Google logo – 24. august 2011

Sådan virker Google™ (måske)

Gerth Stølting Brodal

Datalogisk Institut
Aarhus Universitet

MADALGO
CENTER FOR MASSIVE DATA ALGORITHMICS

Ungdommens Naturvidenskabelige Forening Aarhus, 25. august 2011

Hvornår har du sidst brugt Google?

a) Seneste time

b) Idag

c) Denne uge

d) Denne måned

e) Aldrig

Internetsøgemaskiner
(April 2011)

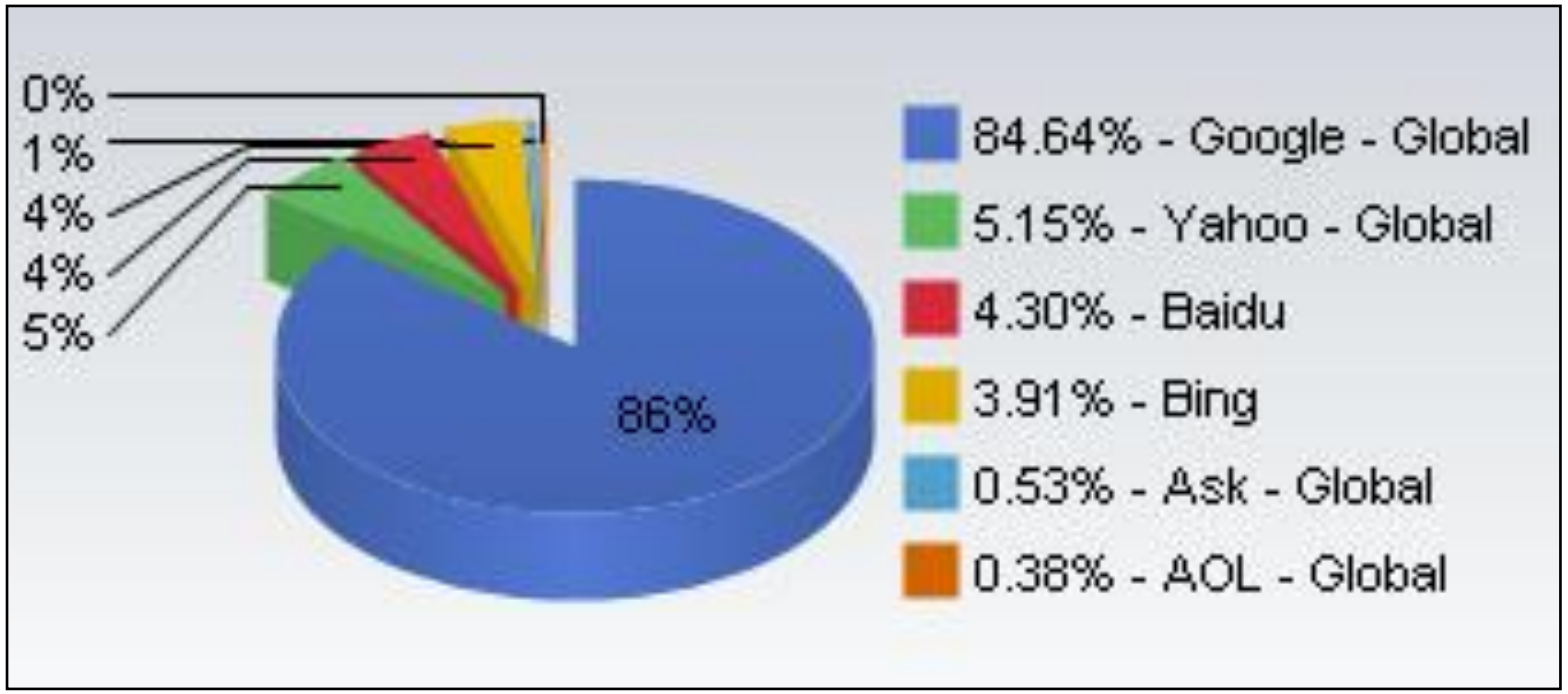

marketshare.hitslink.com


Google
Baidu 百度
msn
HOTBOT
altavista
alltheweb
find it all
Jubii
-or not to be
AOL Search
LYCOS
YAHOO! SEARCH
excite
bing
Ask
.com

Internettets Historie

Historiske Perspektiv

- 1969 Første ARPANET forbindelser - starten på internettet
- 1971 Første email, FTP
- 1990 HTML sproget defineres
- 1991-1993 få kender til HTML
- 1993 Mosaic web-browser
- 1993 Lycos
- 1994 WebCrawler
- 1995 Yahoo!, Altavista
- **1998 Google**
- 2004 Facebook
- 2005 YouTube
- ....

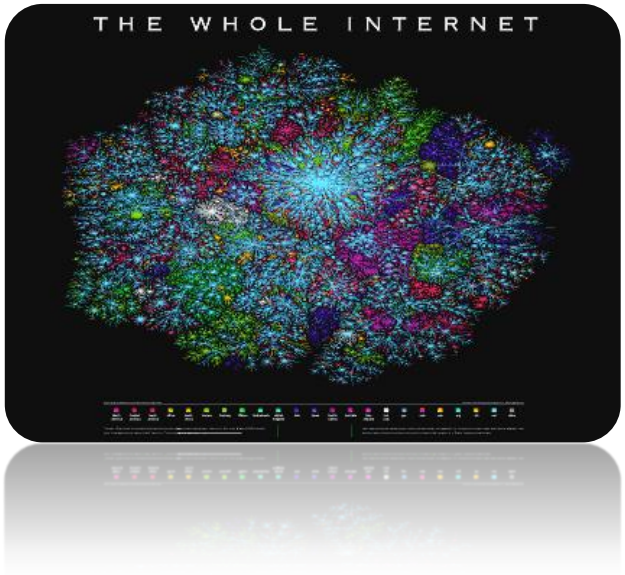

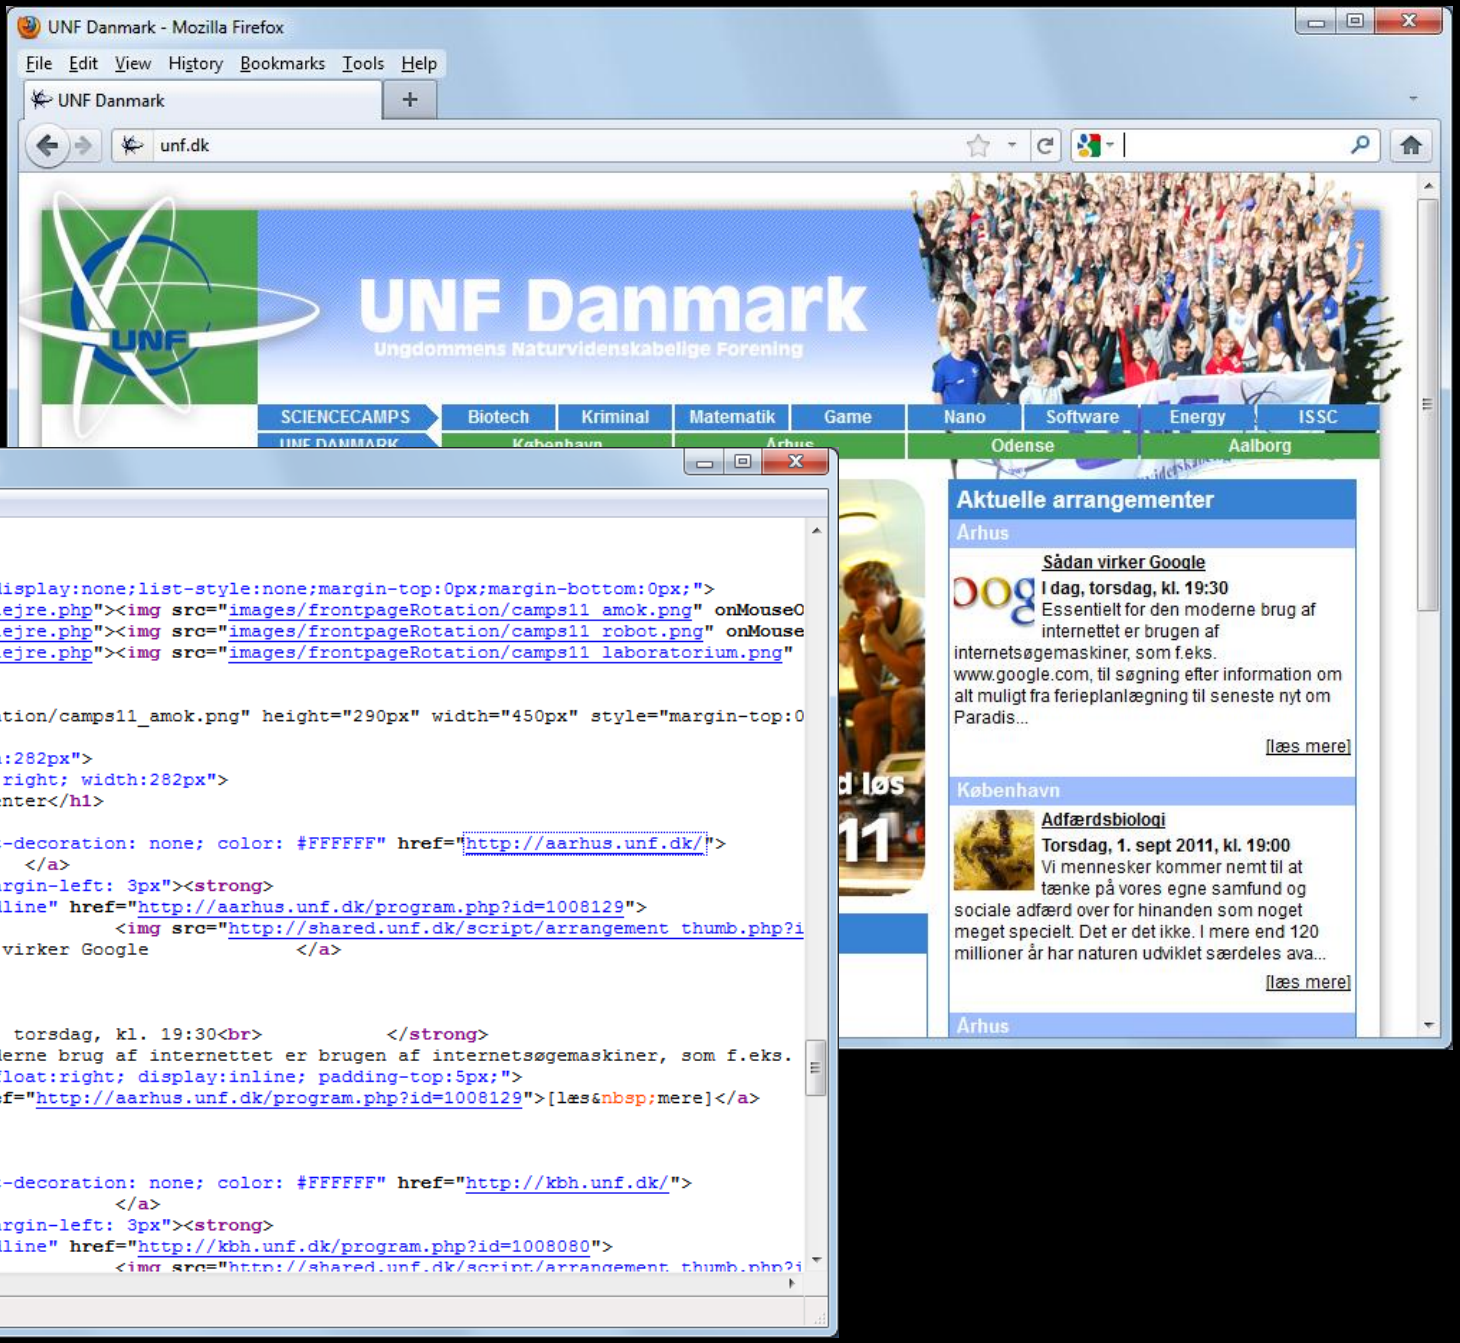
UNF Danmark - Mozilla Firefox
File Edit View History Bookmarks Tools Help
UNF Danmark
unf.dk
UNF Danmark
Ungdommens Naturvidenskabelige Forening
SCIENCECAMPS
Biotech
Kriminal
Matematik
Game
Nano
Software
Energy
ISSC
Odense
Aalborg
Aktuelle arrangementer
Århus
Sådan virker Google
I dag, torsdag, kl. 19:30
Essentielt for den moderne brug af internettet er brugen af internetsøgemaskiner, som f.eks. www.google.com, til søgning efter information om alt muligt fra ferieplanlægning til seneste nyt om Paradis...
[læs mere]
København
Adfærdsbiologi
Torsdag, 1. sept 2011, kl. 19:00
Vi mennesker kommer nemt til at tænke på vores egne samfund og sociale adfærd over for hinanden som noget meget specielt. Det er det ikke. I mere end 120 millioner år har naturen udviklet særdeles ava...
[læs mere]
Århus
Source of: http://unf.dk/ - Mozilla Firefox
File Edit View Help
});
</script>
<ul id="image_rotate" style="display:none;list-style:none;margin-top:0px;margin-bottom:0px;">
<img src="images/frontpageRotation/camps11_amok.png" onMouseO
<img src="images/frontpageRotation/camps11_robot.png" onMouse
<img src="images/frontpageRotation/camps11_laboratorium.png"

<img src="images/frontpageRotation/camps11_amok.png" height="290px" width="450px" style="margin-top:0
</noscript>

<h1>Aktuelle arrangementer</h1>
<h2>

Århus
</h2>

<img src="http://shared.unf.dk/script/arrangement_thumb.php?i
Sådan virker Google

I dag, torsdag, kl. 19:30
Essentielt for den moderne brug af internettet er brugen af internetsøgemaskiner, som f.eks.

[læs mere]

<h2>

København
</h2>
<a class="headline" href="http://kbh.unf.dk/program.php?id=1008080">
Line 303, Col 71

Internettet – WorldWideWeb

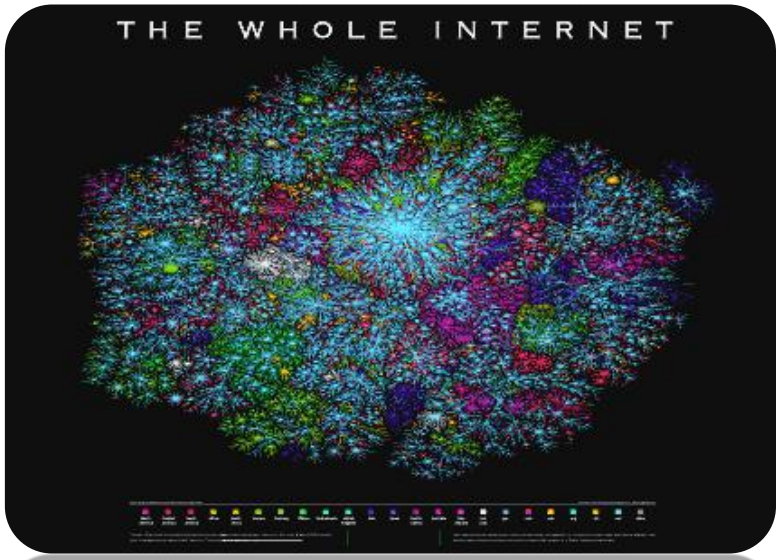

- **Meget** stor mængde **ustruktureret** information.
- Hvordan finder man relevant info? **Søgemaskiner**!

1994 Lycos,. . .
1996 Alta Vista: mange sider
1999 Google: mange sider og **god ranking**

Søgemaskinernes Barndom

`princess diana`

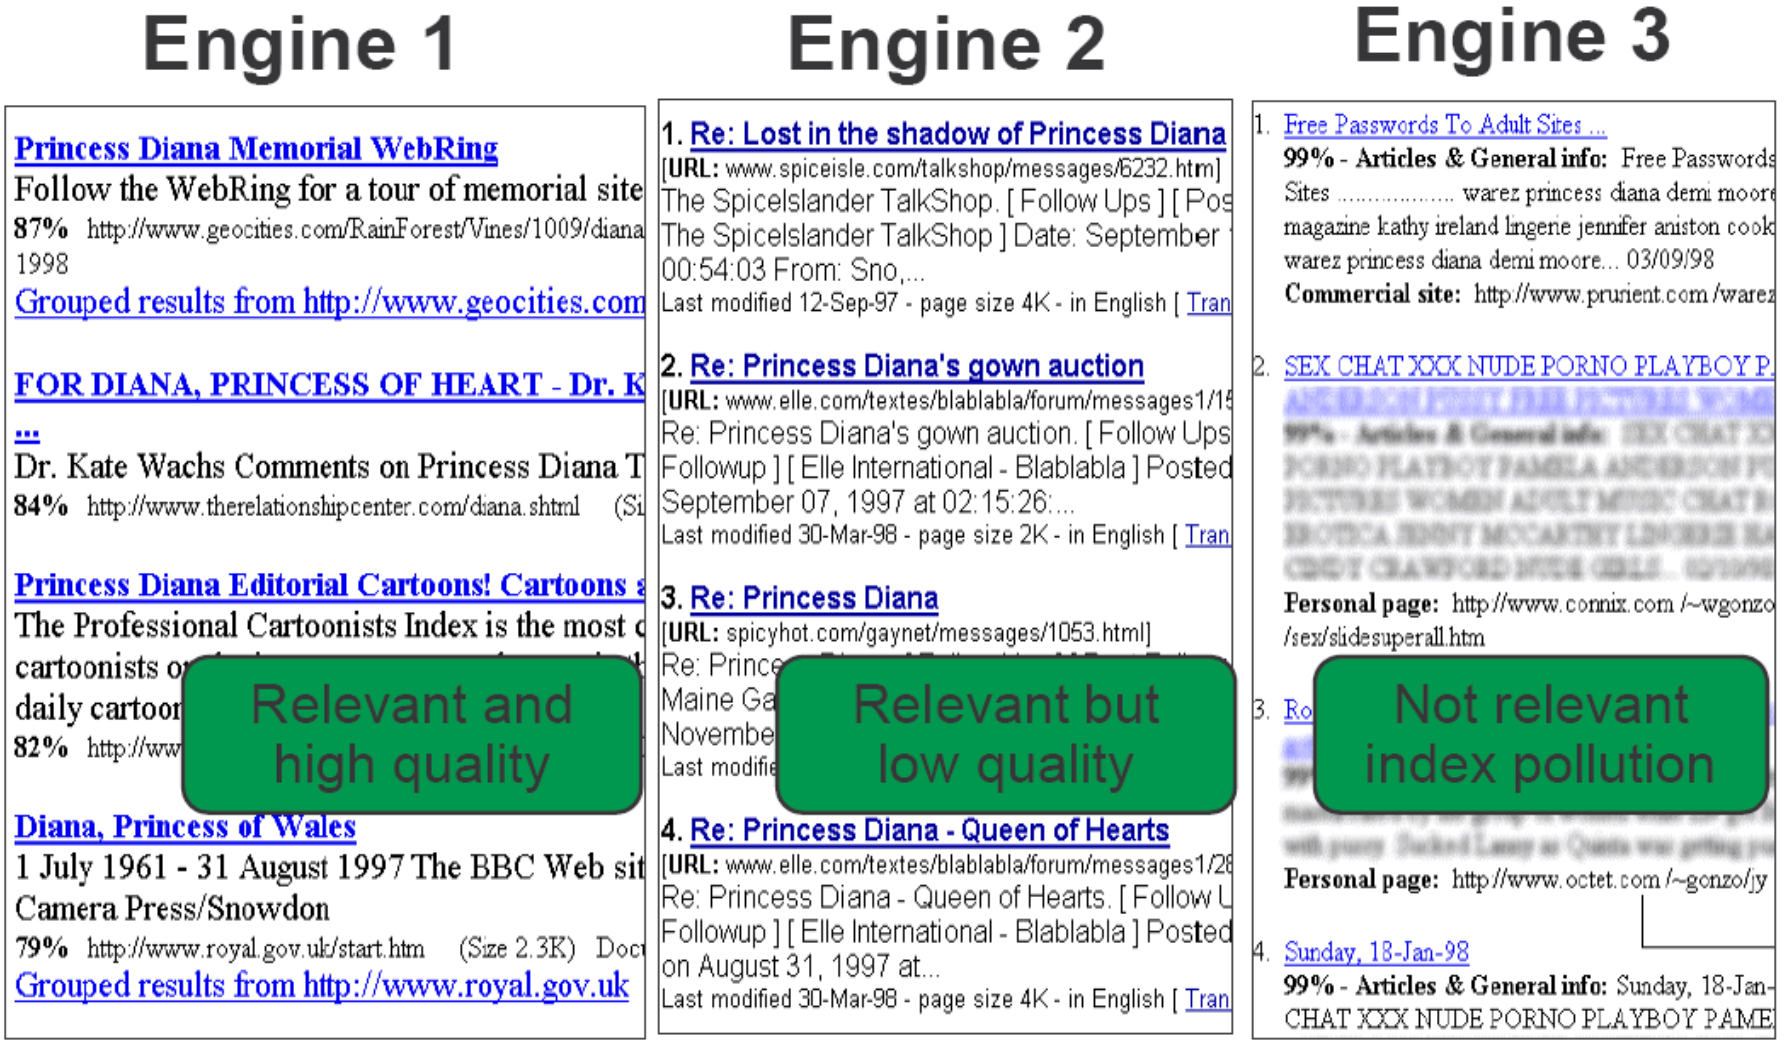

Henzinger @ Google, 2000

2004

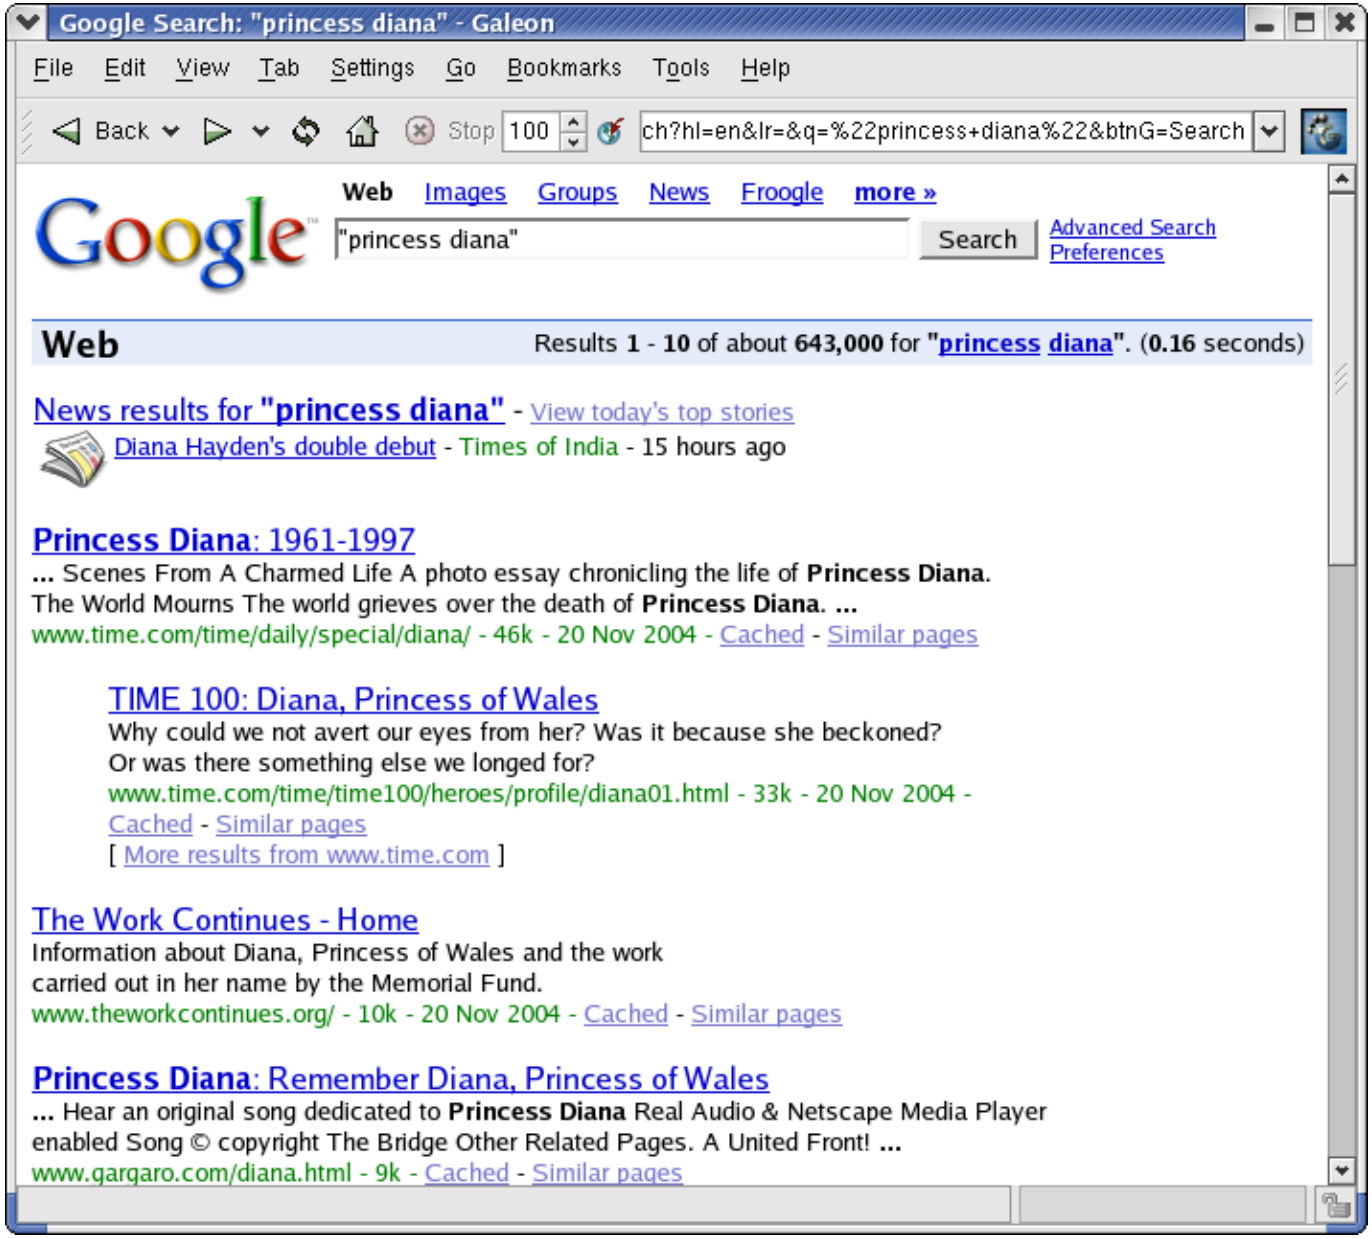
Google Search: "princess diana" - Galeon
File Edit View Tab Settings Go Bookmarks Tools Help
Back Stop 100
ch?hl=en&lr=&q=%22princess+diana%22&btnG=Search
Google
Web Images Groups News Froogle more »
"princess diana"
Search
Advanced Search
Preferences
Web
Results 1 - 10 of about 643,000 for "princess diana". (0.16 seconds)
News results for "princess diana" - View today's top stories
Diana Hayden's double debut - Times of India - 15 hours ago
Princess Diana: 1961-1997
... Scenes From A Charmed Life A photo essay chronicling the life of Princess Diana.
The World Mourns The world grieves over the death of Princess Diana. ...
www.time.com/time/daily/special/diana/ - 46k - 20 Nov 2004 - Cached - Similar pages
TIME 100: Diana, Princess of Wales
Why could we not avert our eyes from her? Was it because she beckoned?
Or was there something else we longed for?
www.time.com/time/time100/heroes/profile/diana01.html - 33k - 20 Nov 2004 -
Cached - Similar pages
[More results from www.time.com]
The Work Continues - Home
Information about Diana, Princess of Wales and the work
carried out in her name by the Memorial Fund.
www.theworkcontinues.org/ - 10k - 20 Nov 2004 - Cached - Similar pages
Princess Diana: Remember Diana, Princess of Wales
... Hear an original song dedicated to Princess Diana Real Audio & Netscape Media Player
enabled Song © copyright The Bridge Other Related Pages. A United Front! ...
www.gargaro.com/diana.html - 9k - Cached - Similar pages

2009

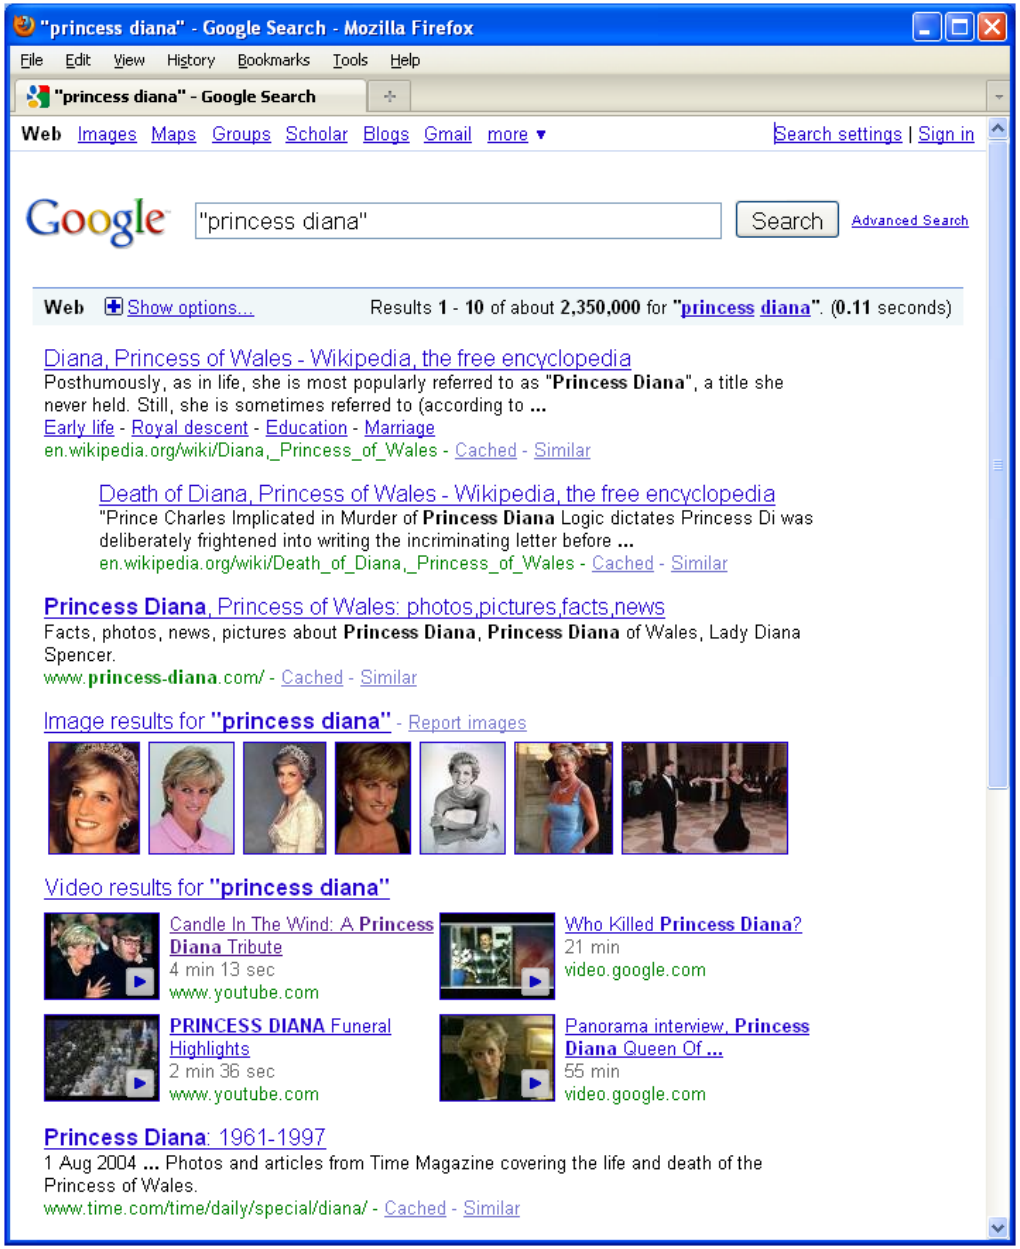
"princess diana" - Google Search - Mozilla Firefox
File Edit View History Bookmarks Tools Help
"princess diana" - Google Search
Web Images Maps Groups Scholar Blogs Gmail more ▾
Search settings | Sign in
Google
"princess diana"
Search
Advanced Search
Web
Show options...
Results 1 - 10 of about 2,350,000 for "princess diana". (0.11 seconds)
Diana, Princess of Wales - Wikipedia, the free encyclopedia
Posthumously, as in life, she is most popularly referred to as "Princess Diana", a title she never held. Still, she is sometimes referred to (according to ...
Early life - Royal descent - Education - Marriage
en.wikipedia.org/wiki/Diana,_Princess_of_Wales - Cached - Similar
Death of Diana, Princess of Wales - Wikipedia, the free encyclopedia
"Prince Charles Implicated in Murder of Princess Diana Logic dictates Princess Di was deliberately frightened into writing the incriminating letter before ...
en.wikipedia.org/wiki/Death_of_Diana,_Princess_of_Wales - Cached - Similar
Princess Diana, Princess of Wales: photos,pictures,facts,news
Facts, photos, news, pictures about Princess Diana, Princess Diana of Wales, Lady Diana Spencer.
www.princess-diana.com/ - Cached - Similar
Image results for "princess diana" - Report images
Video results for "princess diana"
Candle In The Wind: A Princess Diana Tribute
4 min 13 sec
www.youtube.com
Who Killed Princess Diana?
21 min
video.google.com
PRINCESS DIANA Funeral Highlights
2 min 36 sec
www.youtube.com
Panorama interview, Princess Diana Queen Of ...
55 min
video.google.com
Princess Diana: 1961-1997
1 Aug 2004 ... Photos and articles from Time Magazine covering the life and death of the Princess of Wales.
www.time.com/time/daily/special/diana/ - Cached - Similar

2011

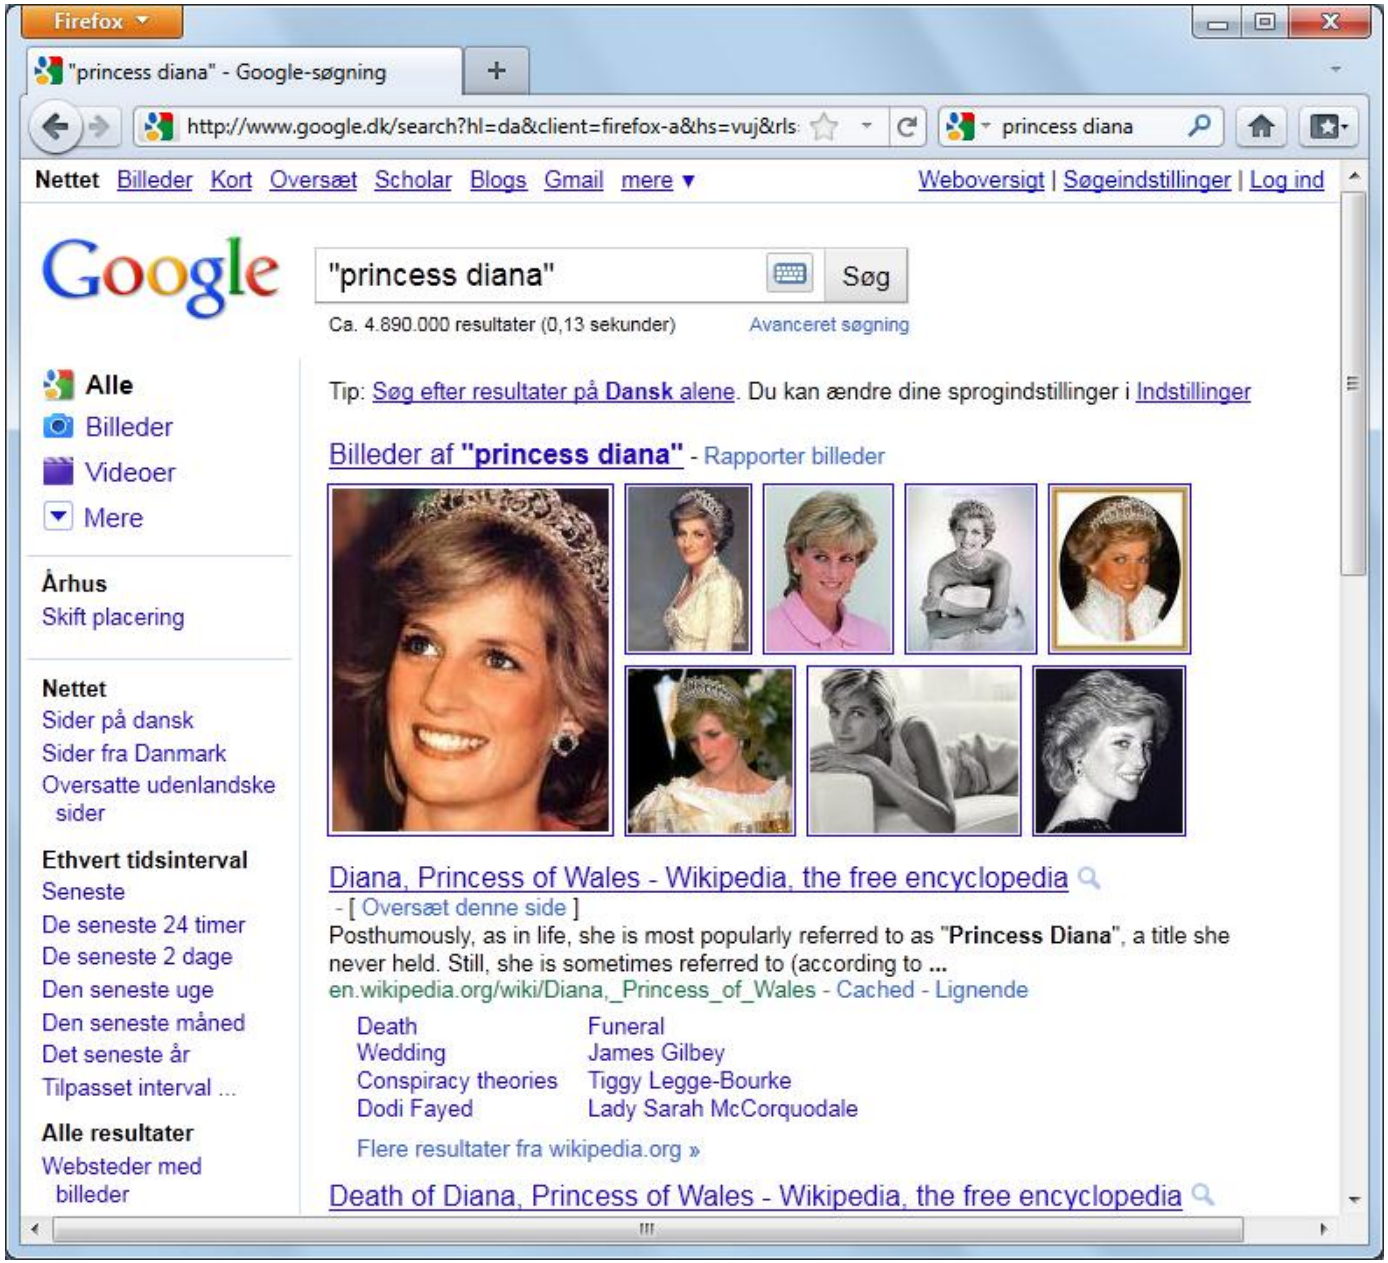
Firefox
"princess diana" - Google-søgning
http://www.google.dk/search?hl=da&client=firefox-a&hs=vuj&rls
princess diana
Nettet Billeder Kort Oversæt Scholar Blogs Gmail mere ▾
Weboversigt | Søgeindstillinger | Log ind
Google
"princess diana"
Søg
Ca. 4.890.000 resultater (0,13 sekunder)
Avanceret søgning
Alle
Billeder
Videoer
Mere
Århus
Skift placering
Nettet
Sider på dansk
Sider fra Danmark
Oversatte udenlandske sider
Ethvert tidsinterval
Seneste
De seneste 24 timer
De seneste 2 dage
Den seneste uge
Den seneste måned
Det seneste år
Tilpasset interval ...
Alle resultater
Websteder med billeder
Tip: Søg efter resultater på Dansk alene. Du kan ændre dine sprogindstillinger i Indstillinger
Billeder af "princess diana" - Rapporter billeder
Diana, Princess of Wales - Wikipedia, the free encyclopedia
- [Oversæt denne side]
Posthumously, as in life, she is most popularly referred to as "Princess Diana", a title she never held. Still, she is sometimes referred to (according to ...
en.wikipedia.org/wiki/Diana,_Princess_of_Wales - Cached - Lignende
Death
Wedding
Conspiracy theories
Dodi Fayed
Funeral
James Gilbey
Tiggy Legge-Bourke
Lady Sarah McCorquodale
Flere resultater fra wikipedia.org »
Death of Diana, Princess of Wales - Wikipedia, the free encyclopedia

Firefox

"Nobodys Home" by Tina Dickow on ... | unf - Google-søgning

http://www.google.dk/search?q=unf&ie=utf-8&oe=utf-8&aq=t&rls=org.mozilla:en-US:official&client=fire

unf

Nettet Billeder Kort Oversæt Scholar Blogs Gmail mere ▾ Søgeindstillinger | Log ind

Google

unf Søg

Ca. 6.480.000 resultater (0,09 sekunder) Avanceret søgning

Alle
Billeder
Videoer
Mere

Aarhus
Skift placering

Nettet
Sider på dansk
Sider fra Danmark
Oversatte udenlandske sider

Ethvert tidsinterval
Seneste
De seneste 24 timer
De seneste 2 dage
Den seneste uge
Den seneste måned
Det seneste år
Tilpasset interval ...

Flere værktøjer

UNF Danmark
Tilbyder foredrag, studiebesøg og nyheder indenfor alle grene af naturvidenskaben.
www.unf.dk/ - Cached - Lignende

København Om UNF
Odense Sciencecamps
Århus Medlemskab
Aalborg Matematik

Flere resultater fra unf.dk »

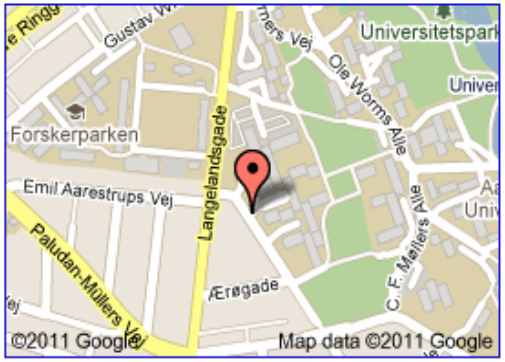

UNF Århus
stedside
Ny Munkegade
8000 Aarhus Municipality
8942 3345
Bus: Langelandsgade/Kaserneboulevar
Hent anvisninger

1 anmeldelse

UNF København
Hvad skal **UNF** KBH holde foredrag om d. 3. marts? [Læs beskrivelse] ...
kbh.unf.dk/ - Cached - Lignende

UNF Odense
Bag alle disse spørgsmål gemmer der sig en naturvidenskabelige forklaring ...
odense.unf.dk/ - Cached - Lignende

UNF Århus
Går du på gymnasiet eller HTX er der nu to muligheder for at komme billigt ...
aarhus.unf.dk/ - Cached - Lignende

Vis flere resultater fra unf.dk

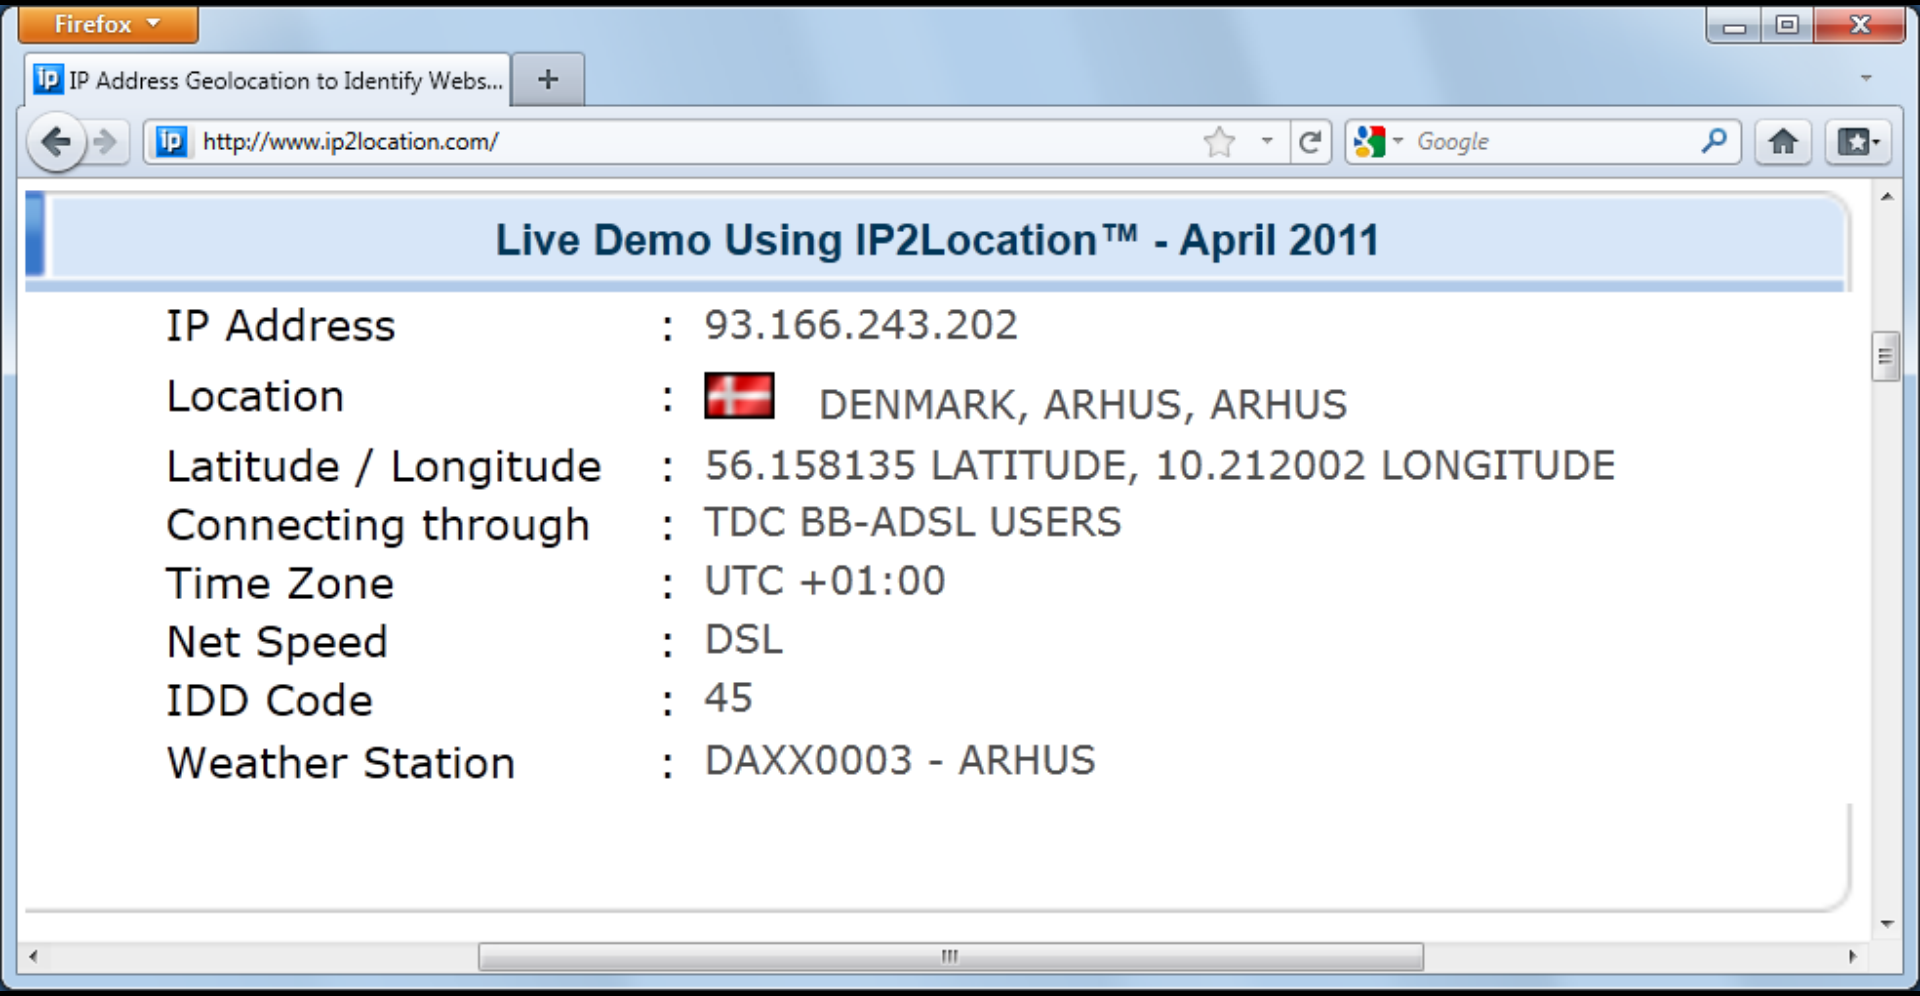
Firefox
IP Address Geolocation to Identify Webs...
http://www.ip2location.com/
Google
Live Demo Using IP2Location™ - April 2011
IP Address : 93.166.243.202
Location : DENMARK, ARHUS, ARHUS
Latitude / Longitude : 56.158135 LATITUDE, 10.212002 LONGITUDE
Connecting through : TDC BB-ADSL USERS
Time Zone : UTC +01:00
Net Speed : DSL
IDD Code : 45
Weather Station : DAXX0003 - ARHUS

Moderne Søgemaskiner

Imponerende performance

- Søger i 10^{10} sider
- Svartider 0,1 sekund
- 1000 brugere i sekundet
- Finder relevante sider

I'm Feeling Lucky

Nye Krav til Søgemaskiner

- Dynamiske websider:

  Nyheder, Twitter, Facebook, ...

- Personlig ranking:

  Baseret på hidtige besøgte websider, gmail, social netværk, ...

Google™

- Startet i 1995 som forskningsprojekt ved Stanford Universitet af ph.d. studerende **Larry Page og Sergey Brin**
- Privat firma grundlagt 1998
- Ansvarlig for hovedparten af alle internet-søgninger
- Hovedsæde i Silicon Valley

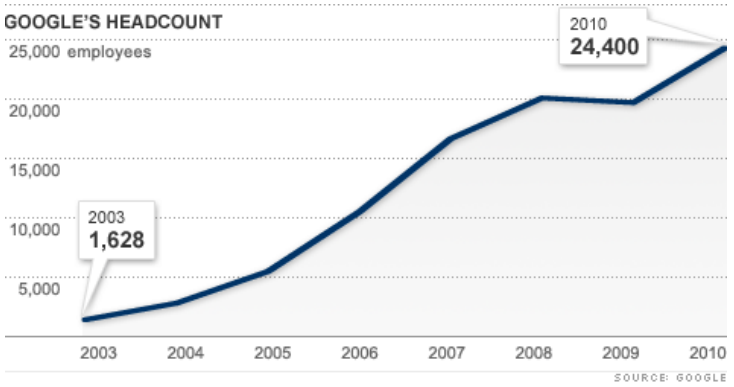

google ≈ googol = 10^{100}

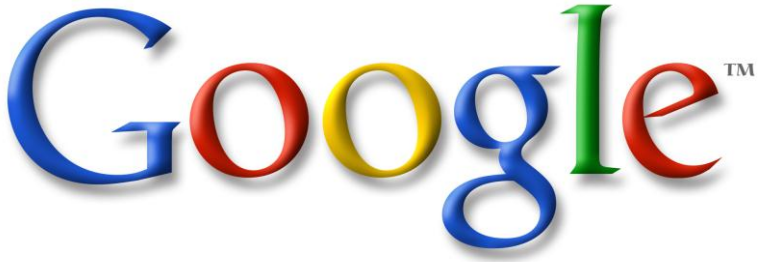
Google™


Google Docs


Google Chrome


http://www.google.com/ig
Google
Google


Google calendar


Google
Earth


YouTube


Gmail™
by Google


Picasa™


Google+


Google AdWords


Bouyer Crane Co.
EXIT

Hvilken Google bygning er dette ?

a) Arkiv over periodiske kopier af internettet
b) Supercomputer
c) Laboratorium for højhastighedsnetværk
d) Distributionslager af firma løsninger

Hvilken Google bygning er dette ?

a) Arkiv over periodisk kopier af internettet

b) Supercomputer

c) Laboratorium for højhastighedsnetværk

d) Distributionslager af firma løsninger

Google™ (2004)

- +8.000.000.000 web sider (+20 TB)
- PageRank: +3.000.000.000 sider og +20.000.000.000 links
- +2 Terabyte index, opdateres en gang om måneden
- +2.000.000 termer i indeks
- +150.000.000 søgninger om dagen (2000 i sekundet)
- +200 filtyper: HTML, Microsoft Office, PDF, PostScript, WordPerfect, Lotus ...
- +28 sprog

Google™ (2004)

- Cluster af +10.000 Intel servere med Linux
  - Single-processor
  - 256MB–1GB RAM
  - 2 IDE diske med 20-40Gb
- Fejl-tolerance: Redundans
- Hastighed: Load-balancing


Bouyer Crane Co.
EXIT


AU 14
AU-14

Google server, april 2009

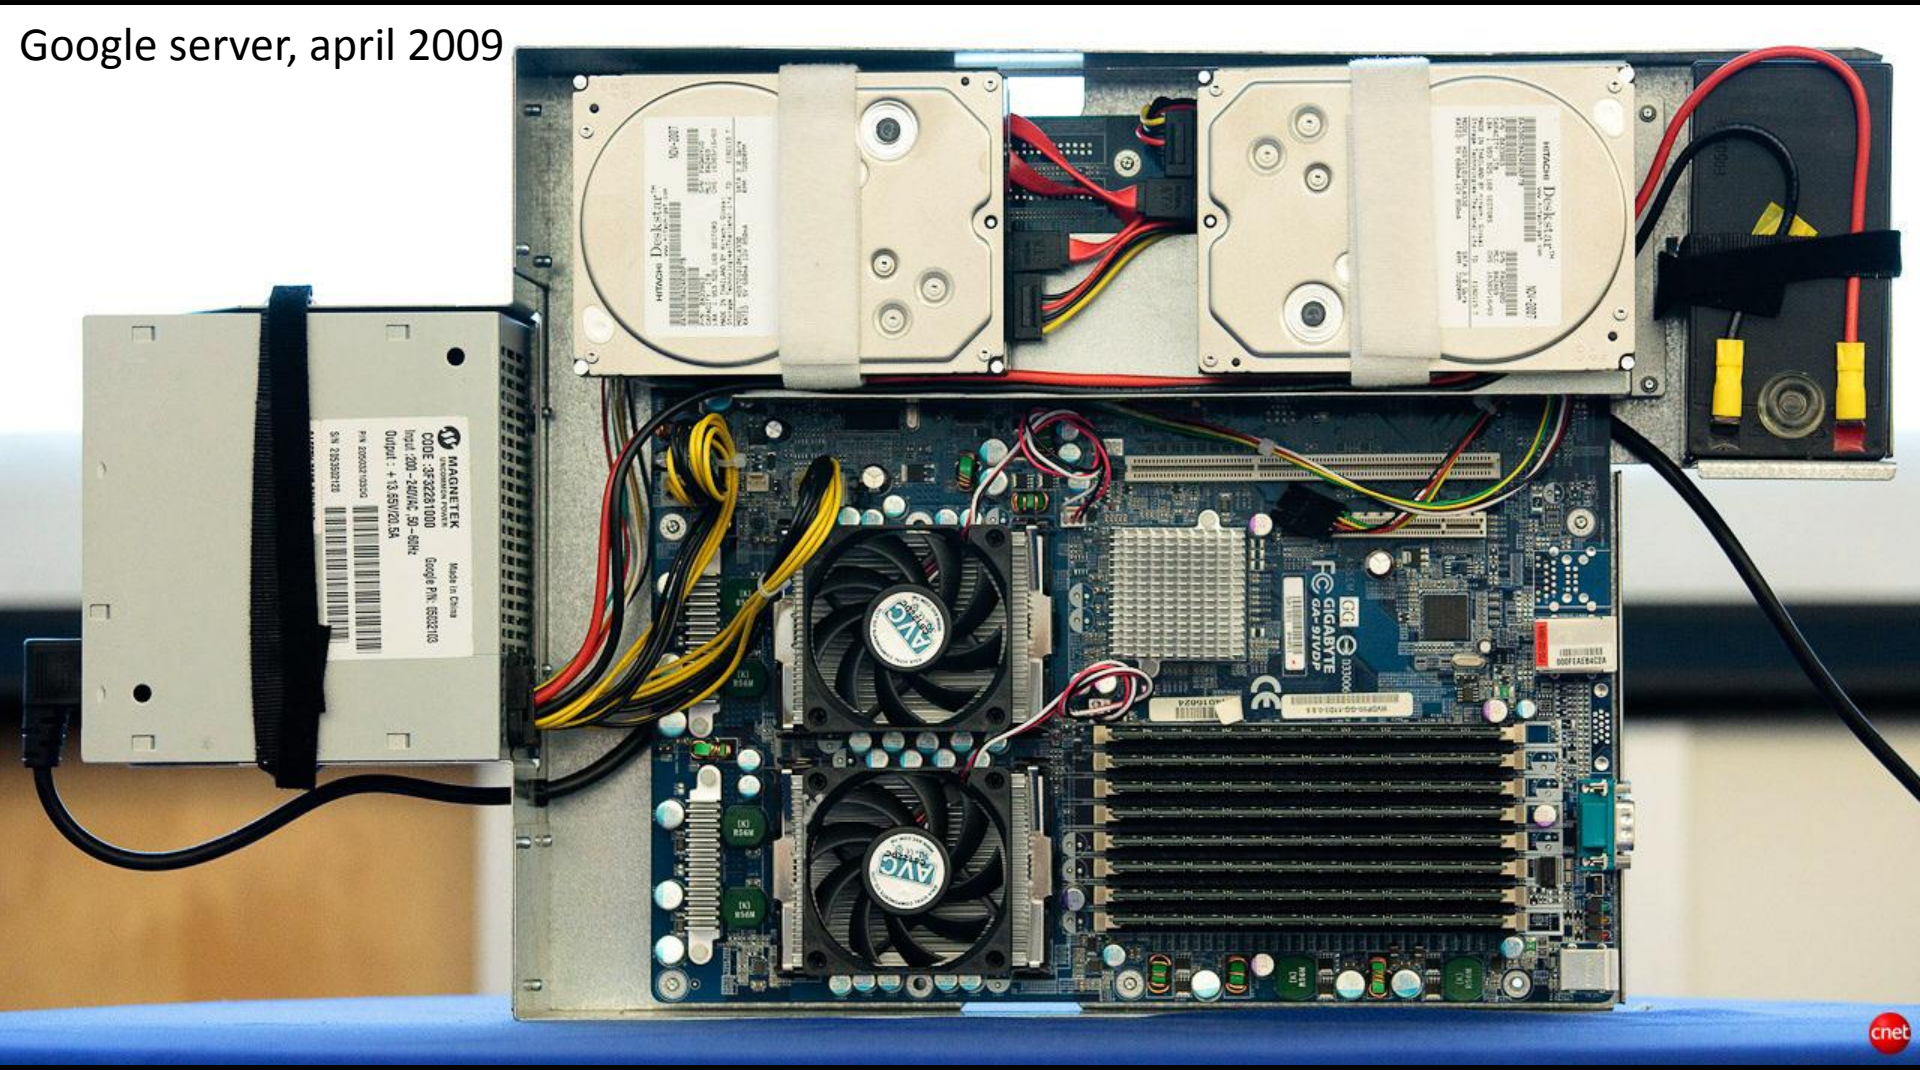

Google™ Datacentre (gæt 2007)

USA

- Mountain View, Calif.
- Pleasanton, Calif.
- San Jose, Calif.
- Los Angeles, Calif.
- Palo Alto, Calif.
- Seattle
- Portland, Oregon
- **The Dalles, Oregon**
- Chicago
- **Atlanta, Ga. (x 2)**
- **Reston, Virginia**
- Ashburn, Va.
- Virginia Beach, Virginia
- Houston, Texas
- Miami, Fla.
- **Lenoir, North Carolina**
- **Goose Creek, South Carolina**
- **Pryor, Oklahoma**
- **Council Bluffs, Iowa**

INTERNATIONAL

- Toronto, Canada
- Berlin, Germany
- Frankfurt, Germany
- Munich, Germany
- Zurich, Switzerland
- **Groningen, Netherlands**
- **Mons, Belgium**
- **Eemshaven, Netherlands**
- Paris
- London
- Dublin, Ireland
- Milan, Italy
- Moscow, Russia
- Sao Paolo, Brazil
- Tokyo
- Hong Kong
- Beijing

www-db.stanford.edu/pub/papers/google.pdf

The Anatomy of a Large-Scale Hypertextual Web Search Engine

Sergey Brin and Lawrence Page

Computer Science Department,
Stanford University, Stanford, CA 94305, USA
sergey@cs.stanford.edu and page@cs.stanford.edu

Abstract

In this paper, we present Google, a prototype of a large-scale search engine which makes heavy use of the structure present in hypertext. Google is designed to crawl and index the Web efficiently and produce much more satisfying search results than existing systems. The prototype with a full text and hyperlink database of at least 24 million pages is available at http://google.stanford.edu/
To engineer a search engine is a challenging task. Search engines index tens to hundreds of millions of web pages involving a comparable number of distinct terms. They answer tens of millions of queries every day. Despite the importance of large-scale search engines on the web, very little academic research has been done on them. Furthermore, due to rapid advance in technology and web proliferation, creating a web search engine today is very different from three years ago. This paper provides an in-depth description of our large-scale web search engine -- the first such detailed public description we know of to date. Apart from the problems of scaling traditional search techniques to data of this magnitude, there are new technical challenges involved with using the additional information present in hypertext to produce better search results. This paper addresses this question of how to build a practical large-scale system which can exploit the additional information present in hypertext. Also we look at the problem of how to effectively deal with uncontrolled hypertext collections where anyone can publish anything they want.

Keywords

World Wide Web, Search Engines, Information Retrieval, PageRank, Google

1. Introduction

(Note: There are two versions of this paper -- a longer full version and a shorter printed version. The full version is available on the web and the conference CD-ROM.)
The web creates new challenges for information retrieval. The amount of information on the web is growing rapidly, as well as the number of new users inexperienced in the art of web research. People are likely to surf the web using its link graph, often starting with high quality human maintained indices such as Yahoo! or with search engines. Human maintained lists cover popular topics effectively but are subjective, expensive to build and maintain, slow to improve, and cannot cover all esoteric topics. Automated search engines that rely on keyword matching usually return too many low quality matches. To make matters worse, some advertisers attempt to gain people's attention by taking measures meant to mislead automated search engines. We have built a large-scale search engine which addresses many of the problems of existing systems. It makes especially heavy use of the additional structure present in hypertext to provide much higher quality search results. We chose our system name, Google, because it is a common spelling of googol, or 10^{100} and fits well with our goal of building very large-scale search

Opbygning af en Søgemaskine

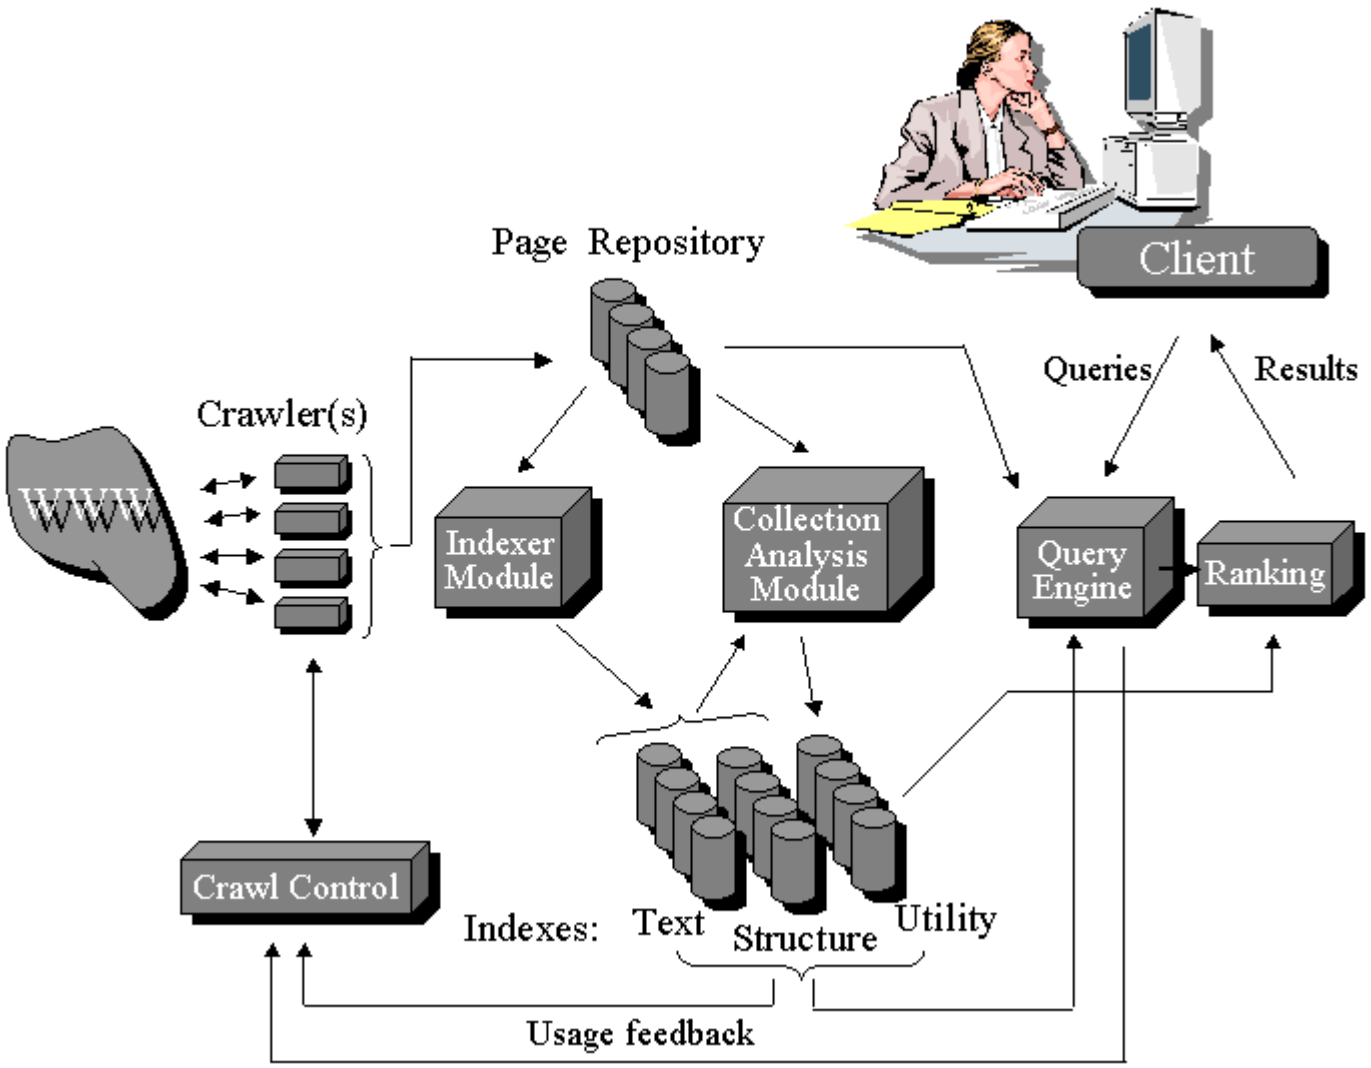

[Arasu et al., 2001]

En søgemaskines dele

Indsamling af data

- Webcrawling (gennemløb af internet)

Indeksering data

- Parsning af dokumenter
- Leksikon: indeks (ordbog) over alle ord mødt
- Inverteret fil: for alle ord i leksikon, angiv i hvilke dokumenter de findes

Søgning i data

- Find alle dokumenter med søgeordene
- Rank dokumenterne

Crawling

Webcrawling = Grafgennemløb

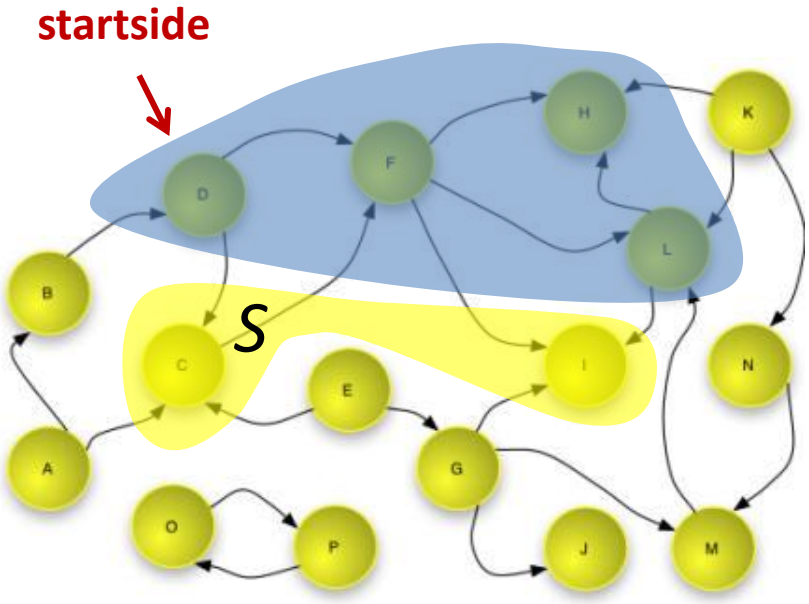

S = {startside}
repeat
  fjern en side *s* fra *S*
  parse *s* og find alle links (*s*, *v*)
  foreach (*s*, *v*)
    if *v* ikke besøgt før
      indsæt *v* i *S*

Statistik

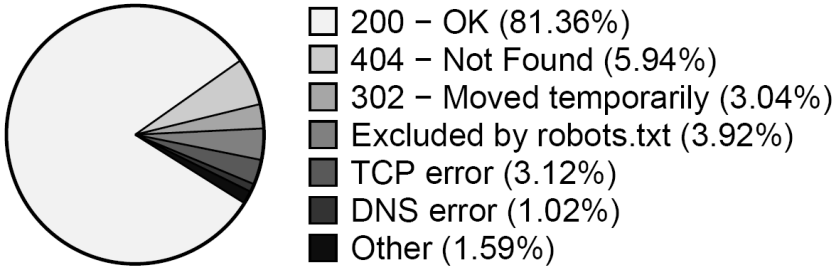

Figure 6: Outcome of download attempts

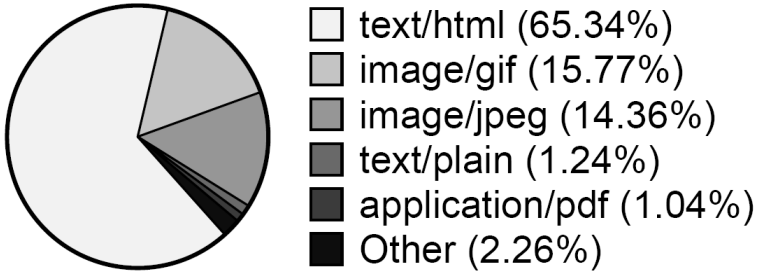

Figure 7: Distribution of content types

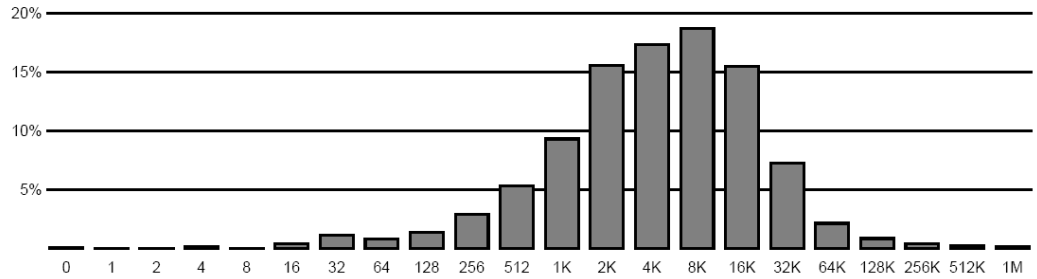

Figure 8: Distribution of document sizes

[Fra: Najork and Heydon, 2001]

robots.txt @ The New York Times

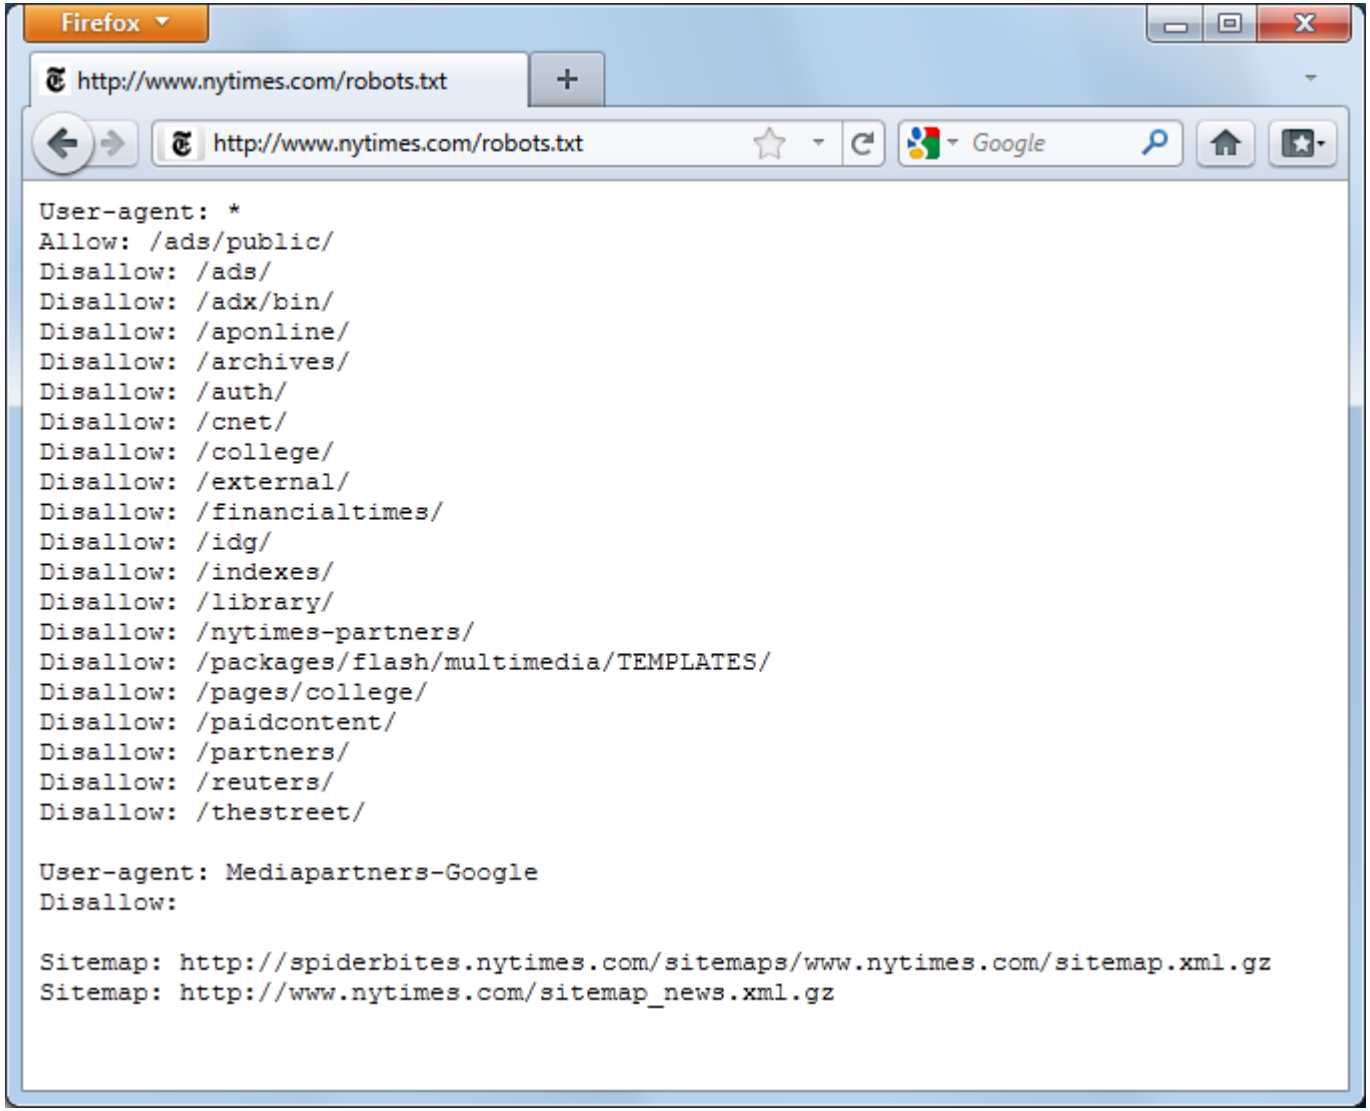


```
User-agent: *
Allow: /ads/public/
Disallow: /ads/
Disallow: /adx/bin/
Disallow: /aponline/
Disallow: /archives/
Disallow: /auth/
Disallow: /cnet/
Disallow: /college/
Disallow: /external/
Disallow: /financialtimes/
Disallow: /idg/
Disallow: /indexes/
Disallow: /library/
Disallow: /nytimes-partners/
Disallow: /packages/flash/multimedia/TEMPLATES/
Disallow: /pages/college/
Disallow: /paidcontent/
Disallow: /partners/
Disallow: /reuters/
Disallow: /thestreet/

User-agent: Mediapartners-Google
Disallow:

Sitemap: http://spiderbites.nytimes.com/sitemaps/www.nytimes.com/sitemap.xml.gz
Sitemap: http://www.nytimes.com/sitemap_news.xml.gz
```

Robusthed

- Normalisering af URLer
- Parsning af malformet HTML
- Mange filtyper
- Forkert content-type fra server
- Forkert HTTP response code fra server
- Enorme filer
- Uendelige URL-løkker (crawler traps)
- ...

Vær konservativ – opgiv at finde alt
Crawling kan tage måneder

Designovervejelser - Crawling

- Startpunkt (initial *S*)
- Crawl-strategi (valg af *s*)
- Mærkning af besøgte sider
- Robusthed
- Ressourceforbrug (egne og andres ressourcer)
- Opdatering: Kontinuert vs. periodisk crawling

```
S = {startside}
repeat
    fjern en side s fra S
    parse s og find alle links (s, v)
    foreach (s, v)
        if v ikke besøgt før
            indsæt v i S
```

Output: **DB med besøgte dokumenter**
DB med links i disse (kanterne i Internetgrafen)
DB med DokumentID–URL mapning

Crawling Strategi ?

- Bredde først søgning
- Dybde først søgning
- Tilfældig næste *s*
- Prioriteret søgning, fx
  - Sider som opdateres ofte (kræver metode til at estimatere opdateringsfrekvens)
  - Efter vigtighed (kræver metode til at estimere vigtighed, fx PageRank)

```
S = {startside}
repeat
    fjern en side s fra S
    parse s og find alle links (s, v)
    foreach (s, v)
        if v ikke besøgt før
            indsæt v i S
```

Hvilken crawling strategi er bedst?

a) Bredde først søgning ("ringe i vandet")
b) Dybde først søgning ("søg i en labyrint")
c) Ved ikke

```
S = {startside}
repeat
    fjern en side s fra S
    parse s og find alle links (s, v)
    foreach (s, v)
        if v ikke besøgt før
            indsæt v i S
```

Hvilken crawling strategi er bedst?

a) Bredde først søgning ("ringe i vandet")
b) Dybde først søgning ("søg i en labyrint")
c) Ved ikke

```
S = {startside}
repeat
    fjern en side s fra S
    parse s og find alle links (s, v)
    foreach (s, v)
        if v ikke besøgt før
            indsæt v i S
```

Crawling : BFS virker godt

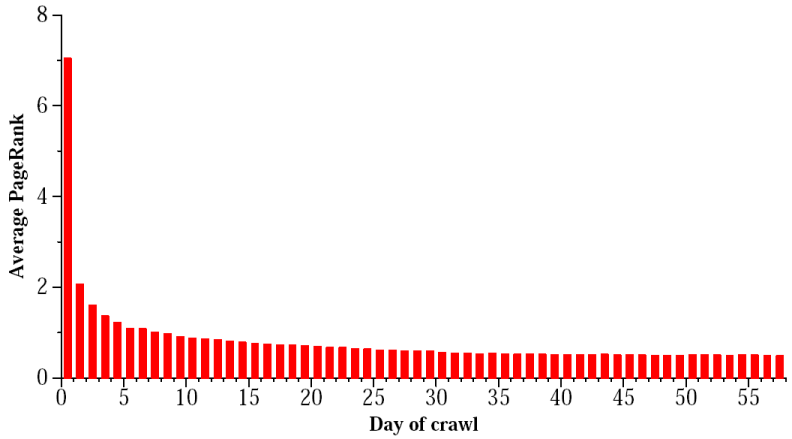

Figure 1: Average PageRank score by day of crawl

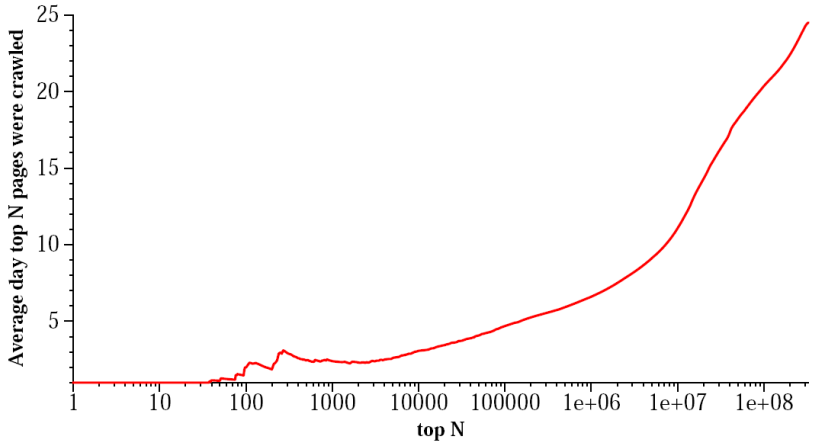

Figure 2: Average day on which the top N pages were crawled

Fra et crawl af 328 millioner sider [Najork & Wiener, 2001]

PageRank prioritet er endnu bedre

(men mere beregningstung. . .)

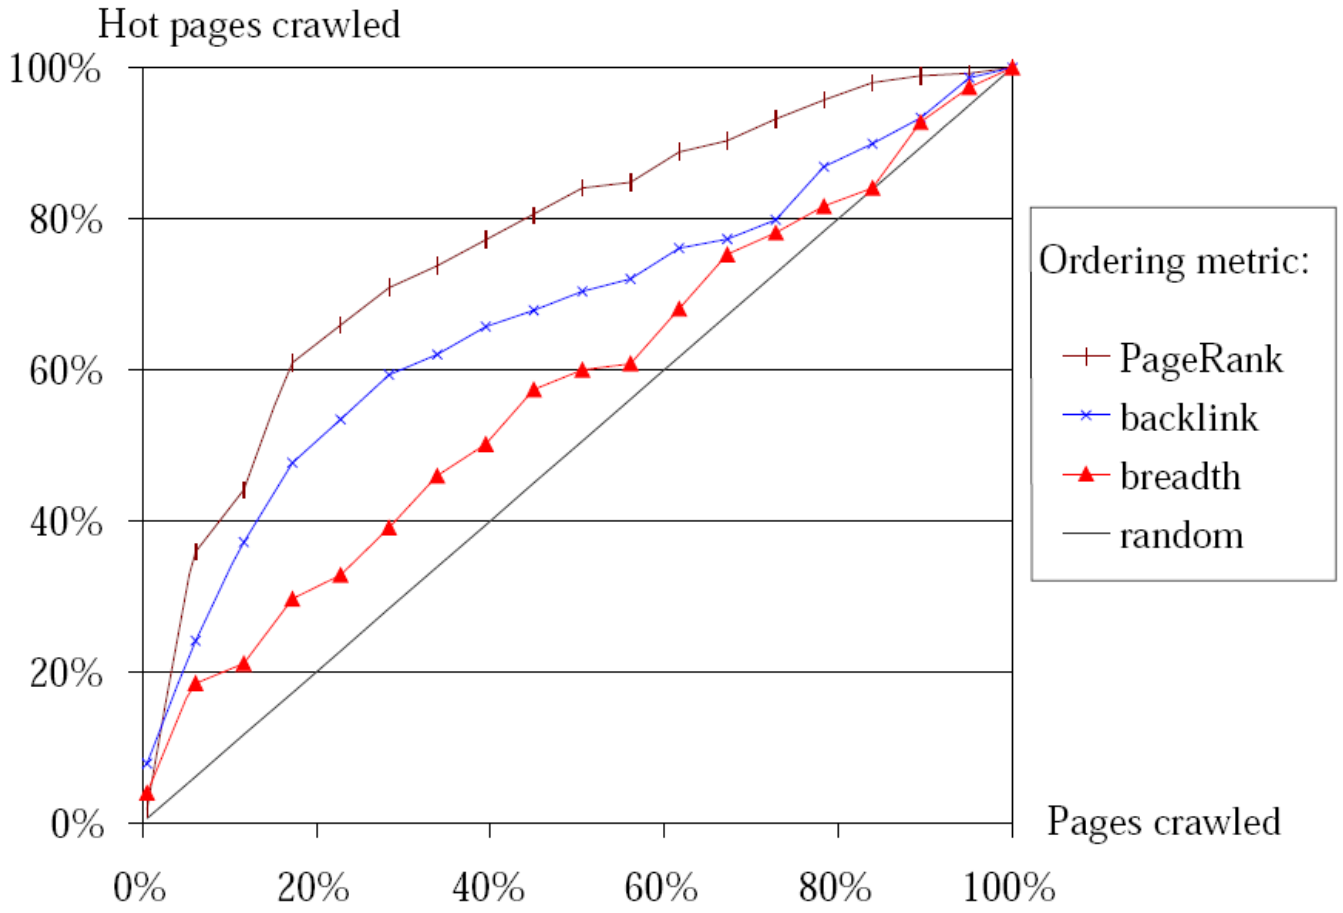

Crawl af 225.000 sider på Stanford Universitet [Arasu et al., 2001]

Resourceforbrug

- Egne resourcer
  - Båndbredde (global request rate)
  - Lagerplads (brug kompakte repræsentationer)
  - Distribuér på flere maskiner (opdel fx rummet af ULR'er)
- Andres resourcer (politeness)
  - Båndbredde (lokal request rate); tommelfingerregel: 30 sekunder mellem request til samme site.
- Robots Exclusion Protocol (www.robotstxt.org)
- Giv kontakt info i HTTP-request

Erfaringer ang. Effektivitet

- Brug caching (DNS opslag, robots.txt filer, senest mødte URL'er)
- Flaskehals er ofte disk I/O under tilgang til datastrukturerne
- CPU cycler er ikke flaskehals
- En tunet crawler (på een eller få maskiner) kan crawle 200-400 sider/sek 35 mio sider/dag

Indeksering

Indeksering af dokumenter

- Preprocessér en dokumentsamling så dokumenter med et givet søgeord kan blive returneret hurtigt

Input: dokumentsamling

Output: søgestruktur

Indeksering: Inverteret fil + leksikon

- **Inverteret fil** = for hvert ord *w* en liste af dokumenter indeholdende *w*
- **Leksikon** = ordbog over alle forekommende ord (nøgle = ord, værdi = pointer til liste i inverteret fil + evt. ekstra info for ordet, fx længde af listen)

For en milliard dokumenter:

Inverteret fil: totale antal ord 100 mia DISK

Leksikon: antal forskellige ord 2 mio RAM

Inverteret Fil

- Simpel (forekomst af ord i dokument):

  ord1: DocID, DocID, DocID

  ord2: DocID, DocID

  ord3: DocID, DocID, DocID, DocID, DocID, ...

  ...

- Detaljeret (*alle forekomster af ord i dokument):*

  ord1: DocID, Position, Position, DocID, Position ...

  ...

- Endnu mere detaljeret:

  Forekomst annoteret med info
  (heading, boldface, anker text,. . .)
  Kan bruges under ranking

Bygning af index

foreach dokument D i samlingen
    Parse D og identificér ord
    foreach ord w
        Udskriv (DocID, w)
        if w ikke i leksikon
            indsæt w i leksikon

(1, 2), (1, 37), … , (1, 123) , (2, 34), (2, 37), … , (2, 101) , (3, 486), …

Disk sortering (MapReduce)

(22, 1), (77, 1), . . . , (198, 1) , (1, 2), (22, 2), . . . , (345, 2) , (67, 3), . . .

Inverteret fil

Søgning

&

Ranking

“Life of a Google Query”

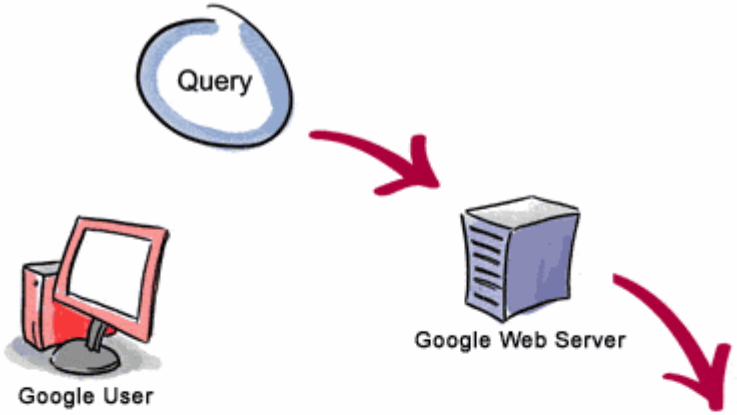

1. The web server sends the query to the index servers. The content inside the index servers is similar to the index in the back of a book - it tells which pages contain the words that match the query.

2. The query travels to the doc servers, which actually retrieve the stored documents. Snippets are generated to describe each search result.

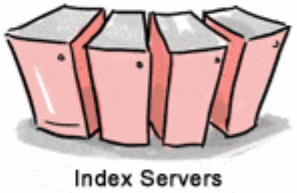

3. The search results are returned to the user in a fraction of a second.

www.google.com/corporate/tech.html

Søgning og Ranking

Søgning: unf AND aarhus

1. Slå **unf** og **aarhus** op i leksikon.
   Giver adresse på disk hvor deres lister starter.
2. Scan disse lister og "flet" dem (returnér DocID'er som er med i begge lister).

unf: 12, 15, 117, 155, 256, ...
aarhus: 5, 27, 117, 119, 256, ...

3. Udregn rank af fundne DocID'er. Hent de 10 højst rank'ede i dokumentsamling og returnér URL samt kontekst fra dokument til bruger.

OR og NOT kan laves tilsvarende. Hvis lister har ord-positioner kan frase-søgninger ("**unf aarhus**") og proximity-søgningner ("**unf**" tæt på "**aarhus**") også laves.

Tekstbaseret Ranking

- Vægt forekomsten af et ord med fx
  - Antal forekomster i dokumentet
  - Ordets typografi (fed skrift, overskrift, ...)
  - Forekomst i META-tags
  - Forekomst i tekst ved links som peger på siden
- Forbedring, men ikke nok på Internettet (rankning af fx 100.000 relevante dokumenter)
- Let at spamme (fyld siden med søge-ord)

Linkbaseret Ranking

- Idé 1: Link til en side ≈ anbefaling af den
- Idé 2: Anbefalinger fra vigtige sider skal vægte mere

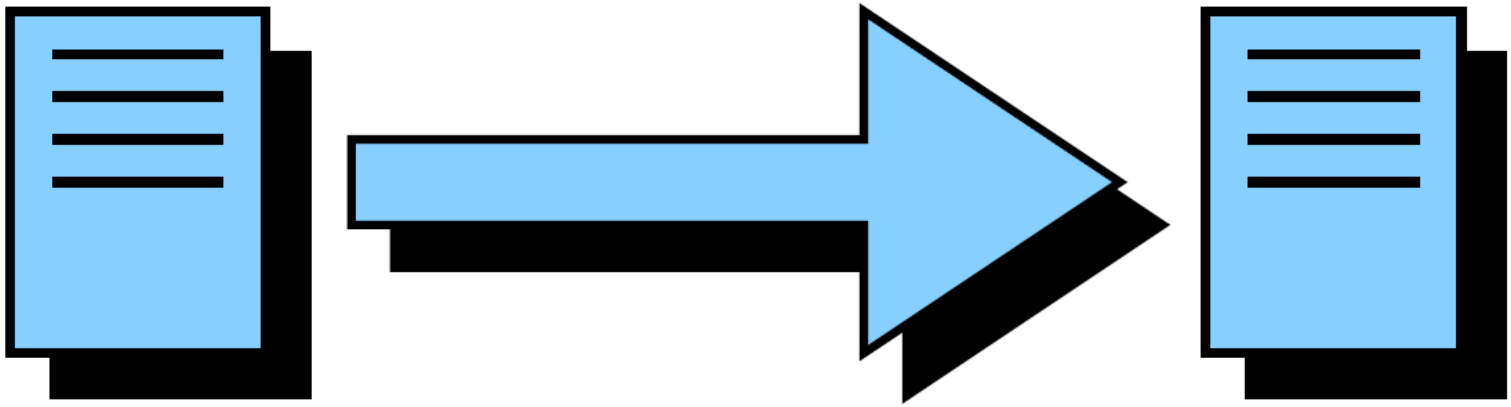

Google PageRank™ ≈ Websurfer

PageRank beregning kan opfattes som en websurfer som (i uendelig lang tid) i hver skridt

- med 85% sandsynlighed vælger at følge et tilfældigt link fra nuværende side,
- med 15% sandsynlighed vælger at gå til en tilfældig side i hele internettet.

PageRank for en side *x* er lig den procentdel af hans besøg som er til side *x*

Simpel Webgraf

Hvilken knude har størst ”rang” ?

a) 1
b) 2
c) 3
d) 4
e) 5
f) 6
g) Ved ikke

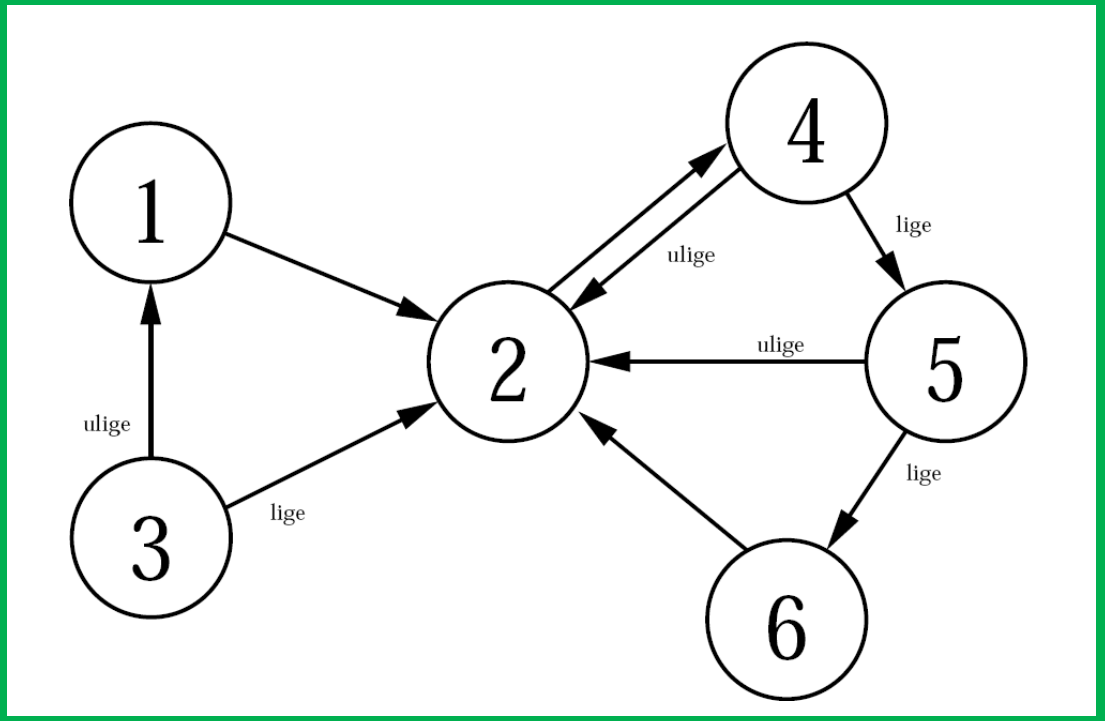

Simpel Webgraf

Hvilken knude har størst ”rang” ?

a) 1
b) 2
c) 3
d) 4
e) 5
f) 6
g) Ved ikke

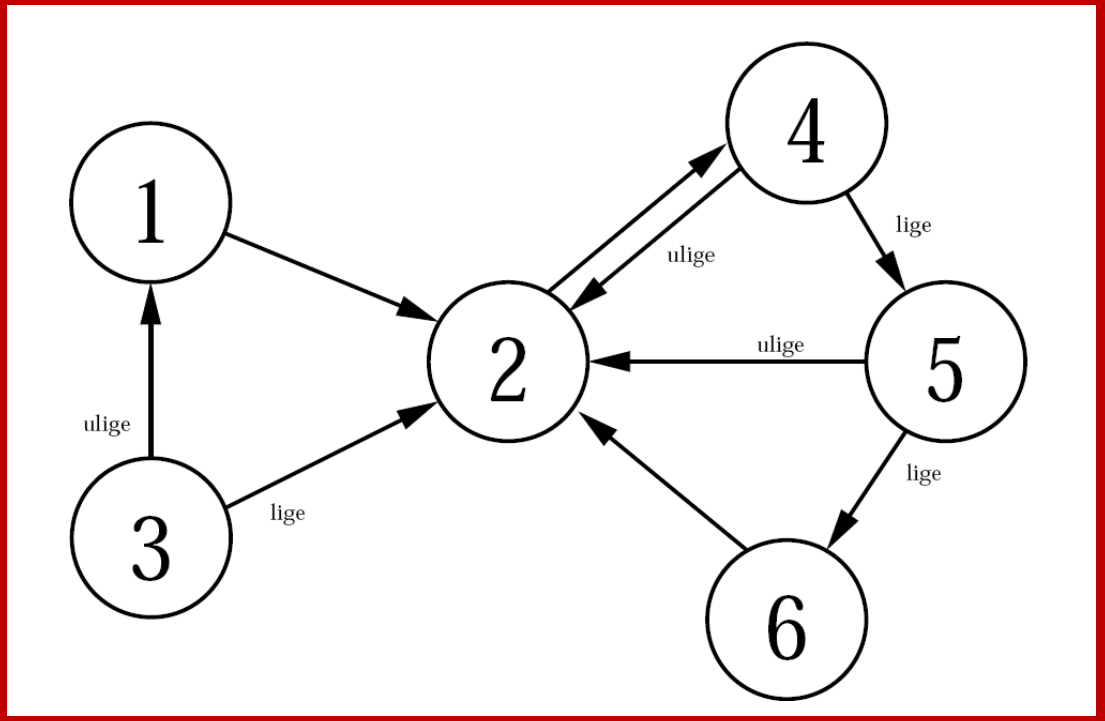

RandomSurfer

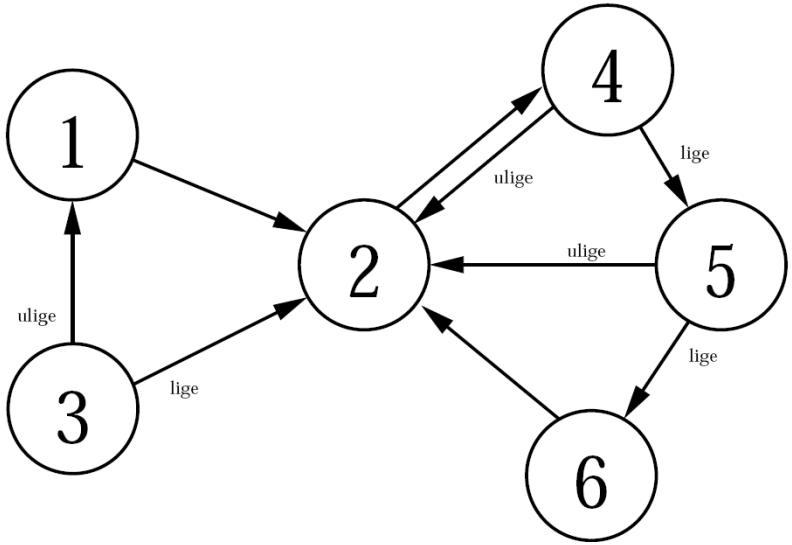

Metode RandomSurfer

Start på knude 1

Gentag mange gange:

    Kast en terning:

    Hvis den viser 1-5:

        Vælg en tilfældig pil ud fra knuden

        ved at kaste en terning hvis 2 udkanter

    Hvis den viser 6:

        Kast terningen igen og spring hen til den knude

        som terningen viser

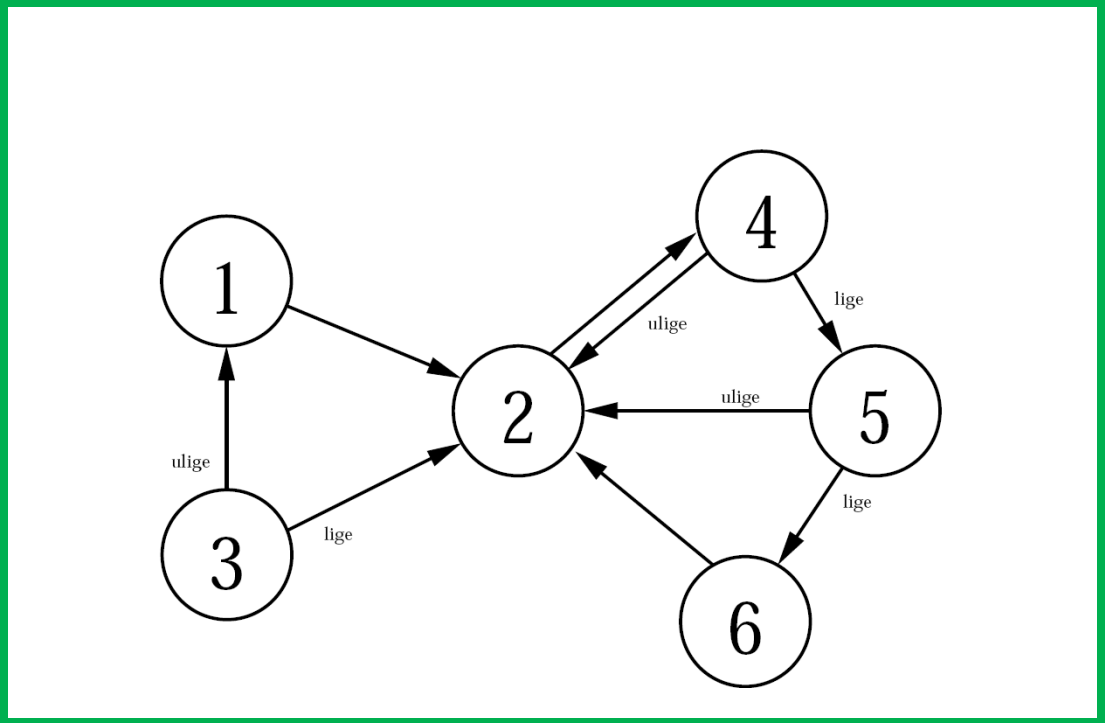

Metode RandomSurfer
Start på knude 1
Gentag mange gange:
    Kast en terning:
    Hvis den viser 1-5:
        Vælg en tilfældig pil ud fra knuden
        ved at kaste en terning hvis 2 udkanter
    Hvis den viser 6:
        Kast terningen igen og spring hen til den knude
        som terningen viser

I starten står man i "1" med sandsynlighed 1.0 og i "2-6" med sandsynlighed 0.0

Sandsynligheden for at stå i "2" efter ét skridt?

a) 1/6
b) 31/36
c) 5/6
d) 1.0
e) Ved ikke

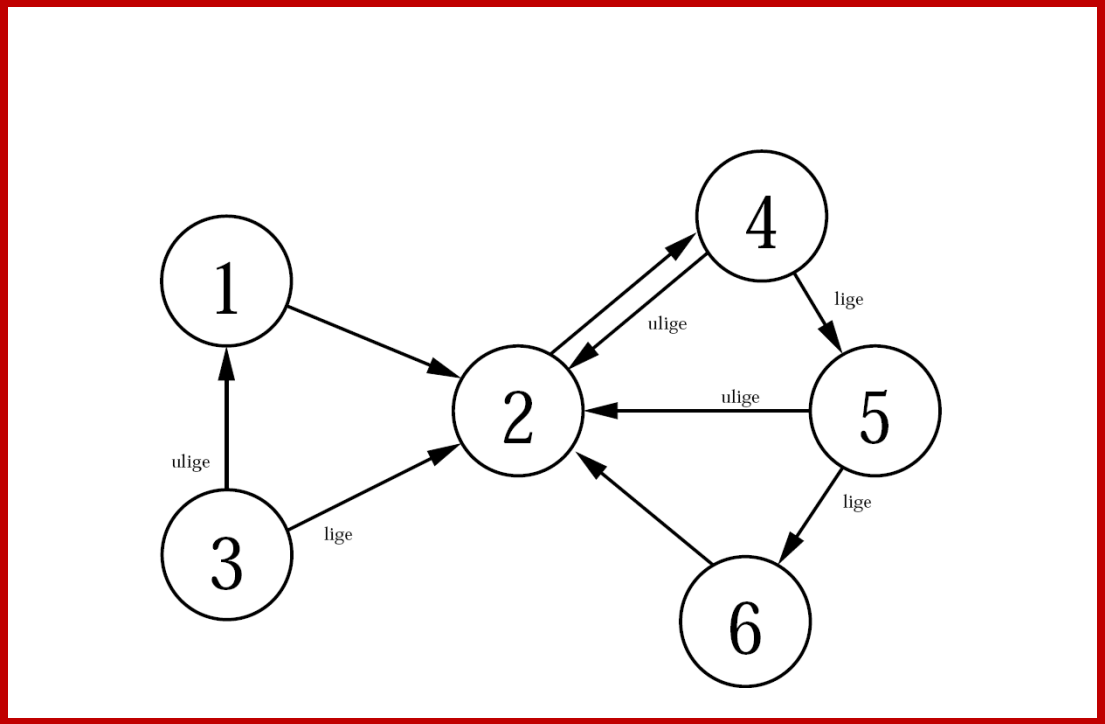

Metode RandomSurfer
Start på knude 1
Gentag mange gange:
    Kast en terning:
    Hvis den viser 1-5:
        Vælg en tilfældig pil ud fra knuden
        ved at kaste en terning hvis 2 udkanter
    Hvis den viser 6:
        Kast terningen igen og spring hen til den knude
        som terningen viser

I starten står man i "1" med sandsynlighed 1.0 og i "2-6" med sandsynlighed 0.0

Sandsynligheden for at stå i "2" efter ét skridt?

a) 1/6
b) 31/36
c) 5/6
d) 1.0
e) Ved ikke

Beregning af Sandsynligheder

Sandsynligheden for at stå i *i* efter *s* skridt:

$$p_i^{(s)} = \frac{5}{6} \sum_{j:\, j \to i} p_j^{(s-1)} \cdot \frac{1}{\text{udgrad}(j)} + \frac{1}{6} \cdot \frac{1}{6}$$

$$p_1^{(0)} = 1.0 \qquad p_2^{(0)} = \cdots = p_6^{(0)} = 0.0$$

Simpel Webgraf — Sandsynlighedsfordeling

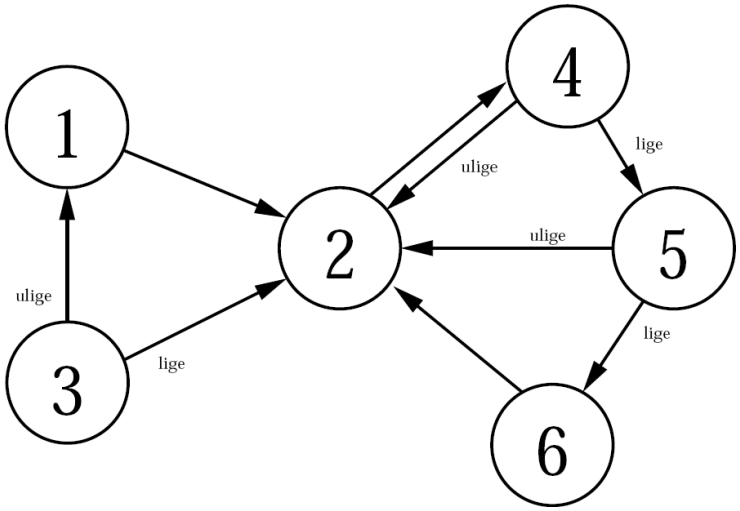

Skridt	1	2	3	4	5	6
0	1.000	0.000	0.000	0.000	0.000	0.000
1	0.028	0.861	0.028	0.028	0.028	0.028
2	0.039	0.109	0.028	0.745	0.039	0.039
3	0.039	0.432	0.028	0.118	0.338	0.044
4	0.039	0.299	0.028	0.388	0.077	0.169
5	0.039	0.406	0.028	0.277	0.189	0.060
6	0.039	0.316	0.028	0.366	0.143	0.107
7	0.039	0.373	0.028	0.291	0.180	0.087
8	0.039	0.342	0.028	0.339	0.149	0.103
9	0.039	0.361	0.028	0.313	0.169	0.090
10	0.039	0.348	0.028	0.329	0.158	0.098
11	0.039	0.357	0.028	0.318	0.165	0.094
12	0.039	0.351	0.028	0.325	0.160	0.096
13	0.039	0.355	0.028	0.320	0.163	0.094
14	0.039	0.352	0.028	0.323	0.161	0.096
15	0.039	0.354	0.028	0.321	0.163	0.095
16	0.039	0.353	0.028	0.323	0.162	0.095
17	0.039	0.354	0.028	0.322	0.162	0.095
18	0.039	0.353	0.028	0.322	0.162	0.095
19	0.039	0.353	0.028	0.322	0.162	0.095
20	0.039	0.353	0.028	0.322	0.162	0.095
21	0.039	0.353	0.028	0.322	0.162	0.095
22	0.039	0.353	0.028	0.322	0.162	0.095
23	0.039	0.353	0.028	0.322	0.162	0.095
24	0.039	0.353	0.028	0.322	0.162	0.095
25	0.039	0.353	0.028	0.322	0.162	0.095

Konvergens af PageRank

Hvor mange skridt skal man beregne sandsynlighedsfordelingen for, før den ikke ændrer sig, når der er milliarder af websider?

a) 10-20
b) 20-50
c) 50-100
d) 100-500
e) 500-1000
f) > 1000

Konvergens af PageRank

Hvor mange skridt skal man beregne sandsynlighedsfordelingen for, før den ikke ændrer sig, når der er milliarder af websider?

a) 10-20
b) 20-50
c) 50-100
d) 100-500
e) 500-1000
f) > 1000

Med sandsynlighed 0.9997 har man lavet et tilfældigt spring inden for de seneste 50 skridt

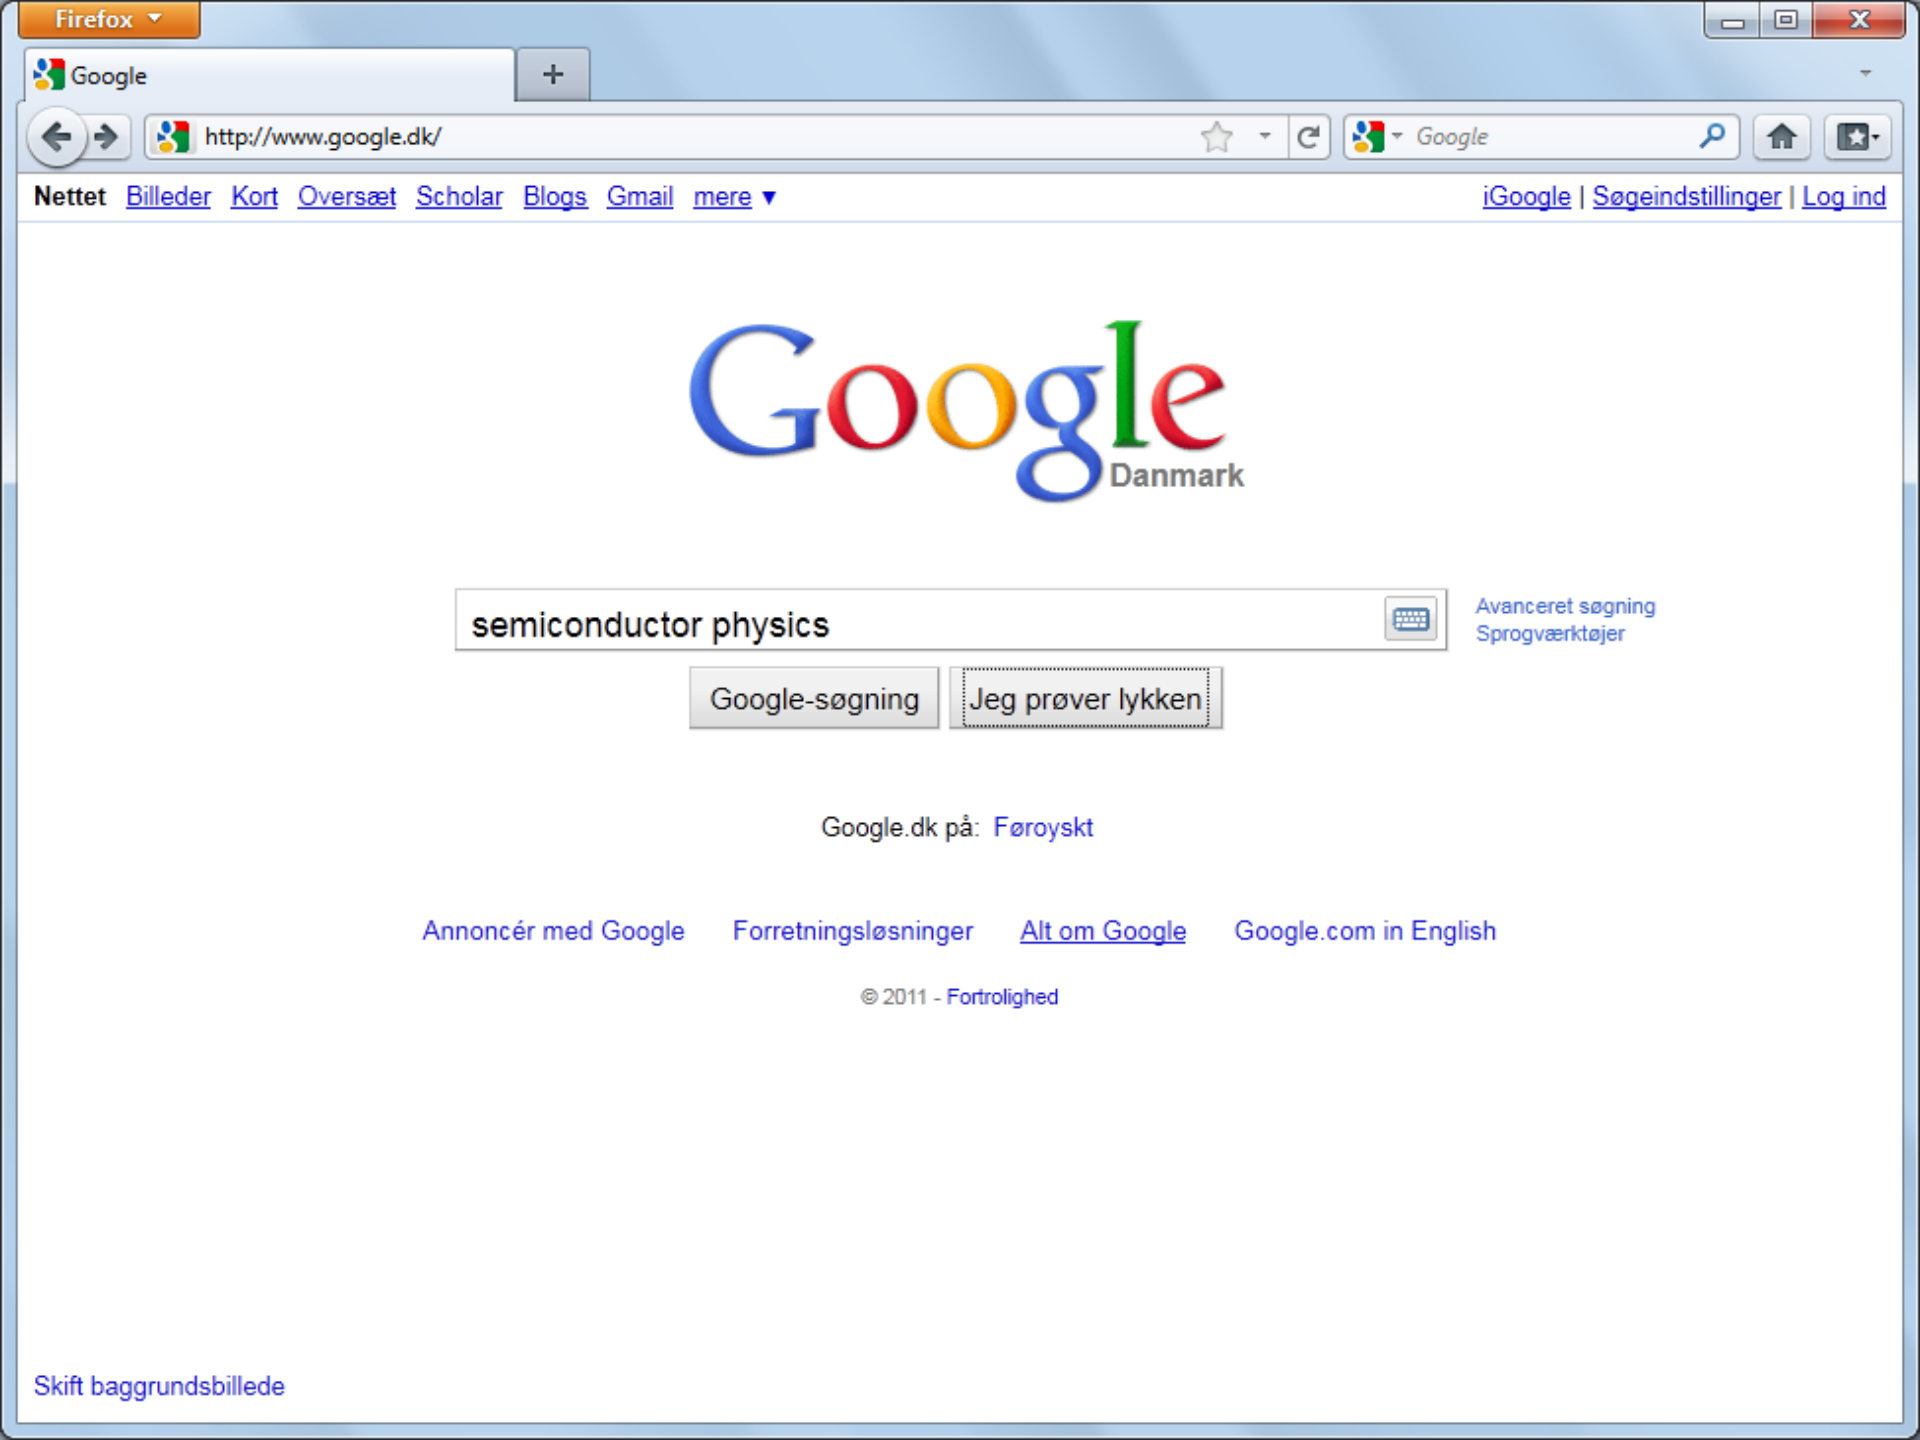
Firefox
Google
http://www.google.dk/
Google
Nettet Billeder Kort Oversæt Scholar Blogs Gmail mere ▾
iGoogle | Søgeindstillinger | Log ind
Google
Danmark
semiconductor physics
Avanceret søgning
Sprogværktøjer
Google-søgning
Jeg prøver lykken
Google.dk på: Føroyskt
Annoncér med Google
Forretningsløsninger
Alt om Google
Google.com in English
© 2011 - Fortrolighed
Skift baggrundsbillede

Britney Spears' Guide to Semiconductor Physics

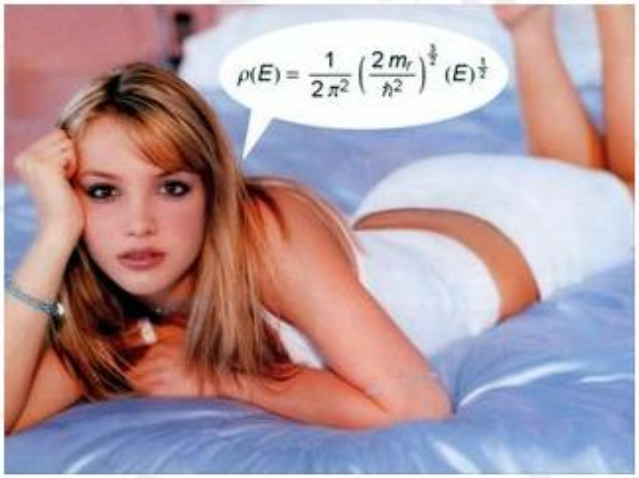

It is a little known fact, that Ms Spears is an expert in semiconductor physics. Not content with just singing and acting, in the following pages, she will guide you in the fundamentals of the vital semiconductor laser components that have made it possible to hear her super music in a digital format.

* Introduction
* Vertical Cavity Surface Emitting Lasers (VCSELs)

Søgemaskine Optimering

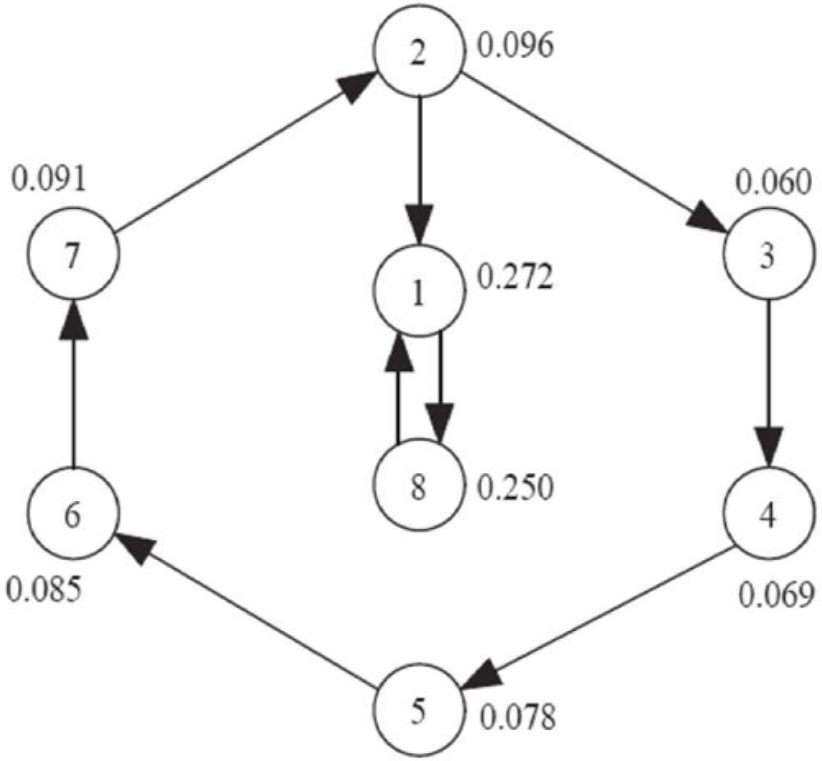

(a) The original graph.

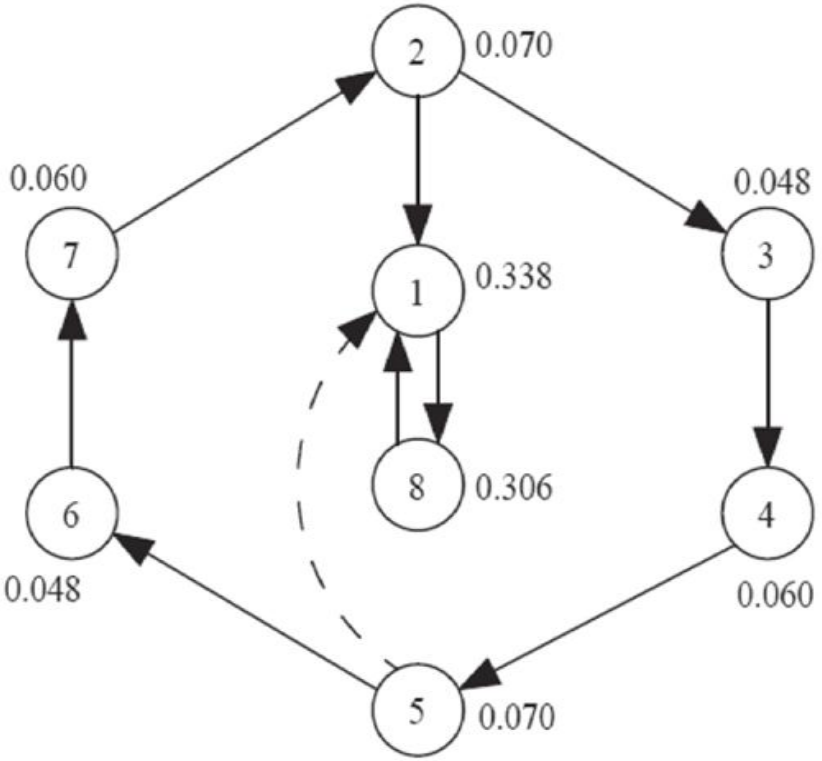

(b) One optimal new link.

Martin Olsen, ph.d. afhandling, august 2009

Søgemaskine Optimering

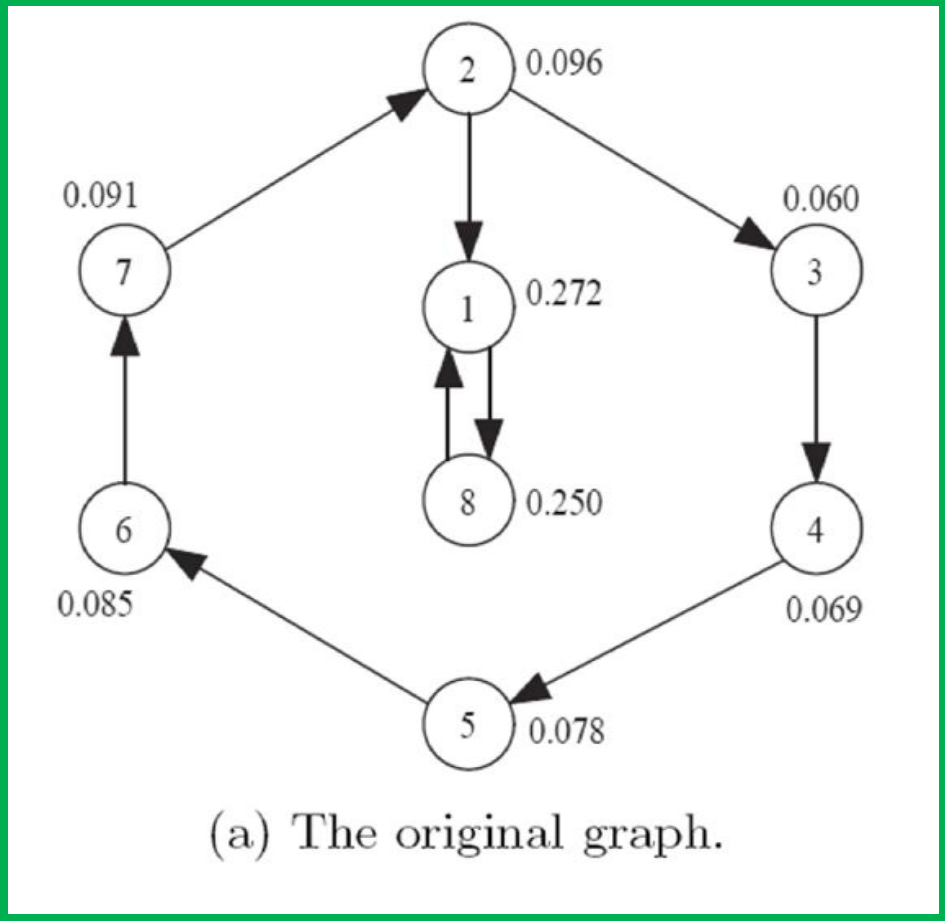

(a) The original graph.

Hvilke **to** kanter skal man tilføje for at maksimere ”1”s PageRank ?

a) (6,1) og (7,1)
b) (5,1) og (7,1)
c) (6,1) og (5,1)
d) (6,1) og (4,1)
e) Ved ikke

Martin Olsen, ph.d. afhandling, august 2009

Søgemaskine Optimering

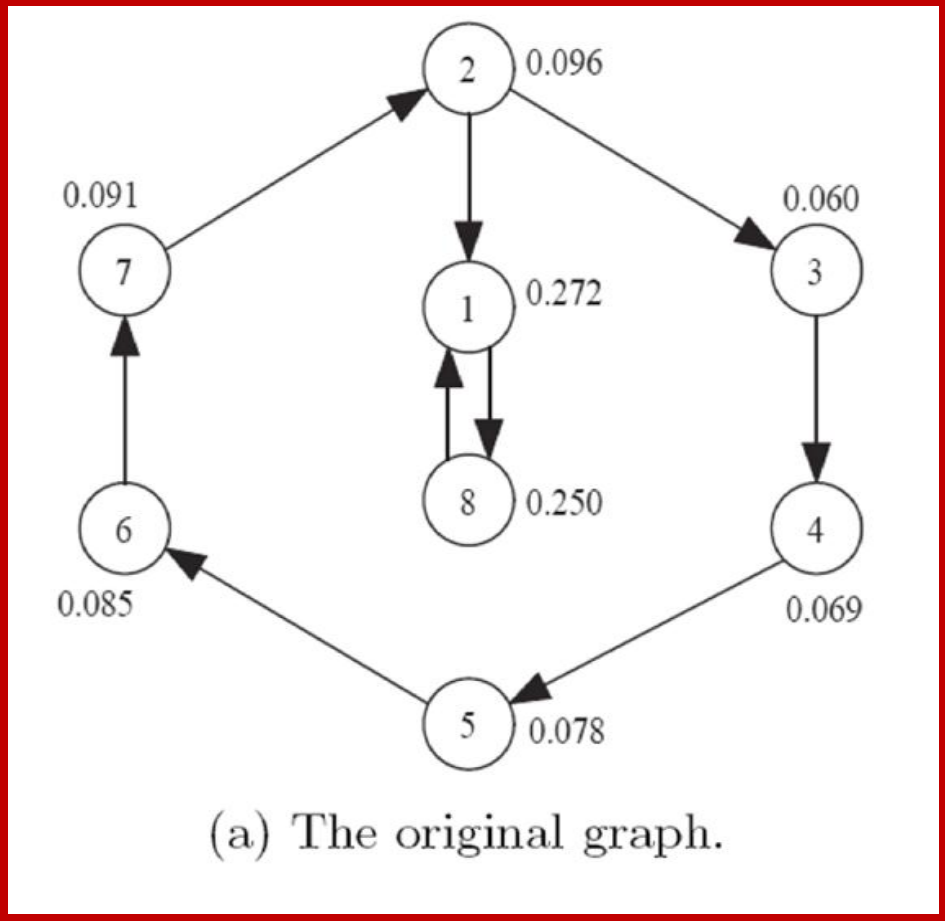

(a) The original graph.

Hvilke to kanter skal man tilføje for at maksimere "1"s PageRank ?

a) (6,1) og (7,1)
b) (5,1) og (7,1)
c) (6,1) og (5,1)
d) (6,1) og (4,1)
e) Ved ikke

Søgemaskine Optimering

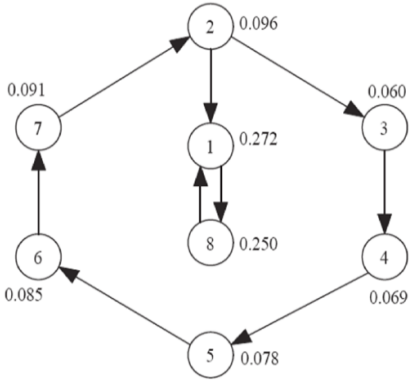

(a) The original graph.

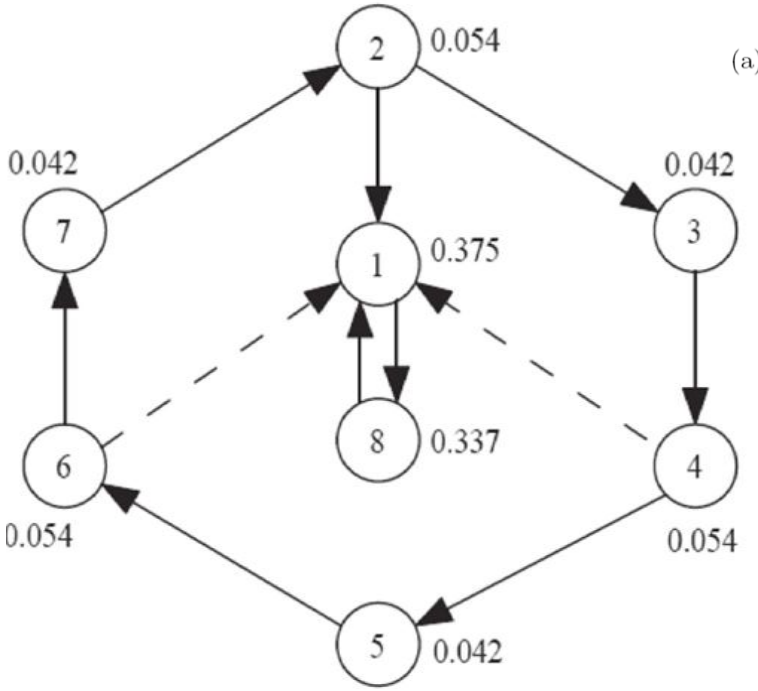

(c) Two optimal new links.

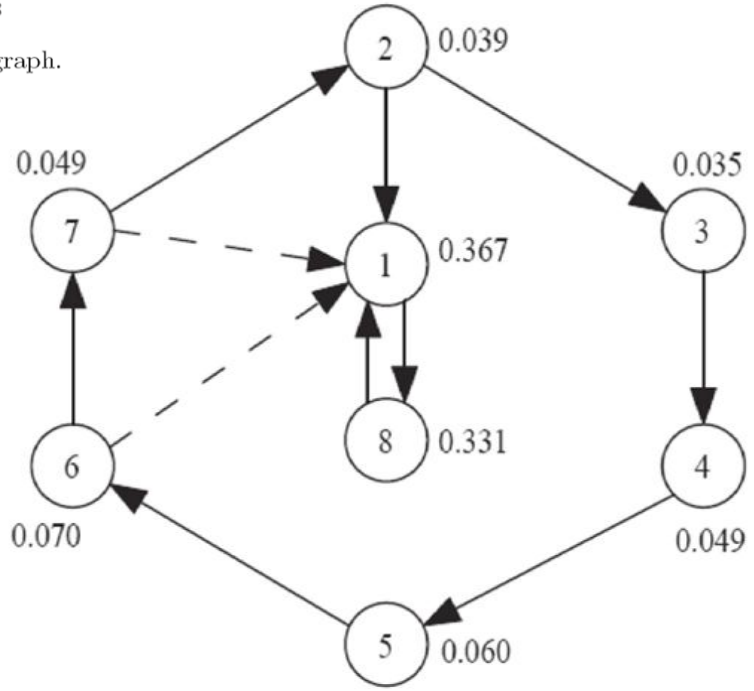

(d) Two new links from the most popular nodes prior to the modification.

Martin Olsen, ph.d. afhandling, august 2009

Søgemaskine Optimering (SEO)

- Mål: Optimer websider til at ligge højt på søgemaskiner
- Metoder: Lav nye websider der peger på en side, bytte links, købe links, lave blog indlæg, meta-tags, ...
- SEO: Milliard industri
- Søgemaskiner: Blacklisting, fjernelse af dubletter, ...

SAS-hoteller sortlistet efter Google-fusk

Verdens mest populære søgemaskine, Google, har boykottet SAS-koncernens nordiske hoteller og konferencecentre, efter de har brugt skjulte websider til at opnå en god placering i søgeresultaterne. Metoden er udviklet af danske Netpointers, som risikerer en bombe under sit forretningsgrundlag.

www.computerworld.dk, 9. november 2004

Gør-det-selv

Programmeringsprojekt i kurset
Algorithms for Web Indexing and Searching
(Gerth S. Brodal, Rolf Fagerberg), efteråret 2002

- Projekt: Lav en søgemaskine for domæne .dk
- 15 studerende
- 4 parallelt arbejdende grupper (crawling, indexing, PageRank, søgning/brugergrænseflade)
- Erfaring: Rimmelig vellykket søgemaskine, hvor rankningen dog kræver yderligere finjustering...

Referencer

- Arvind Arasu, Junghoo Cho, Hector Garcia-Molina, Andreas Paepcke, and Sriram Raghavan, *Searching the Web. ACM Transactions on Internet Technology*, 1, p. 2-43, 2001.
- Sergey Brin and Larry Page, *The Anatomy of a Search Engine, 1998.* http://www-db.stanford.edu/pub/papers/google.pdf
- Monika Rauch Henzinger, *Web Information Retrieval. Proceedings of the 16th International Conference on Data Engineering*, 2000.
- Marc Najork and Allan Heydon, *High-Performance Web Crawling.* Compaq SRC Research Report 173.
- Marc Najork and Janet L. Wiener, *Breadth-First Search Crawling Yields. In Proceedings of the Tenth Internal World Wide Web Conference*, 114-118, 2001.
- Martin Olsen, *Link Building. Ph.d. afhandling, Datalogisk Institut,* Aarhus Universitet, august 2009.