



Univerzitet u Beogradu, Elektrotehnički fakultet



WEB PRETRAŽIVANJE

Miloš Pavković

Decembar, 2017

SADRŽAJ KURSA

- Motivacija, uvod u taksonomija i anatomsiju Veb pretraživača.
- Problemi prilikom implementacije.
- Paralelizacija pretraživanja.
- Ponovno pretraživanje sajta.
- Specijalizovani/fokusirani pretraživači.
- Optimizacija pretraživanja od strane sajta.

UVOD

Google elektrotehnicki fakultet

All Images Maps News Videos More Settings Tools

About 115,000 results (0.53 seconds)


ETF-u - Београд - Универзитет у Београду
www.etf.bg.ac.rs/ ▾ Translate this page
Навигација. Почетна; Факултет - О Факултету; Руководство; Савет факултета; Наставно-научно веће; Изборно веће; Катедре; Публикације; Пројекти; Акта факултета; Зграде факултета; Партери факултета; Алумни и пријатељи; Контакт · Студирање · Основне академске студије; Мастер ...
Електротехнички факултет · Основне академске студије · Etf prijemni · Упис

ETF
[www.etf.bg.ac.rs/index.php?lang=sl](http://www.etf.bg.ac.rs/index.php?lang=sr) ▾ Translate this page
Instaliran je novi digitalni sertifikat! Da biste mogli bez problema da pristupate mail serveru (kao i drugim zaštićenim ETF-ovim serverima) molimo instalirajte ...

Univerzitet u Beogradu, Elektrotehnički fakultet - Akta fakulteta
www.etf.bg.ac.rs/ ▾ Fakultet ▾ Translate this page
Akta Fakulteta. Pravilnik o udžbenicima i drugoj nastavnoj literaturi [11.12.2007.] Pravilnik za praćenje, obezbeđivanje, unapredjenje i razvoj kvaliteta studijskih ...

Elektrotehnički fakultet u Beogradu | Upis, prijemni - Fakulteti / edukacija
fakulteti.edukacija.rs/...fakulteti/.../elektrotehnicki-fakultet-u-beogr... ▾ Translate this page
Elektrotehnički fakultet - Beograd. Prijemni ispit, školarina, smerovi, testovi za prijemni, upis, broj mesta, bodovi... Upis na ETF u Beogradu...

Rezultati prijemnog - Elektrotehnički fakultet Beograd
fakulteti.edukacija.rs/...fakultetima/elektrotehnicki-fakultet-beograd ▾ Translate this page
Rezultati prijemnog ispita na Elektrotehničkom fakultetu u Beogradu. Pogledajte rang-liste kandidata i bodove za svaki smer na Elektrotehničkom fakultetu.



The screenshot shows the Google search results for the query "elektrotehnicki fakultet". The top result is for the University of Belgrade Faculty of Electrical Engineering. It includes a logo, a map showing its location near the Nikola Tesla Museum, and a snippet of text describing it as a public university in Belgrade, Serbia. Below this, there are other search results for the Faculty of Electrical Engineering at the University of Belgrade, including links to their website and directions.

Q: Kako pretraživač zna da svi ovi sajtovi i strane sadrže traženu ključnu reč?

A: Zato što su sve te strane prvobitno indeksirane i parsirane uz pomoć Veb pretraživača

UVOD

- Definicija Veb pretraživača:
 - Veb pretraživač je kompjuterski program koji pretražuje internet mrežu na metodički, automatizovan način.
- Primena:
 - Prikupljanje stranica sa interneta.
 - Podrška globalnim pretraživačima kao što su Google, MSN i sl.
- Cilj:
 - Prikupiti sa stranica tekst, video, slike i sl.
 - Preko linkova i povezanosti strana rekonstruišu strukturu Veb sajta.


MOTIVACIJA

- U upotrebi kod svih značajnijih pretraživača (Google, Yahoo, MSN, Ask, itd.).
- Vertikalni (specijalizovani, fokusirani) pretraživači za vesti, kupovinu, dokumenta, korisnički generisan sadržaj itd.
- Biznis inteligencija, digitalno istraživanje javnog mnjenja, praćenje vremenskih nepogoda, epidemija (WHO).
- Praćenje Veb sajtova od interesa.
- Prikupljanje podataka (spamming, phishing...).


RAZLIČITI NAZIVI VEB PRETRAŽIVAČA

- Crawler
- Spider
- Robot (ili samo bot)
- Web agent
- Wanderer, worm, ...
- I čuvene instance: googlebot, scooter, slurp, msnbot, ...

TAXONOMIJA WEB PRETRAŽIVAČA



ANATOMIJA VEB PRETRAŽIVAČA




- Klasičan sekvencijalni pretraživač.
- SEED može biti bilo koja lista početnih URL-a.
- Redosled posećivanja stranica određuje 'frontier'.
- Svi novi nađeni URLovi se stavljaju u 'frontier' ako prethodno nisu bili posećeni.
- Posećene strane se smeštaju u repozitorijum.
- STOP kriterijum može biti bilo šta

PROLAZAK KROZ STRUKTURU WEB SAJTA (BFS ILI DFS)


■ Obilazak po širini

- Implementiran uz pomoć FIFO reda.
- Pronalazi prvo strane najbliže ulazu sajta – najprioritetnije.
- Ako za početak izaberu ‘dobre’ strane, velika je šanse da će ostale strane takođe biti ‘dobre’.



■ Obilazak po dubini

- Implementiran uz pomoć LIFO reda.
- Uglavnom se koristi kod specijalizovanih pretraživača.
- Može da odluta (lost in cyberspace).



PSEUDO KOD PRETRAŽIVAČA PO ŠIRINI NAPISAN U PERLU

```
my @frontier = read_seeds($file);
while (@frontier && $tot < $max) {
    my $next_link = shift @frontier;
    my $page = fetch($next_link);
    add_to_index($page);
    my @links = extract_links($page, $next_link);
    push @frontier, process(@links);
}
```

PROBLEMI PRILIKOM IMPLEMENTACIJE

- Prikupljanje duplih stranica:
 - Čuvanje indeksa već prikupljenih stranica, što kroz tabelu što implementacijom HASH funkcija.
 - Takođe treba obratiti pažnju na strane koje još nisu posećene, a nalaze u frontieru.
- Rast frontiera:
 - Rešenje: prioritizacija. Algoritmi koji daju prioritet jednim stranama u odnosu na druge.
- Modul za preuzimanje strana mora biti robustan:
 - Otporan na neuspelo preuzimanje strane, timeout mehanizam 404 greške i sl.
- Određivanje tipa fajla pre preuzimanja.


PROBLEMI PRILIKOM IMPLEMENTACIJE (PREUZIMANJE)

- Preuzimanje prvih 10KB do 250KB strane. Sve preko se naknadno preuzima ako ima potrebe.
- Menadžment *loop* linkova i linkova koji redirektuju. Po potrebi se ugrađuje *break* uslov.
- Obezediti nastavak pretrage posle grešaka kao što su:
 - timeout
 - server not responding
 - file not found, i sl.

PROBLEMI PRILIKOM IMPLEMENTACIJE (PARSIRANJE)

- HTML je strukturno uređeno DOM stablo.
- Genirsano DOM HTML stablo na sajtu nije uvek tačno u smislu semantike.
- Pretraživači, isto kao i pregledači, moraju da 'opraštaju' greške.
- Postoje i gotovi alati koji vrlo dobro mogu da izadju na kraju sa lošim HTML kodom. Npr. - tidy.sourceforge.net.

```
<html>
  <head>
    <title>Here comes the DOM</title>
  </head>
  <body>
    <h2>Document Object Model</h2>
    
    <p>
      This is a simple
      <code>HTML</code>
      page to illustrate the
      <a href="http://www.w3.org/DOM/">DOM</a>
    </p>
  </body>
</html>
```



PROBLEMI PRILIKOM IMPLEMENTACIJE (LINKOVI)

- Apsolutni VS. Relativni

- Svaki pretraživač mora da prevede relativne linkove u absolutne.
- Pretraživač mora da dohvati 'Base URL' Veb sajta ili iz HTTP hedera, ili `<base>` taga zapisanog u HTML kodu.
- Primer ako je base url: <http://www.cnn.com/linkto/>
 - Relative URL: `intl.html`
 - Absolute URL: `http://www.cnn.com/linkto/intl.html`
 - Relative URL: `/US/`
 - Absolute URL: `http://www.cnn.com/US/`

PROBLEMI PRILIKOM IMPLEMENTACIJE (URL KANONIZACIJA)

- Linkovi kao što su:
 - <http://www.cnn.com/TECH>
 - <http://WWW.CNN.COM/TECH/>
 - <http://www.cnn.com:80/TECH/>
 - <http://www.cnn.com/bogus/..//TECH/>
- Svi odgovaraju jednoj kanonskoj formi: <http://www.cnn.com/TECH/>
- Da bi pretraživač izbegao duplike svi linkovi moraju biti kanonizovani.
- Link koji sadrži port se pamti isključivo ako je port podrazumevani :80

PROBLEMI PRILIKOM IMPLEMENTACIJE (URL KANONIZACIJA)

■ Neke transformacije su trivijalne ali se moraju poštovati:

- ✗ <http://informatics.indiana.edu>
- ✓ <http://informatics.indiana.edu/>

- ✗ <http://informatics.indiana.edu/index.html#fragment>
- ✓ <http://informatics.indiana.edu/index.html>

- ✗ <http://informatics.indiana.edu/dir1/../../dir2/>
- ✓ <http://informatics.indiana.edu/dir2/>

- ✗ <http://informatics.indiana.edu/%7Efil/>
- ✓ <http://informatics.indiana.edu/~fil/>

- ✗ <http://INFORMATICS.INDIANA.EDU/fil/>
- ✓ <http://informatics.indiana.edu/fil/>

OPTEREĆENJE

- Bitno je paziti kako se Veb sajt pretražuje u potrazi za stranama.
- Cloudflare zaštita (CDN, DNS, DDoS) – sajt će vas blokirati ako ga preopteretite.
- Nasumično vreme preuzimanja strane.
- Slučajno izabrane strane.
- Nasumične strane na nasumičnih sajtova.
- Promena IP adresa odakle se vrši pretraga - VPN, TOR.
- Automatsko logovanje i simulacija korisnika (nije preporučljivo).

PARALELIZACIJA - MOTIVACIJA


- Skalabilnost – zbog velikog sadržaja interneta pa i samih sajtova, od imperativa je paralelizovati pretraživanje i ubrzati proces prikupljanja. Više procesa može da pretražuje jedan sajt.
- Disperzija opterećenja mreže – procesi mogu da se izvršavaju na geografski različitim lokacijama.
- Redukcija opterećenja mreže – pretraživač na jednoj geografskoj lokaciji ne treba da pretražuje udaljene sajtove. Na ovaj način se ne opterećuje mreža kroz koje prolaze zahtevi.

PARALELIZACIJA - PROBLEMI

- Preklapanje – različiti procesi mogu da prikupe iste strane. Jedan proces mora biti svestan šta su drugi prikupili u međuvremenu.
- Kvalitet – odluka o prioritetnim stranama se teže donosi. Jedan proces ne može biti na pravi način svestan ‘slike’ celog sajta.
- Opterećenje intra-proces mreže – da bi se poboljšao kvalitet strana i sprečilo preklapanje, procesi moraju da komuniciraju između sebe. Što veći broj procesa i strana koje se preuzimaju, veće je opterećenje mreže kroz koji procesi komuniciraju.


PARALELIZACIJA – ARHITEKTURA

- Paralelni pretraživač mora da se sastoji od više procesa koji obavljaju identični posao
- Svaki proces treba da preuzme stranu sa Veb sajta, ekstrahuje linkove, i skladišti preuzetu stranu u bazu.
- U zavisnosti kako se preuzeti linkovi raspoređuju kasnije između procesa, razlikujemo intra-site paralelne pretraživače i distribuirane pretraživače.




PARALELIZACIJA – INTRA-SITE PRETRAŽIVAČ

- Kada svi procesi rade na jednoj lokalnoj mreži.
- Komunikacija se obavlja preko brze lokalne infrastrukture.
- U ovom slučaju opterećenje mreže prilikom razmene informacija je centralizovano.




PARALELIZACIJA – DISTRIBUIRANI PRETRAŽIVAČ

- Kada svi procesi rade na geografski udaljenim lokacijama i povezani su preko interneta.
- Ovakvi distribuirani potraživači pomažu pri rasterećenju mreže i disperziji pretraživanja.
- Problem prilikom odluke kada treba komunicirati i kojom frekvencijom.




PARALELIZACIJA – NEZAVISNI PROCESI

- Svaki proces sam odlučuju koje strane će da preuzme.
- Ovo može biti urađeno sa ili bez konsultacije sa ostalim procesima.
- Što manje koordinacije, veći broj preklapanja ali znatno rasterećenija mreža.
- Veća komunikacija opterećuje procese pa samim tim i usporava pretragu.
- Potrebno je balansirati između brzine i kvaliteta prikupljenih podataka.




PARALELIZACIJA – CENTRALIZOVANA KOORDINACIJA

- Takođe se naziva i dinamički mod.
- Strane su logički particionisane i raspoređene procesima od strane glavnog procesa-servera.
- Procesi parsiraju linkove sa preuzete strane i vraćaju podatke glavnom koordinatoru.
- Sporije pretraživanje zbog frekventne komunikacije sa glavnim koordinatorom.
- Smanjen broj duplih stranica.




PARALELIZACIJA – STATIČKI MOD RADA

- Procesima se samo u startu podele logički partitionisani delovi sajta ili veb prostora koji treba da se pretraži.
- Proc1:
<http://informatics.indiana.edu/dir1/>
Proc2:
<http://informatics.indiana.edu/dir2/>
- Nema potrebe za centralnim koordinatorom i međusobnom koordinacijom sem na početku.
- Problem sa linkovima koji vode u domen drugih procesa.




PARALELIZACIJA – STATIČKI MOD RADA (FIREWALL MODE)

- Procesi ignoriraju linkove koji vode van njihovih partitionisanih domena.
- linkovi $c \rightarrow g$, $a \rightarrow g$, $h \rightarrow d$ se ignoriraju pa samim tim nema potrebe za koordinatorom.
- Nema preklapanja ni opterećenja.
- Strane kao što su e i d nije moguće dohvatiti iz istog domena, pa ostaju ne pretražene.




PARALELIZACIJA – STATIČKI MOD RADA (CROSS-OVER MODE)

- Procesi prvo obidu sve strane svog domena, pa tek onda izlaze van njega.
- Na ovaj način proces C_1 može da dohvati strane d i e preko domena procesa C_2 .
- Postoji preklapanje i neke strane se preuzimaju duplo.
- Ograničavanje procesa na koliko drugih domena je dozvoljeni preći i koliko strana van svog domena sme da pretraži pre nego što se zaustavi.



PARALELIZACIJA – STATIČKI MOD RADA (EXCHANGE MODE)

- Procesi periodično razmenjuju informacije sa drugim procesima o linkovima koji vode na njihov domen, ali ih ne prate.
- Proces C_1 informiše proces C_2 o postojanju linka $c \rightarrow g$ i $a \rightarrow g$. C_2 informiše C_1 o $h \rightarrow d$.
- Sve strane domena procesa bivaju obiđene.
- Minimalna komunikacija između procesa i minimalno opterećenje mreže.



PONOVNO PRETRAŽIVANJE SAJTA

- Posle nekog vremena potrebno je posetiti sajt u potrazi za novim sadržajem.
- Sadržaj na starim stranama se možda izmenio.
- Neke strane više ne postoje.
- Nova strane su dodate i potrebno ih je pronaći.

PONOVNO PRETRAŽIVANJE SAJTA

- Postoje dva moda pretraživanja sajta. Inicijalno i ponovno.
- Inicijalno pretraživanje - kada se sajt posećuje prvi put i sve strane se indeksiraju.
- ponovno pretraživanje - kada se posle određenog vremena ponovo posećuju strane sajta u potrazi za novim ili izmenjenim sadržajem.
- Problem – frekvencija posete i procena izmene na stranama.

NAČINI PONOVNOG PRETRAŽIVANJA SAJTA


- Periodični i Inkrementalni.
- Periodični pretraživač posle određenog vremena ponovo obilazi kompletan sajt i stare strane zamenjuje novim.
- Inkrementalni konstanto posećuje bitne strane i ažurira bazu - 'Batch-mode' i 'Steady' modovi pretraživanja.
- Inkrementalni su bolji u situaciji gde se samo određene strane menjaju. Ovo doprinosi boljem čuvanju protoka i bržem otkrivanju novih strana.
- Periodični pretraživač otkriva nove strane tek kada poseti ponovo ceo sajt, što u većini slučajeva nije efikasno.

BALANSIRANJE IZMEĐU POKRIVENOSTI I SVEŽINE

- Coverage & Freshness – dva najbitnija faktora pri inkrementalnom pretraživanju.
- Proceniti životni vek strane i sadržaja na strani. Koliko se često sadržaj menja. Koliko često se dodaju nove stranice a stare brišu.
- Veća pokrivenost i traženje novih strana smanjuje broj poseta postojećim stranama.
- Većom pokrivenošću se smanjuje svežina sadržaja.
- Inkrementalni pretraživač mora da balansira između pokrivenosti i svežine.


'BATCH-MODE' INKREMENTALNI PRETRAŽIVAČ

- Batch-mode pretraživač periodično posećuje strane u određenim vremenskim intervalima.
- Kada procenjena vrednost svežine baze opadne, inicijalizuje se nova pretraga.



“‘STEADY’ INKREMENTALNI PRETRAŽIVAČ.

- ‘Steady’ pretraživač konstantno posećuje sajt.
- Nove stane se otkrivaju i stari sadržaj se zamenjuje novim u bazi.
- Prosečna svežina stranica je ista kao i kod ‘batch’ modela.
- ‘Steady’ model ima prednost jer posećuje sajt manjom brzinom i samim tim manje opterećuje mrežu.



PRIKUPLJANJE NOVOG SADRŽAJA

- Shadowing i In-Place.
- Shadowing – tehnika gde se sav novi sadržaj prvo sakupi odvojeno, pa se na kraju kopira preko starog od jednom.
- In-Place – tehnika gde preko starog sadržaja odmah presnimi novi čim se na njega nađe.
- Shadowing tehnika omogućava da se trenutni sadržaj zaštitи o samog procesa pretraživanja i trenutnih nepravilnosti koji mogu da se dese kod povezanih informacija između strana. Odgovara najviše 'batch' modu.
- In-Place tehnika omogućuje da se novi sadržaj što pre nađe u bazi i samim tim povećava svežinu. Odgovara najviše 'steady' modu.

FREKVENCIJA POSETE STRANAMA

- Fiksirana i varijabilna frekvencija.
- Kod fiksirane frekvencije pretraživač posećuje sve strane u isto vreme u potrazi za novim sadržajem. Najviše odgovara 'batch' modelu.
- Kod varijabilne frekvencije pretraživač za svaku stranu nezavisno određuje vreme ponovne posete. Najviše podobna za 'steady' model.
- Različiti matematički modeli za procenu frekvencije promene sadržaja na strani.

DVE MOGUĆE VARIJANTE INKREMENTALNOG PRETRAŽIVAČA

Tip A

Steady
In-Place
update
Variable freq.

Tip B


Batch-Mode
Shadowing
Fixed freq.

- Sveži podaci
- Manja opterećenost mreže

- Lakši za implementaciju
- Visok integritet podataka u celini


SPECIJALIZOVANI PRETRAŽIVAČI

- Takođe se nazivaju i fokusirani.
- Specijalno dizajnirani da traže samo određene strane sajta.
- Takođe mogu biti fokusirani na određeni sadržaj.
- Specijalizovan potraživač donosi odluke o daljem pretraživanju prepoznavanjem specifičnih linkova ili tipova stranica.
- Najpoznatiji su iRobot i FoCUS.




SPECIJALIZOVANI POTRAŽIVAČ BAZIRAN NA PREPOZNAVANJU STRANICA

- Najpoznatiji - iRobot.
- Sastoji se od dve faze, učenja i pretraživanja.
- U prvoj fazi se strane klasterizuju i izvlače parterni na osnovu kojih će se kasnije prepoznavati strane za vreme pretraživanja.
- U drugoj fazi se pretražuje sajt na osnovu šablonu određenih u prvoj fazi.
- U zavisnosti šta je cilj pretraživanja, strane sa takvim sadržajem se ciljaju u prvoj fazi učenja.



SPECIJALIZOVANI POTRAŽIVAČ BAZIRAN NA PREPOZNAVANJU LINKOVA

- Najpoznatiji – FoCUS.
- U prvoj fazi se uz pomoć mašinskog učenja i SVMa uče šabloni o stranama.
- Uz pomoć naučenih šablon prepoznaju se strane i linkovi koji vode do njih.
- Učenje regularnih izraza na osnovu izabranih linkova.
- Druga faza je faza pretrage uz pomoć regularnih izraza koji prepoznaju linkove.



OPTIMIZACIJA PRETRAŽIVANJA SA STRANE SAJTA

- Robots.txt – tekstualna datoteka obično održavana od strane administratora ili tehnologije koja pokreće Veb sajt.
- Može da se nalazi u bilo kojem folderu Veb sajta.
- Daje instrukcije pretraživaču šta treba da pretražuje.
- Etika dobrog ponašanja pretraživača je da prati uputstva data u ovoj datoteci iako pretraživač ne mora da ih sledi.
- Veb sajt može da blokira određeni pretraživač ako se ne ponaša u skladu sa datim instrukcijama.

ROBOTS.TXT - PRIMER

User-agent: Google

Disallow:

User-agent: WebSpider

Disallow: /~joe/junk.html

Disallow: /~joe/foo.html

Disallow: /~joe/bar.html

User-agent: *

Disallow: /

OPTIMIZACIJA PRETRAŽIVANJA SA STRANE SAJTA

- Sitemap.xml – XML struktuirana datoteke, najčešće održavana od strane tehnologije koja pokreće Veb sajt.
- Nalazi se u folderu početne strane sajta.
- Sadrži spisak strana koje su od važnosti i njihove parametre.
- Parametri svake strane mogu biti URL putanja, datum poslednjeg ažuriranja, prioritet [0-1], frekvencija promene sadržaja.

SITEMAP.XML - PRIMER

```
<?xml version="1.0" encoding="UTF-8"?>
<loc>http://mywebiste.com/just-some-url.htm</loc>
<lastmod>2017-11-07T15:48:49+00:00</lastmod>
<changefreq>weekly</changefreq>
<priority>0.5</priority>
</url>
<url>
...
</url>
```

SITEMAP.XML I ROBOTS.TXT

- Mogu biti korisni ako se pravilno održavaju.
- Teže održavanja kod sajtova koji često menjaju sadržaj i strane.
- Istraživanja su pokazala da se ove dve datoteke ne održavaju pravilno.
- Većina sajtova ih i ne sadrži.
- Ako ih održava administrator umesto tehnologije koja pokreće Veb sajt, ove datoteke postaju još nepreciznije.
- Pretraživač po pravilu treba da prati uputstva iz robots.txt, dok sitemap.xml treba samo da konsultuje i uporedi sa svojim procenama.

KORISNI RADOVI I LINKOVI

- Cho, J. and H. Garcia-Molina - *The Evolution of the Web and Implications for an Incremental Crawler*
- L. Page, S. Brin et al - *The PageRank citation ranking: Bringing order to the web.*
- J Cho, H Garcia-Molina - *Effective page refresh policies for web crawlers*
- C Olston, M Najork - *Web crawling*
- Cai, R., et al. - *iRobot: an intelligent crawler for web forums*
- Jiang, J., et al. - *FoCUS: Learning to Crawl Web Forums*
- *Web Crawling* - Microsoft Research - <https://www.microsoft.com/en-us/research/publication/web-crawling/>
- Google patents pagerank - <https://www.google.com/patents/US6285999>

HVALA NA PAŽNJI



Email: milos_pavkovic@yahoo.com