

Kako arhivirati Web

Miroslav Milinović

Sveučilišni računski centar Sveučilišta u Zagrebu
<miro@srce.hr>

Mirna Willer

Nacionalna i sveučilišna knjižnica, Zagreb
<mwiller@nsk.hr>

50. kolokvij knjižnice Instituta "Ruđer Bošković"

Zagreb, 1. prosinca 2004.

Sadržaj

- Informacijski prostor Weba
- Iskustva s hrvatskim prostorom Weba
- O arhiviranju Weba
- Zaključak (što nam je činiti?)

Web: informacijski servis

- jednostavno publiciranje
 - manje barijera / lakši pristup
 - brzo i efikasno publiciranje (posebno za dinamičke izvore informacija)
- informacije su distribuirane
- upravljanje informacijskim prostorom je teško, mogućnosti su ograničene
- novi odnosi između autora, izdavača, distributera, posrednika i korisnika (potrošača)

Informacijski prostor Weba

- “površinski” (*publicly indexable*) Web
 - veljača 1999., *Lawrence and Giles, NEC Institute*
 - 800 milijuna stranica, 15 (6) TB informacija
 - sadržaj: 83% com, 6% sci/edu, 1.5% porn
 - 60% Weba je indeksirano / katalogizirano
 - siječanj 2000., *Inktomi & NEC Institute*
 - više od 1 milijarde Web stranica
 - top-level domene: 55% .com, 8% .net, 4% .org, 1% .gov
 - u stalnom rastu:
 - ≈ 41 milijun Web sjedišta (lipanj 2003., Netcraft)
 - ≈ 5 milijardi Web stranica (2003.)



Informacijski prostor Weba

- 85% korisnika rabi pretraživačke mahanizme ili tematske kataloge kako bi pronašli informacije

Steve Lawrence, Lee Giles , Nec Institute, veljača 1999.

- korisnici smatraju da je Internet važan izvor informacija
 - 2/3 korisnika smatra da je Internet važan ili vrlo važan izvor informacija
 - 53%(47%) smatra TV (radio) jednako važnim

Center for Communication Policy, UCLA, kolovoz 2000.

- visoka očekivanja korisnika:
 - 97% korisnika očekuje pronaći traženo

Pew Internet & American Life, 2002.



Informacijski prostor Weba

- problemi inačica i duplikata:
 - caching, mirroring
- 40% od 800 milijuna stranica su duplikati

FAST, 2000.

- 30% Web stranica su kopije

Shivakumar and Garcia-Molina, 1998.

- “Deep” Web
 - 400 do 550 puta veći od “surface” Weba
 - 7500 TB podataka

The Deep Web: Surfacing Hidden Value; BrightPlanet.com, srpanj 2000.

Problemi?

- velika očekivanja korisnika
- alati i mehanizmi za upravljanje informacijskim prostorom Weba u stalnom razvoju (nikad dovoljno dobri)
- informacijski prostor nije (dobro) organiziran
- nepouzdana (nesigurna):
 - kvaliteta informacija
 - integritet informacija
 - povjerenje u izvor informacija (autentičnost)
- problem identifikacije resursa (URL)

Iskustava Srca s hrvatskim prostorom Weba

- Mjerenje hrvatskog Web prostora (**MWP**)
 - <http://www.srce.hr/mwp/>
 - Kontakt adresa mwp@srce.hr
 - započeto 2002. godine
- Projekt uspostave sustava za preuzimanje i arhiviranje obveznog primjerka hrvatskih mrežnih publikacija (**DAMP**)
 - zajednički projekt NSK i Srca
 - započet u studenom 2003. godine
 - cilj: uspostaviti sustav za preuzimanje i arhiviranje uz očuvanje autentičnosti sadržaja, oblika i funkcionalnosti mrežnih publikacija
- Projekt uspostave sustava za preuzimanje i arhiviranje mrežnih resursa za potrebe HIDRA-e (**AMD**)
 - zajednički projekt HIDRA-e i Srca
 - započet u svibnju 2004. godine
 - cilj: uspostaviti sustav za preuzimanje i arhiviranje mrežom dostupnih dokumenata s odabranog skupa Web sjedišta

MWP: što se i kako mjerilo?

- Provedena mjerenja:
 - MWP1: 29.03.-07.05.2002.
 - MWP2: 14.05.-22.07.2003.
 - MWP3: 08.09.-25.11.2003.
- Predmet mjerenja:
 - elektronički resursi dostupni HTTP / HTTPS protokolom s poslužitelja u .hr vršnoj internetskoj domeni
- Mjerilo se:
 - veličinu
 - korištene formate zapisa (prema MIME standardu)
 - obim i sadržaj metapodataka

Rezultati mjerenja


- MWP1 vs. MWP3:

- MWP1 (2002.)

- “HTTP resursi”
- ≈ 320 GB (389 GB)
- 5.145.383 obrađena resursa

- MWP3 (2003.)

- “HTTP/HTTPS resursi”
- ≈ 548 GB
- 7.125.879 obrađenih resursa (6.433.902 uspješno)
- text/html: 3.194.548 resursa, prosječne veličine 28.902 byta



MWP vs. svijet

- Web je “*small and simple*”:
 - MWP-1(2002.):
 - 320 GB i ≈ 6 milijuna resursa
 - 5 MIME tipova čini više od 90% obrađenih resursa
 - švedski Web (Hakala, 1999.):
 - 300 GB i ≈ 7,5 milijuna resursa
 - 4 MIME tipa pokrivaju 97% resursa
- Uporaba metapodataka:
 - Lawrence & Giles (1999.):
 - 34% Web resursa ima META oznaku / 0,3% rabi DC
 - 123 različita oblika META oznake
 - MWP:
 - MWP-1: 31% Web resursa ima META oznaku / 0,09% rabi DC
 - MWP-2: 43,1% Web resursa ima META oznaku / 2,31% rabi DC
 - broj različitih vrijednosti NAME atributa META oznake:
MWP1: 743 / MWP2: 645 / MWP3: 666

MWP: zaključak

- rezultati odgovaraju očekivanjima i sličnim istraživanjima provedenim u svijetu
- (površinski) Web je i dalje jednostavan: rabimo mali broj različitih formata
- autori ne brinu dovoljno o metapodacima
- dinamički web, inventivne, ali i nestandardne uporabe Web tehnologija čine mjerenje sve složenijim

Projekt DAMP

- Projekt uspostave sustava za preuzimanje i arhiviranje obveznog primjerka hrvatskih mrežnih publikacija
 - zajednički projekt NSK i Srca, uz suradnju tvrtke UNIBIS
 - započeo u studenom 2003. godine
 - **Cilj:** uspostava sustava za preuzimanje i arhiviranje obveznog primjerka hrvatskih publikacija na internetu uz očuvanje, u najvećoj mogućoj mjeri autentičnosti njihova sadržaja, oblika i funkcionalnosti, a u svrhu njihove dugoročne zaštite i korištenja u budućnosti. Cilj projekta usklađen je s temeljnom zadaćom NSK da prikuplja, obrađuje, čuva i daje na korištenje hrvatske publikacije na svim medijima.
- DAMP (**D**igitalni **A**rhiv **M**režnih **P**ublikacija) ver. 1.0.
 - modularan, proširiv, jednostavna uporaba za korisnika/arhivara
 - utemeljen na Open Source programskoj podršci
 - razvijen na temelju iskustava Srca u području istraživanja Weba (projekt MWP)


DAMP: temeljni principi

- Pobiru se i arhiviraju samo one publikacije koje su bibliografski identificirane i obrađene, tj. poslovanje mrežnim publikacijama podliježe svim postupcima knjižničnog poslovanja kao s građom koja nije mrežna.
- Sustav DAMP kao izvor osnovnih informacija o publikacijama (Web sjedištima, kandidatima za pobiranje) rabi katalog NSK (CROLIST)

Dijelovi sustava DAMP

- **Gatherer**
 - podsustav za pobiranje Web sjedišta (publikacije)
- **Controller**
 - podsustav za kontrolu pobiranja i arhiviranje rezultata pobiranja
- **Scheduler**
 - podusustava za raspoređivanje pobiranja
- **Skladište podataka**
 - čine ga baza podataka i posebno organizirani datotečni sustav
- **Web sučelje** za pristup arhivu i upravljanje sustavom
- **Modul za razmjenu podataka** s Katalogom NSK

Funkcionalni model sustava DAMP



DAMP: upravljanje pobiranjem

- administrator/arhivar mora obraditi svaku novu publikaciju:
 - pregledati konkretno Web sjedište
 - odrediti frekvenciju (vrijeme i učestalost) pobiranja
 - odrediti parametre pobiranja (prije svega **dubinu**)
 - provjeriti ishod prvog (probnog pobiranja) i eventualno dodatno podesiti uvjete/parametre
- temeljem postavljenih uvjeta i parametara scheduler uvrštava konkretno pobiranje u red
- gatherer(i) izvršava(ju) pojedina pobiranja prema tom redu (pod nadzorom controllera)

DAMP: pristup arhivu


- putem Web sučelja
- za svako pobiranje pojedine publikacije omogućuje:
 - pregledavanje arhivskog primjerka
 - pregledavanje podataka o pobiranju
 - osnovni podaci o pobiranju (veličina, status, ...)
 - distribucija tipova prikupljenih datoteka
 - metapodaci
 - pregledavanje zapisa o pobiranju (log)
 - izravni pristup direktoriju s rezultatom pobiranja

Koncept i funkcionalni model integracije sustava DAMP i CROLIST

- Koncept: Pobiru i arhiviraju samo one publikacije koje su bibliografski identificirane i obrađene, tj. poslovanje mrežnim publikacijama podliježe svim postupcima knjižničnog poslovanja kao s građom koja nije mrežna, od njene identifikacije do pronalaženja u WebPAC-u NSK.
- Posebnosti poslovanja s mrežnom građom odnose se na upravljanje njihovim arhiviranjem u poslovnom procesu interakcije sustava DAMP i CROLIST.

Integriranje digitalnog arhiva s LIS-om (Projekt NEDLIB)

1. Odabir za izgradnju fonda
2. Nabava
3. Pobiranje
4. Registracija
5. Provjera
6. Opis/Katalogizacija
7. Pohrana/rukovanje
8. Zaštita
9. Isporuka
10. Pristup
11. Nadzor



Bicikl : e-zine u WebPAC-u

NSK - Nacionalna i sveučilišna knjižnica, Zagreb - Microsoft Internet Explorer

Datoteka Uređivanje Prikaz Favoriti Alati Pomoć

Nazad Pretraži Favoriti

Adresa <http://www.nsk.hr/opac-crolist/crolist.html> Idi Links

DOGADANJA + OPĆE OBAVIJESTI + USLUGE + KNJIŽNICE NA INTERNETU
OBAVIJESTI ZA IZDAVAČE + KNJIŽARA + VIRTUALNA SETNJA

Baza podataka: **Nacionalna i sveučilišna knjižnica - Zagreb**

CroList

Tražili ste: bibliografski zapis
Vaš upit: 410314135

410314135: serijska publikacija/1

ISBD UNIMARC

Identifikatori: ISSN 1333-9818
Naslov: Bicikl : e-zine za ljubitelje labilne ravnoteže / glavna urednica Darinka Širola
Vrsta i opseg: Novine
Brojčani podaci: 2001 (siječanj) - ..
Impresum: [Zagreb] : Bicikl.com, 2001 - ..
Napomene: Nepoznato. - Pristup: World Wide Web. - Stv. nasl. s naslovnice. - Stv. nasl. iz zaglavljia HTML: Bicikl. hr. - Stv. nasl. od 2001. do 2004. : Bicikl. com. - Ranije dostupno na URL: <http://www.bicikl.com>.
Napomena o primjerku: Opis građe dana: 14. 03. 2001.; zadnji opis prema verziji dana: 21. 09. 2004.
Ključni naslov: Bicikl.com
Ostali naslovi: Bicikl.hr
Bicikl.com
UDK: 796.6
Internet: <http://www.bicikl.hr>; Arhiv: <http://damp.srce.hr/index.php?show=archive&idpublication=88>

[Jednostavno pretraživanje](#) | [Složeno pretraživanje](#) | [Primjeri](#) | [Mreža knjižnica](#) | [Početak](#)

© 1996-2004 Unibis

start Ulazna pošta - Outloo... kolokvij-irb-mm_mw Izmjenjivi disk (G:) NSK - Nacionalna i sv... HR 16:29

DAMP: izazovi

- dinamički web, inventivne, ali i nestandardne uporabe Web tehnologija čine arhiviranje složenim (nemogućim?)
- dubinski web - nepoberiv (?)
- publikacije zaštićene nekim mehanizmom autentikacije/autorizacije
- off-line arhive nakladnika
- uvjeti / ograničenja na javni pristup arhivu
- DAMP-dijagnostika u funkciji procjene kvalitete arhivskog primjerka
- minimalni uvjeti za publikacije (upute za nakladnike)
- osigurati suradnju nakladnika

Arhiviranje Weba

- izazovno, ali globalno/sveobuhvatno (ne)moguće (?)
- nužna/važna selekcija/izbor resursa koji se pobiru
- mogući opći kriteriji:
 - domena
 - jezik
 - sadržaj
 - vrsta publikacija
 - oblik/način objavljivanja
 - pristup
 - format
 - ...
- metode pobiranja:
 - dostava, pobiranje, pobiranje uz prethodnu selekciju, ...

Projekti arhiviranja Web u svijetu

Zemlja	Projekt	Metoda	Pristup	Veličina
Australija	PANDORA (NLA)	Odabir	Da	353 GB
Austrija	AOLA	Pobiranje	Ne	448 GB
Finska	Sveučilišna Knjižnica Helsinki	Pobiranje	Ne	401 Gb
FR	BNF	Odabir i pobiranje	Ne	< 1 TB
Švedska	Kulturarw	Pobiranje	Ograničen pristup	4.5 TB
VB	Britain on the Web, BL	Odabir	Ne	30 MB
SAD	Internet Archive	Pobiranje	Da	> 150 TB
SAD	MINERVA, LC	Odabir	Ne	35 sites
HR	NSK	Odabir	?	ca 800 publ.

Klarin, S. AKM8: Arhiviranje sadržaja weba u projektima nacionalnih knjižnica i projektu "Internet Archive"
Day, Michael. Collecting and preserving the World Wide Web : version 1.0 – 25 february 2003. Str. 18.

Što nam je činiti? (kao autorima/nakladnicima)

- upoznajmo i poštujujmo standarde i preporuke
 - meta podaci
 - Standards for Robots Exclusion (REP, ROBOTS META oznaka)
 - W3C WAI
 - ...
 - <http://useit.com/>
 - domaće inicijative i projekti
 - ...
- Izbjegavajmo inventivnu, ali nestandardnu (neuobičajenu) uporaba Web tehnologija
 - Uporaba tehnologije radi tehnologije same
 - "best viewed with any browser"

Kako arhivirati?

- Definirati uvjete / kriterije
- Definirati metode / tehnike
- Educirati nakladnike / autore, ali i korisnike
- Pratiti razvoj (Web) tehnologija

- Nema kvalitetnog arhiva bez nadzora arhivara!

Sadržaj

- Informacijski prostor Weba
- Iskustva s hrvatskim prostorom Weba
- O arhiviranju Weba
- Zaključak (što nam je činiti?)

Kako arhivirati Web

Miroslav Milinović

Sveučilišni računski centar Sveučilišta u Zagrebu
<miro@srce.hr>

Mirna Willer

Nacionalna i sveučilišna knjižnica, Zagreb
<mwiller@nsk.hr>

50. kolokvij knjižnice Instituta "Ruđer Bošković"

Zagreb, 1. prosinca 2004.