablets are stored in a replicated file system that is accessible by all BigTable servers
- Any changes to a BigTable tablet are recorded to a transaction log, which is also stored in a shared file system
- Data in immutable files
  - Data in file is never changed – cannot be corrupt, only incomplete
- If any tablet server crashes, another server can immediately read the tablet data and transaction log from the file system and take over.
- Table updates in RAM
  - Periodic merge with disk files

# BigTable

73

- Logically organized into rows
- A row stores data for a single web page
- Many attribute-value pairs



- Combination of a row key, a column key, and a timestamp point to a single *cell* in the row
  - Timestamp: Extra dimension for versioning

# BigTable

74

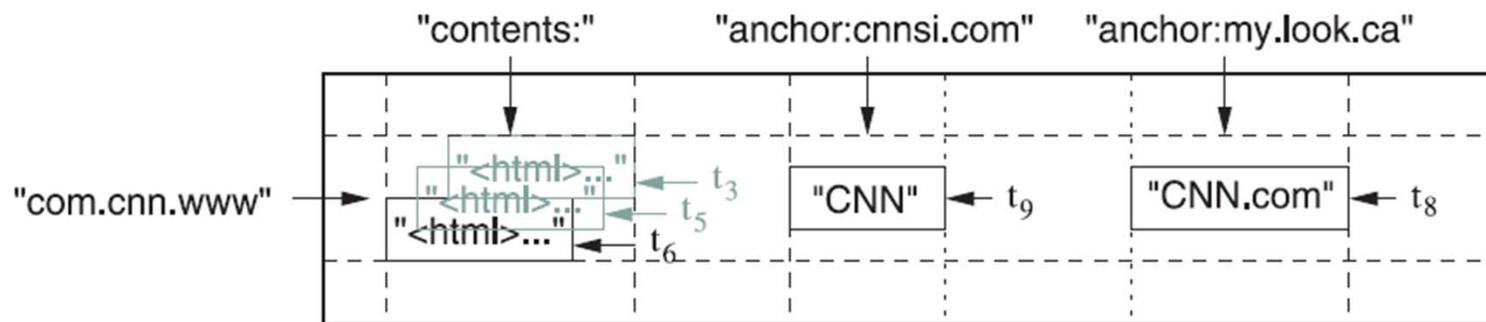


Fig. 1. A slice of an example table that stores Web pages. The row name is a reversed URL. The contents column family contains the page contents, and the anchor column family contains the text of any anchors that reference the page. CNN's home page is referenced by both the Sports Illustrated and the MY-look home pages, so the row contains columns named anchor:cnnsi.com and anchor:my.look.ca. Each anchor cell has one version; the contents column has three versions, at timestamps  $t_3$ ,  $t_5$ , and  $t_6$ .

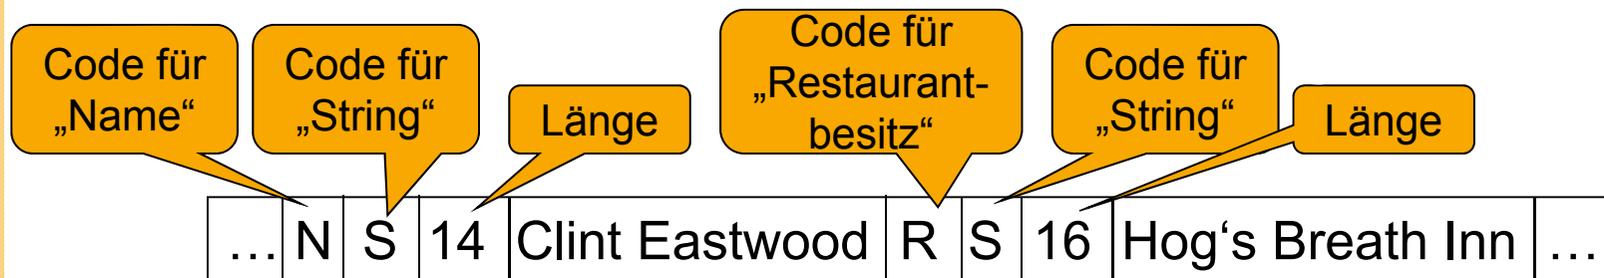
- BigTable can have a huge number of columns per row
  - All rows have the same column families
    - ◇ Families: Columns of same type
    - ◇ Not too many families, all known in advance
  - Not all rows have the same columns
  - Important for reducing disk reads to access document data
- Rows are partitioned into tablets based on their row keys (i.e., URLs)
  - Simplifies determining which server is appropriate

# From DBS II

## Datensätze variabler Länge

76

- Es ist unbekannt welche und wieviele Felder der Datensatz haben wird.
- *Tagged fields* (getaggte Felder)
  - Feldname (Attributname)
  - Feldtyp
  - Feldlänge
  - Feldwert
- Nützlich bei
  - Informationsintegration: Es ist noch unbekannt welche Felder von Quellen hinzukommen.
  - Dünn besetzte Datensätze: Tausende Attribute, nur wenige haben Werte



# Overview

77

- Crawling the Web
- The Deep Web
- Document Conversion
- Document Storage
- Duplicate Detection
- Removing Noise



# Detecting Duplicates

78

- Duplicate and near-duplicate documents occur in many situations
  - Multiple links point to same page
  - Copies, versions, plagiarism, spam, mirror sites
  - 30% of the web pages in a large crawl are exact or near duplicates of pages in the other 70%.
    - ◇ Fetterly et al. 2003 (<http://portal.acm.org/citation.cfm?doid=775152.775246>)
- Duplicates consume significant resources during crawling, indexing, and search.
  - Little value to most users

# Duplicate Detection

79

- *Exact* duplicate detection is relatively easy
  - *Checksum* techniques
    - A checksum is a value that is computed based on the content of the document
      - ◇ e.g., sum of the bytes in the document file
- |    |    |    |    |    |    |    |    |    |    |    |    |    |            |
|----|----|----|----|----|----|----|----|----|----|----|----|----|------------|
| T  | r  | o  | p  | i  | c  | a  | l  |    | f  | i  | s  | h  | <i>Sum</i> |
| 54 | 72 | 6F | 70 | 69 | 63 | 61 | 6C | 20 | 66 | 69 | 73 | 68 | 508        |
- Possible for files with different text to have same checksum
  - Functions such as a *cyclic redundancy check* (CRC), have been developed that consider the positions of the bytes
    - Otherwise “acfhiiloprs T” would be duplicate

# Near-Duplicate Detection

80

- More challenging task
  - Are web pages with same text context but different advertising or format near-duplicates?
  - Do small revisions or updates constitute a new page?
- A near-duplicate document is defined using a threshold value for some similarity measure between pairs of documents
  - e.g., document *D1* is a near-duplicate of document *D2* if more than 90% of the words in the documents are the same

# Near-Duplicate Detection

81

- *Search:*
  - Find near-duplicates of a document  $D$
  - $O(n)$  comparisons required
- *Discovery:*
  - Find all pairs of near-duplicate documents in the collection
  - $O(n^2)$  comparisons
    - ◇ Really?
- IR techniques are effective for search scenario
  - Similarity based on words
  - Too computationally complex
- For discovery, other techniques used to generate compact representations: Fingerprints

# Fingerprints (shingling)

82

1. The document is *parsed* into words.
  - Non-word content, such as punctuation, HTML tags, and additional whitespace, is removed
2. The words are *grouped* into contiguous  $n$ -grams, for some  $n$ .
  - Usually overlapping sequences of words, although some techniques use non-overlapping sequences.
3. Some of the  $n$ -grams are *selected* to represent the document.
  - Distinguishing feature of different algorithms
4. The selected  $n$ -grams are *hashed* to improve retrieval efficiency and further reduce the size of the representation.
5. The hash values are *stored*, typically in an inverted index.
6. Documents are *compared* using overlap of fingerprints
  - Absolute number of shared  $n$ -grams
  - Relative number of shared  $n$ -grams (Jacard distance)

# Fingerprint Example

83

- Example text
  - *Tropical fish include fish found in tropical environments around the world, including both freshwater and salt water species.*
- 3-grams
  - tropical fish include, fish include fish, include fish found, fish found in, found in tropical, in tropical environments, tropical environments around, environments around the, around the world, the world including, world including both, including both freshwater, both freshwater and, freshwater and salt, and salt water, salt water species
- Hash values (hypothetical)
  - 938 664 463 822 492 798 78 969 143 236 913 908  
694 553 870 779
- 3-gram selection: 0 mod 4 (hash values whose mod 4 value is 0)
  - 664 492 236 908

# Simhash

84

- Similarity comparisons using word-based representations more effective at finding near-duplicates
  - Problem is efficiency
- Simhash combines the advantages of the word-based similarity measures with the efficiency of fingerprints based on hashing
  - Similar documents have similar hash values!
- Property of simhash: Similarity of two pages as measured by the cosine correlation measure is proportional to the number of bits that are the same in the simhash fingerprints.

# Simhash

85

1. Process the document into a set of features with associated weights.
  - Assume simple case: Features are words weighted by their frequency
2. Generate a hash value with  $b$  bits (the desired size of the fingerprint) for each word.
  - The hash value should be unique for each word.
  - $b$  typically several hundred
3. In  $b$ -dimensional vector  $V$ , update the components of the vector:
  - For each feature, add the weight to every component for which the corresponding bit in the word's hash value is 1.
  - Subtract the weight if the value is 0.
4. After all words have been processed, generate a  $b$ -bit fingerprint by setting the  $i$ -th bit to 1 if the  $i$ -th component of  $V$  is positive, or 0 otherwise.

# Simhash Example

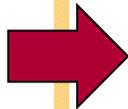
86

- Original text
  - Tropical fish include fish found in tropical environments around the world, including both freshwater and salt water species.
- 1. Words with weights (here: tf)
  - tropical 2 fish 2 include 1 found 1 environments 1 around 1 world 1 including 1 both 1 freshwater 1 salt 1 water 1 species 1
- 2. 8-bit hash values (in practice hundreds of bits)
  - tropical      01100001 fish                      10101011 include 11100110
  - found          00011110 environments      00101101 around 10001011
  - world          00101010 including              11000000 both      10101110
  - freshwater 00111111 salt                      10110101 water      00100101
  - species        11101110
- 3. Vector  $V$  formed by summing weights (weight for 1s; negative weight for 0s)
  - 1 -5 9 -9 3 1 3 3
- 4. 8-bit fingerprint formed from  $V$  (1 for positive, 0 for negative)
  - 1 0 1 0 1 1 1 1
- Duplicate if certain (high) percentage of fingerprint bits agree

# Overview

87

- Crawling the Web
- The Deep Web
- Document Conversion
- Document Storage
- Duplicate Detection
- Removing Noise



## Removing Noise

88

- Many web pages contain text, links, and pictures that are not directly related to the main content of the page.
- This additional material is mostly *noise* that could negatively affect the ranking of the page.
  - Presence of large numbers of irrelevant words
- Techniques have been developed to detect the content blocks in a web page.
  - Non-content material is either ignored or reduced in importance in the indexing process

# Noise example

89

Schlagzeilen | TV-Programm | RSS | Newsletter | Mobil | Dienste | Startseite | Wetter | DER SPIEGEL

**SPIEGEL ONLINE** NETZWELT

Suche

NACHRICHTEN VIDEO ENGLISH EINESTAGES FORUM SPIEGEL WISSEN ABO SHOP

Home | Politik | Wirtschaft | Panorama | Sport | Kultur | **Netzwelt** | Wissenschaft | UniSPIEGEL | SchulSPIEGEL | Reise | Auto

Nachrichten > Netzwelt > Web Login > Registrierung

01.05.2009 Drucken | Senden | Bookmark | Feedback | Merken

**COOKIE-RICHTLINIE** Schrift: [A]

### Wie die EU Internet-Nutzer nerven will

Von Frank Patalong

Die EU-Ratspräsidentschaft versucht, ein Zustimmungsverfahren zu Cookies einzuführen. Das klingt zunächst nach einer langweiligen Marginalie. Bis man begreift, dass Sie mehrere Einverständniserklärungen hätten unterzeichnen müssen, um auch nur diese Zeilen zu lesen.

ANZEIGE



Über Cookies kann man geteilter Meinung sein. Die kleinen Textdateien machen Notizen über Ihr Surfverhalten, über Ihre auf bestimmten Web-Seiten gewählten Einstellungen und Präferenzen und darüber, welchen Funktionalitäten einer Seite Sie zugestimmt und welche Sie abgelehnt haben.



Betreiber von Web-Seiten nutzen Cookies, um Ihnen zum Beispiel ein bequemes Einkaufen zu ermöglichen. Sie sorgen dafür, dass Sie beim Einloggen in Ihren Instant Messenger nicht jedesmal Nutzernamen und Passwort eingeben

**MOST WANTED**

Netzwelt | Alle Ressorts | Videos

- 1 Simple Webseiten: Von gaga bis genial
- 2 Lautstark: Volle Dröhnung auf die Ohren
- 3 Webradio: Radiomitschnitte statt Raubkopien
- 4 I.Play: Auf diesem Spielplatz sammeln Kinder Highscores
- 5 Cookie-Richtlinie: Wie die EU Internet-Nutzer nerven will

**VIDEOS NETZWELT**

1 | 2 | 3



Netzfischer: Fan attackiert Britney Spears



Netzfischer: Verwandte Autos blamieren Diebe

**EXKLUSIV**

- Quiz der Spieleklassiker: Sind Sie ein Game Boy?
- Terrorprozess: Chemikalien-Händler der Sauerland-Gruppe belieferte private Bombenbauer
- Acer Aspire Revo: Der 300-Euro-PC mit Grafik-Turbolader
- Kampf der Community-Giganten: Wieso Facebook gegen StudivZ prozessiert
- Katastrophenschutz: Kanal-Kidnapping für Notfälle

**FEHLFUNKTION >>**

- Wirre Rechtschreibprüfung: Das Mist-Gesetz des Onanier-Ordens
- Technikergernis Rechtschreibprüfung: Barock Obama und die Stinker-Raketen

Singles in Ihrer Nähe kennenlernen?



# Noise example

90

wenn Cookies, das haben die EU-Parlamentarier durch die Diskussionen um Google, vor allem aber um den britischen Datenkraken Phorm gelernt, können dazu dienen, das Konsumverhalten von EU-Bürgern auszuspionieren. Es gäbe wohl wichtigere Datenschutzthemen, die eine Hinterfragung lohnen würden - von Ursula von der Leyens abstrusen Internet-Sperr-Plänen über Wolfgang Schäubles Überwachungsphantasien bis hin zur Bürgerdaten-Tombola im internationalen Sicherheitsbehörden-Club und zur leidigen Vorratsdatenspeicherung. Sei's drum: Die EU-Parlamentarier finden es okay, wenn unsere Vorstrafen zwecks Terrorabwehr an US-Behörden vermailt werden und unsere ganze Kommunikation auf Monate dokumentiert wird. Hauptsache, niemand bekommt ohne ausdrückliches Einverständnis einen Cookie.



Die klammheimlichen Verordnungspläne gehen zahlreichen Medien-, Werber- und Händlerverbänden dagegen ganz schön auf den Keks.

**Bürger, duck' Dich: Man hält Dich für nicht mündig**

MEHR ÜBER...  
**Cookies Europäische Union**  
**Ratspräsidentenschaft ePrivacy Datenschutz Phorm**  
 zu SPIEGEL WISSEN >>>

Kein Wunder, denn in der Praxis würde die Ergänzung zur ePrivacy-Richtlinie bedeuten, dass Sie auf jeder besuchten Web-Seite mit ganzen Kaskaden von Pop-up-Verträgen belastigt würden.

Jedesmal, wenn Sie einen Artikel aufrufen, eine Seite weiterblättern, der Ad-Server, der die Werbung einspielt, eine

Anzeige wechselt; wenn Sie sich bei Amazon einen Artikel ansähen, wenn Sie versuchen würden, die Artikel-Merkmalfunktion bei Ebay zu nutzen; wenn Sie Benutzereinstellungen in Ihrem Facebook-, MySpace- oder StudiVZ-Account vornehmen; wenn Sie sich in Ihr E-Mail-Konto einloggen, bei jedem Schritt in Ihrem Online-Banking würde Ihnen ein Pop-up serviert, in dem Sie erst einmal bestätigen müssten, dass Sie wirklich wollen, was Sie da gerade tun und damit einverstanden sind, dass Ihnen auch ermöglicht wird, was Sie wollen: umzublätern, Artikel aufzurufen, einzukaufen, Post zu lesen, Social Networks zu nutzen. Herr, wirf ihm vom Himmel!

**Europa, die Nervzone des Webs?**

Man muss sich das einmal vorstellen. Mit der bequemen Nutzung des Webs wäre es vorbei, sobald man sich auf Web-Seiten bewegt, die in der Europäischen Union hinterlegt sind - denn natürlich würde all das für außereuropäische Seiten nicht gelten. SPIEGEL ONLINE unterschiede sich vom "Sydney Morning Herald online" nicht nur in Sprache, Design und geografischem Fokus, sondern auch dadurch, dass es seine Nutzer gesetzlich verordnet dauernerven müsste - denn EU-Direktiven sind nach dem Subsidiaritätsprinzip in Landesgesetze umzusetzen.

Dabei kommt viel Sinnvolles heraus, leider zu oft aber auch geballter Schwachsinn. Das Problem dabei: Oft erfahren wir zu spät davon, weil EU-Themen in der Öffentlichkeit selten diskutiert werden. Vieles, was dort in der Mache ist, erscheint als bürokratisch und sehr weit weg - bis es uns in Form gültiger Gesetze serviert wird mit dem Argument, EU-Richtlinien müssten

SERVICE-ANGEBOTE

- Arztuche
- Immobilien-Börse
- Versicherungs-Vergleiche
- Kfz-Versicherung
- Brutto-Netto-Rechner
- Uni-Tools
- Rezensionen
- Energiespar-Ratgeber
- Stromanbieter-Vergleich
- buch aktuell
- Veranstaltungs-Kalender

...halt umgesetzt werden.



Im Fall Cookies steht zu befürchten, dass viele der Leute, die möglicherweise schon am 5. Mai darüber abzustimmen haben, nicht den geringsten Schimmer haben, worüber sie da eigentlich abstimmen. Es einfach nicht begreifen, sich nicht vorstellen können. Das Thema nicht erfassen, weil sie es nicht kennen. Das Internet nicht nutzen, sondern nutzen lassen, aber durchaus darüber entscheiden. In informierten Kreisen nennt man solche einflussreichen Menschen auch "Internet-Ausdrucker". Man kann nur hoffen, dass von denen wenige beteiligt sind; dass auch unsere deutschen Abgeordneten die Wichtigkeit des vermeintlich technischen Themas begreifen.

Denn man kann leider nicht davon ausgehen, dass das Thema vor der Abstimmung wirklich vertieft, erklärt und beredet würde. Es ist eine kleine, scheinbar marginale Änderung von vielen in einer Richtlinie, die nur einige wenige wirklich lesen werden. Erheblich größer wird die Zahl der Betroffenen ausfallen: Aktuellen Schätzungen zufolge gibt es davon allein in Deutschland rund 55 Millionen. Gemeint sind alle Internet-Nutzer, vor allem aber die, die dort versuchen, ihr Geld zu verdienen.

**Verordneter Wettbewerbsnachteil**

Ingo Notthoff, Sprecher des Bundesverbands Digitale Wirtschaft BVDW, entdeckt in den wohlmeinenden Plänen einen "Rückschlag für Internet-Nutzer und die Online-Wirtschaft". Er ist damit nicht allein: Wenn eine EU-Richtlinie die Nutzung europäischer Web-Seiten verkomplizieren würde, ließe das auf eine verordnete Wettbewerbsverzerrung hinaus. "Die Einführung eines Opt-in-Systems würde die Nutzung des Internets für den einzelnen Nutzer durch zahlreiche Zustimmungserfordernisse verlangsamen und den Zugang zu Online-Services und -Inhalten verkomplizieren", heißt es auch in einem Brief der Verlegerverbände an die deutschen Europa-Abgeordneten. "Eine einfache und verbraucherfreundliche Nutzung von Web-Seiten wäre dann nicht mehr möglich."

**IHRE MEINUNG IST GEFRAGT**  
 Diskutieren Sie über diesen Artikel

Es ist sogar noch schlimmer: Die Regelung ist schlicht kontraproduktiv. Sie schützt die Daten der Nutzer nicht, sondern nervt sie nur unnötig. Wenn ich mit meiner Browsereinstellung,

die alle Cookies und Verlaufsdaten nach jeder Sitzung löscht, solch eine EU-kompatible Seite besuche, werde ich jedes Mal auf Neue mit diversen "Sind Sie einverstanden, dass ..." - Fenstern genervt. Mein Kollege, der auf Datenschutz pfeift und alle Cookies und Verlaufsdaten bis zum jüngsten Gericht speichert, wird damit nur ein einziges Mal konfrontiert: Sein einmal gegebenes Einverständnis bleibt archiviert.

Was bitte schön soll an dieser Regelung im Sinne des Verbrauchers sein? Wie soll ihn das schützen? Wer sich selbst schützt, indem er Cookies kilt, statt sich damit EU-konform einverstanden zu erklären, wird mit endlosen Pop-up-Kaskaden bestraft. Wer seinen Datenschutz vernachlässigt, wird auch mit den EU-Cookie-Pop-ups nicht behelligt.

Erde an Brüssel: jemand zu Hause?

**Diskutieren Sie über diesen Artikel!**

FORUM

**DIE NEUESTEN BEITRÄGE ZUM ARTIKEL**

1. heute 13.45 Uhr von Fackus Glaube macht selig
2. heute 13.25 Uhr von SeaBug ohne Wertung
3. heute 13.11 Uhr von StonyBrook Sinn/Unsinn von Cookies
4. heute 12.27 Uhr von Fackus na denn
5. heute 12.26 Uhr von Boindil Cookies

Alle Beiträge zum Artikel >>>

**MELDUNGEN AUS ANDEREN RESSORTS**

**WISSENSCHAFT**

**Impfstoff gegen Schweinegrippe: Roulettespiel mit dem Seuchenvirus**  
 Forscher arbeiten an einem Impfstoff gegen das Schweinegrippe-Virus - fürchten aber, dass H1N1 mutiert. Kann ein jetzt entwickeltes Serum überhaupt vor einer veränderten Version des Erregers schützen?  
 Von Heike Le Ker mehr... [ Forum ]

- > **Klimaschutz:** Australien verschiebt Emissionshandel
- > **Drogen- und Suchtbericht:** Deutschlands Jugend hat ein Alkoholproblem
- > **Arktisches Monopoly:** Heimliche Herren des Eismeer-Schatzes
- > **mehr Wissenschaft**

**KULTUR**

**Taschenbuch-Bestseller: Buch schreiben, Münze reiben**  
 Infotainment heißt das Genre, Moderator Ranga Yogeshwar gehört im TV zu seinen erfolgreichsten Vertretern. Jetzt hat der studierte Physiker ein Buch vorgelegt. Ein bisschen Spaß, ein bisschen Know-how: Fertig ist der Wissens-Bestseller. mehr...

- > **Soulstar Raphaela Saadiq:** Verehrer, Verführer, Verräter
- > **Kamitz-Ausstellung:** "Öl, Ei, Salz und rühren"
- > **Box Office:** Wolverine krallt sich die Kinokasse
- > **mehr Kultur**

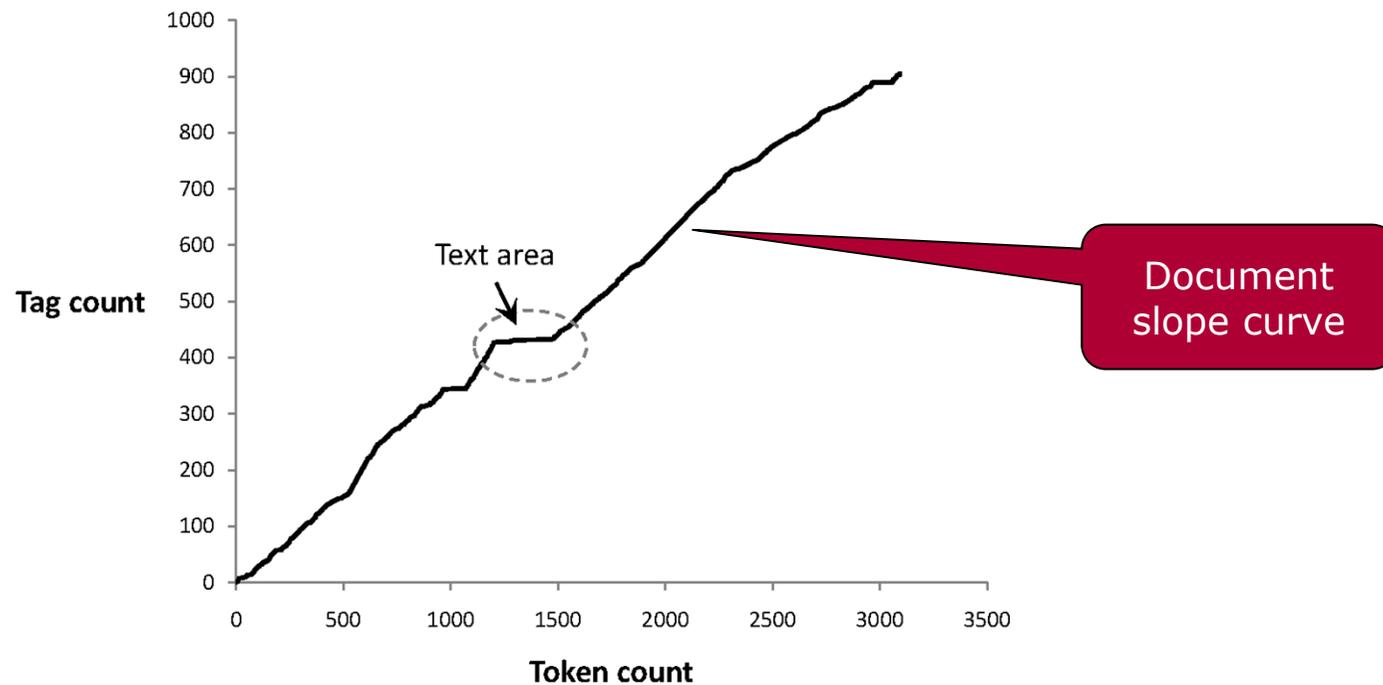
© SPIEGEL ONLINE 2009  
 Alle Rechte vorbehalten  
 Vervielfältigung nur mit Genehmigung der SPIEGELnet GmbH



# Finding Content Blocks

91

- Intuition: less HTML tags in main content
- Cumulative distribution of tags in the example web page



- Main text content of the page corresponds to the “plateau” in the middle of the distribution

## Finding Content Blocks

92

- Represent a web page as a sequence of bits, where  $b_n = 1$  indicates that the  $n$ th token is a tag
  - Corresponds to document slope curve
  - Ignore text formatting tags
- Optimization problem where we find values of  $i$  and  $j$  to
  - Maximize the number of tags below  $i$
  - Maximize the number of tags above  $j$
  - Maximize the number of non-tag tokens between  $i$  and  $j$
  - i.e., maximize

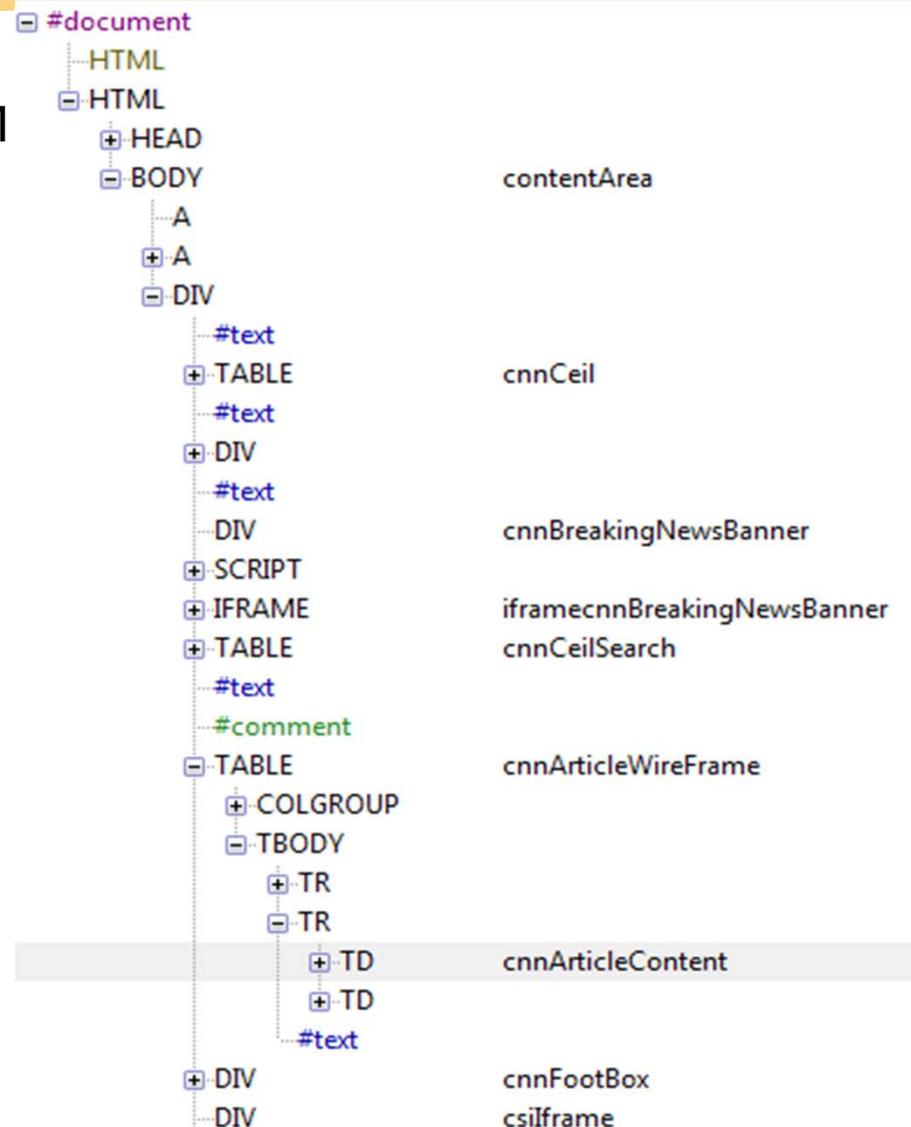
$$\sum_{n=0}^{i-1} b_n + \sum_{n=i}^j (1 - b_n) + \sum_{n=j+1}^{N-1} b_n$$

- Compute by scanning  $i$ -s and  $j$ -s

# Finding Content Blocks

93

- Other approaches use DOM structure and visual (layout) features
- Effective for multiple content sections in a document
  - As opposed to the previous tag distribution approach



# Deep Web Literature

94

## ■ Wichtigste Literatur

- [IGS01] Probe, Count, and Classify. P.G. Ipeirotis, L. Gravano, and M. Shami. SIGMOD 2001
- [BC04] A. Bergholz and B. Chidlovskii. Learning Query Languages of Web Interfaces, SAC04

## ■ Weiteres

- [Be01] The Deep Web: Surfacing Hidden Value Michael K. Bergman, Whitepaper at <http://www.completeplanet.com/Tutorials/DeepWeb/index.asp>
- [To01] Foliensatz von Dawne Tortorella (BellCow) nach [Be01]
- [IG02] Distributed Search of the Hidden Web: Hierarchical Data Sampling and Selection. P.G. Ipeirotis and L. Gravano in VLDB 2002.