

# Pronalaženje informacija na Internetu i metapodaci

*Miroslav Milinović  
miro@srce.hr*

*Zagreb, studeni 2003.*

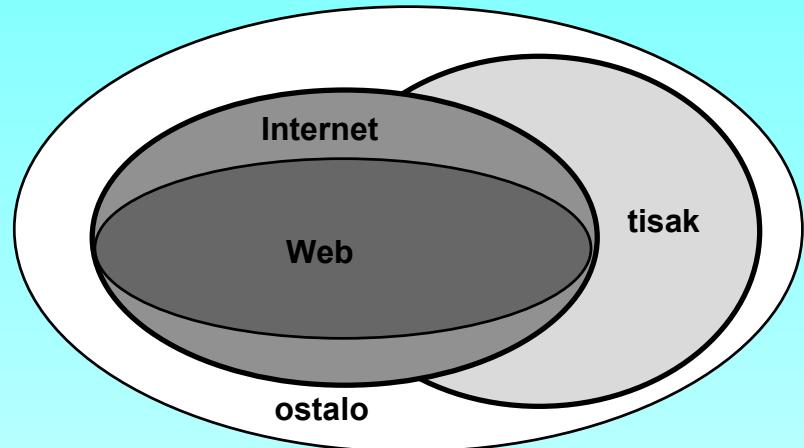
# Sadržaj

- Dio 1. - Pronalaženje informacija na Internetu
  - Internetski prostor informacija
  - pretraživanje Weba
  - tražilice
  - tematski katalozi
- Dio 2. - Metapodaci
  - motivi i koncepti
  - Dublin Core
  - RDF

# *Dio 1. - Pronalaženje informacija na Internetu*

# Internetski prostor informacija

- NIJE UREĐEN - unificiran
- Mnoštvo tema
- Različiti izvori informacija
- Različiti formati
- Pristup je moguć pomoću različitih alata (programa)
- Postoje informacije koje (još) **nisu**:
  - publicirane u elektroničkom obliku
  - dostupne putem mreže



# Internetski prostor informacija

## Mnoštvo dostupnih tema i formata:

- dokumenti različitog formata
- slikovni, audio i video zapis
- elektronička izdanja novina, časopisa, knjiga, ...
- katalozi, organizirane kolekcije informacija
- baze podataka
- javno dostupna programska podrška
- ...
- “smeće”

# Mrežni izvori informacija (resursi)

- **Informacije se publiciraju pomoću različitih mrežnih usluga i servisa:**
  - Web
  - FTP arhive
  - distribucijske (mailing) liste
  - mrežne novine (USENET)
  - elektronička pošta
  - imenički servisi (LDAP, ...)
  - baze podataka dostupne putem mreže
  - ...

# Identifikacija mrežnih resursa

- **URI** - Uniform Resource Identifier (RFC 2396)
  - **URL** - Uniform Resource Locator (RFC 1630, RFC 1738)
    - određuje: način pristupa, adresu računala, naziv datoteke ...
    - **protocol://host\_name[:port\_num][/path][/file\_name]**
    - PURL - Persistent URL
  - **URN** - Uniform Resource Name (RFC 1737, RFC 2141)
- **URC** - Uniform Resource Characteristics
  - podaci o mrežnom resursu
  - metadata = podaci o podacima

# Web informacijski prostor

- pretraživi (*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
  - 2003. (?)
    - $\approx$  5 milijardi Web stranica
  - mwp@SRCE.hr (2002.)
    - Hrvatski Web prostor (.hr TLD)  $\approx$  320 GB ( $\approx$  6 milijuna resursa)



# Web informacijski prostor

- 40% od 800 milijuna stranica su duplikati  
*FAST, 2000.*
- 30% Web stanica 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.*



# Web informacijski prostor

- 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.*

# Sustavi za pretraživanje

- mnoštvo različitih sustava (alata)
- većinom su specijalizirani za pretraživanje određenih resursa
- (gotovo) svi alati imaju Web sučelje
- doseg pretraživanja je globalni ili lokalni
- nema savršenog niti sveobuhvatnog alata
- opterećeni su problemom ažurnosti i/ili kvalitete
- postoje alati koji se temelje na Webu, ali ne pretražuju Web resurse

# Sustavi za pretraživanje Weba

- **Tražilice (pretraživački mehanizmi) (search engines)**
  - tražilice (search engines)
  - metatražilice (*metasearch engines, unified search interfaces*)
- **Tematski katalozi** (*subject catalogs, subject directories, ...*)
  - u pravilu pretraživi (searchable indexes, searchable catalogs)
- **Ostali sustavi:**
  - višestruka sučelja (*multiple search interfaces*)
  - specijalizirana sučelja (*information gateways*)
  - ...
- **Portali**

# Tražilice

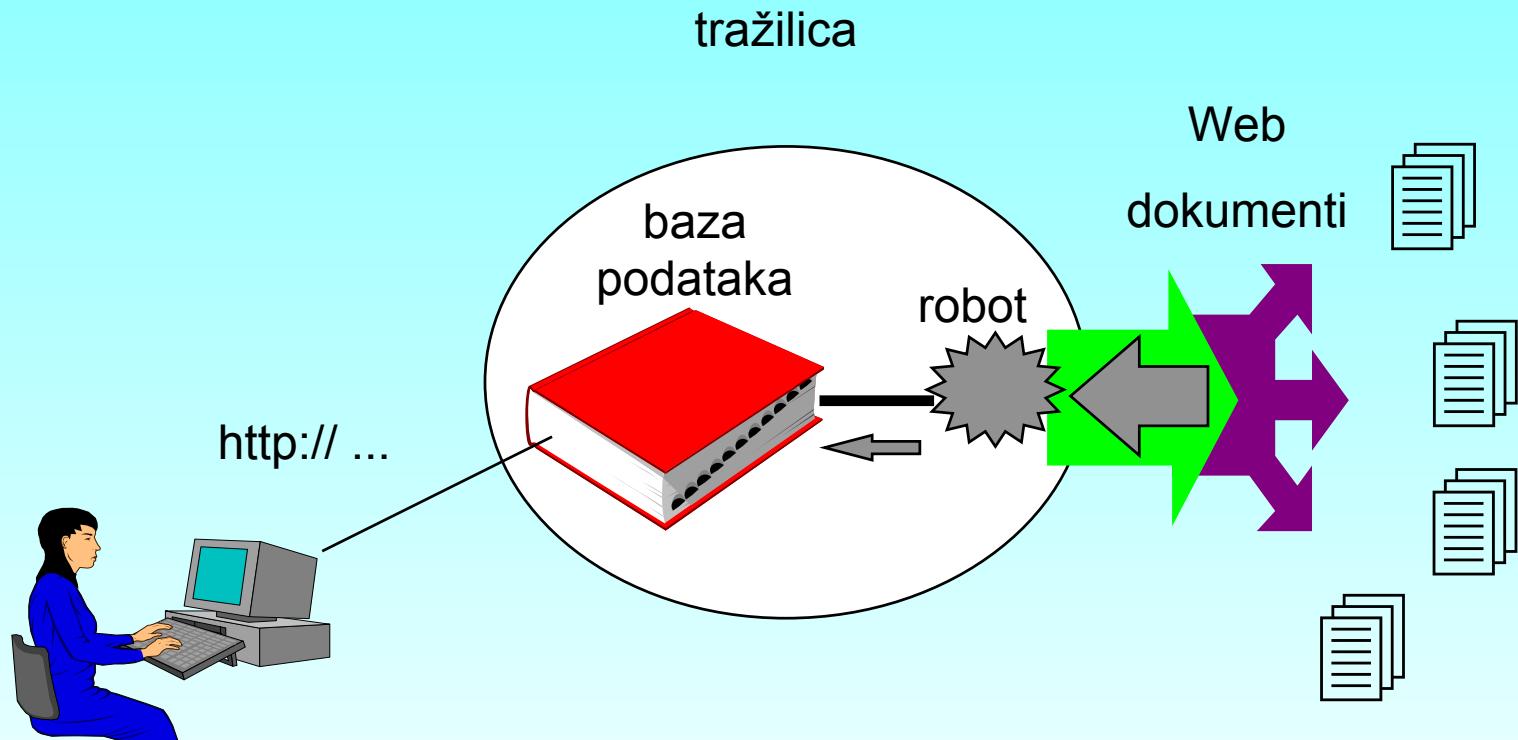
## Što su i kako rade?

- automatizirani sustavi
- prikupljaju informacije o mrežnim resursima i omogućuju pretraživanje prikupljenih informacija
- posebni programi - roboti (*robot, crawler, spider*)
  - dohvaćaju dostupne mrežne resurse (Web stranice)
  - sudjeluju u gradnji/održavanju pretražive kolekcije podataka (baze podataka)
- sustav za pretraživanje (baze podataka)
  - Web sučelje omogućuje korisniku postavljanje upita
  - posebna pravila za postavljanje upita
  - ispis rezultata pretraživanja (*hits*)



# Tražilice

## Što su i kako rade?



# Tražilice

## Primjeri

GO.com (InfoSeek) - <http://www.go.com/>

Lycos Search - <http://www.lycos.com/>

Alta Vista - <http://www.altavista.com/>

excite! NetSearch - <http://www.excite.com/>

Google - <http://www.google.com/>

HotBot - <http://hotbot.lycos.com/>

WebCrawler - <http://www.webcrawler.com/>

Nothern Light Search - <http://www.northernlight.com/>

FAST - <http://www.alltheweb.com/>

Raging Search - <http://ragingsearch.altavista.com/>



tražilice lokalnog dosega:

(<http://cross.carnet.hr/>)

(<http://altavista.hinet.hr/>)

# Tražilice

## Osnovni procesi

- prikupljanje resursa (gathering)
- izgradnja baze podataka (indexing)
- posluživanje korisničkih upita (searching)

# Tražilice

## Prikupljanje resursa

- valja razmisliti o:
  - samo HTTP ili i drugi protokoli/resursi (FTP, Usenet, ...)
  - koristimo li cacheve za dohvat resursa (ICP?)
  - distribuirano prikupljanje
  - popis resursa (gdje početi i gdje završiti)
  - kojom učestalošću obilaziti (iste) resurse
  - potrebni mrežni i računalni resursi

# Tražilice

## Indeksiranje

- valja razmisiliti o:
  - koje formate dokumenata indeksiramo (samo HTML ili ...)
  - puni tekst ?
  - metapodaci ?
  - višejezičnost
  - uporaba podataka iz drugih baza (indeksa)
  - potrebni mrežni i računalni resursi

# Tražilice

## Pretraživanje

- valja razmisliti o:
  - sintaksa i mogućnosti pri postavljanju upita
    - metode za pretraživanje baze i dohvat rezultata
  - način ispisivanja/predstavljanja rezultata upita
  - korisničko sučelje
  - višejezičnost
  - potrebni mrežni i računalni resursi

# Roboti

- mogu samo opteretiti i mrežu i računalo (poslužitelj)
  - vodite brigu o robotima, ali i o tuđim resursima
- postoje pravila ponašanja (etika) za robote:
  - robot exclusion protocol
  - ROBOT META oznaka
- korisna URL adresa:
  - <http://www.robotstxt.org/>
  - <http://www.searchenginewatch.com/webmasters/spiderchart.html>

# Robot Exclusion Protocol

- može rabiti samo osoba s pravom pisanja u odgovarajućem direktoriju (webmaster)
- robot.txt datoteka
  - posebna sintaksa
  - u početnom direktoriju Web poslužitelja
  - URL: <http://hostname/robots.txt>
- primjer:
  - User-agent: \*
  - Disallow: /archives/
  - Disallow: /radni/

# ROBOT META oznaka

- može rabiti autor Web stranice prema potrebi
- <META NAME="ROBOTS" CONTENT="content">
  - content = ALL | NONE | directive ["," directive]
  - directive = index | follow
  - index = "INDEX" | "NOINDEX"
  - follow = "FOLLOW" | "NOFOLLOW"
- default: INDEX, FOLLOW
- primjer:

```
<meta name="robots" content="index,nofollow">
```

# Tražilice

## Postavljanje upita

- Sintaksa upita i spektar mogućnosti ovisi o alatu
  - postoji standardni spektar mogućnosti (uporaba malih i velikih slova, fraze, kontrola ključnih riječi, ...)
- Moguć je izbor resursa koje pretražujemo
  - Web ili neki drugi resursi; čitavi dokumenti ili samo naslovi, ...
- Korisno je pri prvom susretu s nekim alatom pročitati raspoložive upute

# Tražilice

## Mogućnosti kod postavljanja upita

- uporaba malih i velikih slova  
`John December`  
`island`
- uporaba fraza  
`"John December"`  
`"NASA Space shuttle program"`
- uporaba logičkih operatora (AND, OR, NOT)  
`vegetables AND green`  
`fruit NOT apple`
- kontrola ključnih riječi (+, -)  
`+film +noir -"pinot noir"`  
`+python -monty`



# Tražilice

## Mogućnosti kod postavljanja upita (2)

- susjednost - proximity search  
`Internet NEAR training`
- uporaba dijelova (korijena) riječi (Keyword Truncation) - \*, ?, %  
`alumi*um`  
`comput*`
- kaskadno pretraživanje (Infoseek)
- kontrola resursa
  - `title:"Internet training"` (AltaVista, HotBot, ...)
  - `host:www.fer.hr` (AltaVista)
  - `image:slika.jpg` (AltaVista)
  - `related:` (Google)



# Tražilice

## Mogućnosti kod postavljanja upita (3)

- *natural language searching* (Ask Jeeves! - <http://www.ask.com/>)
- drugačiji pristupi:
  - Ditto.com - <http://www.ditto.com/>
  - (Oingo - <http://www.ingo.com/>)
- korisna URL adresa:
  - <http://www.searchenginewatch.com/>

# Tražilice

## Važne odlike

- Baza podataka (veličina, ažurnost, složenost) / rujan 2003.
  - Google – 3,3 milijardi Web stranica
  - AllTheWeb (FAST) – 3,2 milijardi Web stranica
  - INKTOMI - 3 milijarde Web stranica
  - AltaVista - 1 milijarda Web stranica
- Mogućnosti postavljanja (složenih) upita
- Brzina rada (odziv)
- Rangiranje rezultata (*ranking*)
- Kvaliteta i mogućnost kontrole ispisa
- Dodatne mogućnosti
  - (kaskadno pretraživanje/profinjavanje upita, ...)

# Tražilice

## Rangiranje rezultata

- kriteriji se temelje na:
  - frekvenciji i položaju (npr. u naslovu) ključnih riječi
  - metapodacima
  - popularnosti
  - analizi linkova (relevantnost)
- plaćeno oglašavanje vs. objektivno rangiranje

# Tražilice

## Prednosti i mane

- Prednosti:
  - veliki opseg
  - efikasno pretraživanje i pristup informacijama
  - automatiziran rad
- Mane:
  - nema kontrole kvalitete
  - nema klasifikacije
  - rezultati mogu biti izvan konteksta (npr. “space”)
  - sadrže i zastarjele i nepostojeće URL adrese
  - sadrže i smeće

# Tražilice

## Metatražilice

- ***metasearch engines, unified search interfaces***
- omogućuju korisniku da putem unificirane forme postavi jedan upit kojeg zatim distribuiraju odabranim tražilicama
- kod postavljanja upita treba koristiti samo sintaksu koju poznaje tražilica
- korisnik dobiva zbirni rezultat pretraživanja
- nemaju vlastite baze podataka niti robot program



# Tražilice

## Metatražilice (2)

- **primjeri:**

(All4one - <http://all4one.com/>)

Mamma - <http://www.mamma.com/>

MetaCrawler - <http://www.metacrawler.com/>

(SavvySearch) CNET Search.com - <http://www.search.com/>



# Tražilice

## Metatražilice (3)

- **važne odlike:**
  - broj i izbor povezanih tražilica
  - brzina rada (odziv)
  - rangiranje rezultata
  - način udruživanja rezultata (*results merging*)
  - kvaliteta ispisa
  - mogućnost kontrole ispisa
  - dodatne mogućnosti



# Tražilice

## Metatražilice (4)

- imaju sve prednosti i mane običnih tražilica
- **dodatna prednost:**
  - pojednostavljaju pristup i pretraživanje
- **dodatne mane:**
  - unificiranjem upita gube se dodatne mogućnosti postavljanja složenijih upita i kontrole ispisa
  - sporije pretraživanje

# Tematski katalozi

## Što su i kako rade?

- tematski organizirane kolekcije podataka o odabranim mrežnim resursima  
(odabrani resursi klasificirani po temama)
- sadrže URL adrese mrežnih resursa
- mogu sadržavati i nazine resursa, sažetke, ...
- ne održavaju se automatski (programski) već se temelje na radu urednika



# Tematski katalozi

## Što su i kako rade?

- klasificiranje resursa se odvija prema hijerarhijskoj shemi tema (područja)
- način klasificiranja nije unificiran  
(UDC, Dewey, proizvoljan ...)
- postoji mogućnost pretraživanja kataloga
- neki tematski katalozi povezani su s tražilicama

# Tematski katalozi

## Primjeri

Yahoo - <http://www.yahoo.com/>

LookSmart - <http://www.looksmart.com/>

EINet Galaxy - <http://galaxy.einet.net/>

Magellan - <http://magellan.excite.com/>

NetGuide - <http://www.netguide.com/>

About.com - <http://www.about.com/>

Open Directory - <http://dmoz.org/>



katalozi lokalnog opsega:

WWW.HR - <http://www.hr/wwwhr/>

# Tematski katalozi

## Važne odlike

- veličina (broj klasificiranih resursa)
  - Yahoo - >100 urednika, 1,8 milijuna Webova (2000.)
  - Open Directory - ≈60000 urednika, 3,8 milijuna Webova (2003.)
  - LookSmart - 200 urednika, 2,5 milijuna Webova (2001.)
- tematsko stablo - način klasifikacije
- dodatne informacije o resursima
- rangiranje resursa
- mogućnost pretraživanja
- veze s tražilicama
- dodatne mogućnosti

# Tematski katalozi

## Prednosti i mane

- Prednosti:
  - klasifikacija resursa po temama (područjima)
  - mogućnost internog pretraživanja kataloga
  - nema “smeća”
- Mane:
  - manualno održavanje
  - pojedine dijelove kataloga ne uređuju profesionalci
  - sadrže i zastarjele informacije

# Portali

- ulaz u informacijski prostor Interneta
- hibridni alat - pravo rješenje
- nude pristup (svim) mrežnim servisima na jednom mjestu
- temelje se na tražilici i/ili tematskom katalogu
- nude personalizirano sučelje
- opći ili specijalizirani (tema ili interesna skupina)
  - <http://cnn.com/>
  - <http://www.excite.com/>
  - <http://www.yahoo.com/>
  - <http://www.ihlth.com/>
  - <http://www.digitalessays.com/>
  - ...

# Pretraživanje Web resursa

## Izbor alata

- **PORTALI !**
- **tematski katalozi**
  - kad nemamo (dobre) ključne riječi odnosno jasnu ideju što tražimo
- **tražilice**
  - kad imamo precizne ključne riječi i jasnu ideju što tražimo
- **specijalizirana sučelja (za neko područje)**
  - nude kvalitetne informacije (ako postoje i znamo za njih)

# *Dio 2. - Metapodaci*

# Problemi?

- velika očekivanja korisnika
- alati i mehanizmi
  - još uvijek nedovoljno dobri
  - u stalnom razvoju
- informacijski prostor nije (dobro) organiziran
- nepouzdana (nesigurna):
  - kvaliteta informacija
  - integritet informacija
  - povjerenje u izvor informacija

# 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)

# Web $\Leftrightarrow$ knjižnica

- pretraživački sustavi:
  - motivirani su oglašavanjem (?)
  - doseg im je omeđen i nepredvidiv
  - recall .vs. precision
  - index spam (metadata spam)
- otvoreni problemi s resursima:
  - kvaliteta, integritet, pouzdanost
  - arhiviranje
  - autorska prava

# Metapodaci

- strukturirani podaci o podacima
  - pomažu u stvaranju reda u Web informacijskom prostoru
  - omogućuju automatsko pronalaženje / upravljanje informacijama
- mogu se rabiti u različite svrhe:
  - pronalaženje informacija (resource discovery)
  - vrednovanje sadržaja (content rating)
  - upravljanje pravima (rights management)
  - sigurnost i autentifikacija (security and authentication)
  - ...

# Izazovi

- osigurati potrebnu raznolikost (uporabe) metapodataka
- funkcionalnost  $\Leftrightarrow$  jednostavnost
- proširivost  $\Leftrightarrow$  interoperabilnost
- kreiranje i uporaba: ljudskim radom i strojno
- ispuniti specifične potrebe

*metadata = pidgin language of the Internet*

# Modularnost i interoperabilnost

- Modularnost
  - koncept "lego kocaka"
  - omogućuje distribuirano upravljanje
  - odgovornost je na pravom mjestu
- Interoperabilnost zahtjeva dogovore o:
  - semantici (značenju pojedinih elemenata)
  - strukturi (razumljiva ljudima, čitljiva strojevima)
  - sintaksi (gramatici)

# Zapisivanje metapodataka

- **osnovni načini pohrane:**
  - metapodaci uloženi (embedded metadata) u Web stanicu - HTML dokument (npr. HTML META tag)
  - metapodaci povezani s Web stranicom (HTTP header)
  - metapodaci dostupni preko treće strane po posebnom zahtjevu (eksplicitni HTTP GET)
- **sintaktička rješenja za zapisivanje:**
  - HTML - trenutno najrasprostranjenije i najjednostavnije rješenje (META oznaka)
  - RDF - temelji se na XML-u; posebno namjenjen za metapodatke
  - XML

# HTML META oznaka

- omogućuje definiranje para značajka - *vrijednost* koji se veže uz dokument
- osnovni oblik META oznake:
  - par atributa **NAME** i **CONTENT**  
`<META NAME="value" CONTENT="value">`
  - atributom **NAME** definira se značajka resursa (npr. autor ili naslov)
    - vrijednosti NAME atributa nisu standardizirane
    - DUBLIN CORE - prijedlog standarda
    - najčešće vrijednosti koje se rabe: AUTHOR, KEYWORDS, DESCRIPTION, TITLE
  - atributom **CONTENT** definira se vrijednost značajke definirane NAME atributom

# META oznaka - primjeri

```
<HEAD>
<TITLE>Naslov</TITLE>
<META name="description" content="Opis sadrzaja">
<META name="keywords" content="kljucne rijeci">
</HEAD>
```

---

```
<HEAD>
<TITLE>Naslov</TITLE>
<META name="DC.Creator" content="December, John">
</HEAD>
```

# Dublin Core (DC)

- predloženi standard za metapodatke (RFC 2413)
- namjenjen opisivanju resursa radi olakšanog pronalaženja informacija
- sastoji se od temeljnog skupa od 15 elemenata (značajki kojima se opisuje mrežni resurs)
- elementi su definirani temeljem ISO 11179 standarda
- elementi nisu obvezni i mogu se ponavljati
- DC predviđa mogućnost proširenja elementa (qualifiers)
- temeljni skup elemenata je proširiv
- moguća je nadopuna drugim metapodacima
- specifikacija (ver 1.1)
  - <http://dublincore.org/documents/dces/>

# DC elementi (DCMES)

- Title
- Creator (author)
- Subject (keywords)
- Description
- Publisher
- Other Contributor
- Date
- Resource Type
- Format
- Resource Identifier
- Source
- Language
- Relation
- Coverage
- Rights Management

# DC kvalifikatori (qualifiers)

- profinjenje osnovnih elemenata
  - profinjuju značenje pojedinog elementa
- definiraju *encoding schemas*
  - određuju pravila ili algoritme za izvrednjavanje ili interpretiranje podataka
  - kontrolirani rječnici, klasifikacijske sheme, liste
- specifikacija:
  - <http://dublincore.org/documents/dcmes-qualifiers/>

# DC u HTML-u

- META oznaka:

- sintaksa:

```
<META name="PREFIX.ELEMENT_NAME" content="ELEMENT_VALUE">
```

- primjer:

```
<META name="DC.Creator" content="December, John">
```



# DC u HTML-u (2)

- **LINK oznaka**

- sintaksa:

```
<LINK rel="schema.PREFIX" href="LOCATION_OF_DEFINITION">
```

- primjer:

```
<LINK rel="schema.DC" ref="http://dublincore.org/documents/dces/">
```



# DC u HTML-u (3)

- ponavljanje elemenata
  - primjer:

```
<META name="DC.Creator" content="Green, John">  
<META name="DC.Creator" content="Brown, Fred">
```



# DC u HTML-u (4)

- dodatne mogućnosti (profinjenje):

- sintaksa:

```
<META
```

```
    name="PREFIX.ELEMENT_NAME.SUBELEMENT_NAME"  
    content="ELEMENT_VALUE"  
    scheme="SCHEME"  
    lang="LANGUAGE">
```

- primjeri:

```
<META name="DC.Date.Created" content="2000-08-01"  
      scheme="ISO8601">
```

```
<META name="DC.Relation.isPartOf"  
      content="http://www.somewhere.net">
```

# DC Metadata Initiative (DCMI)

- Formalna podrška razvoju DC-a
- Radne skupine
- Domain-specific initiatives
  - DC-Education, DC-Libraries, DC-Government, ...
- DC-Registry
  - <http://www.schemas-forum.org/>
- Redoviti sastanci / radionice
- <http://dublincore.org/>

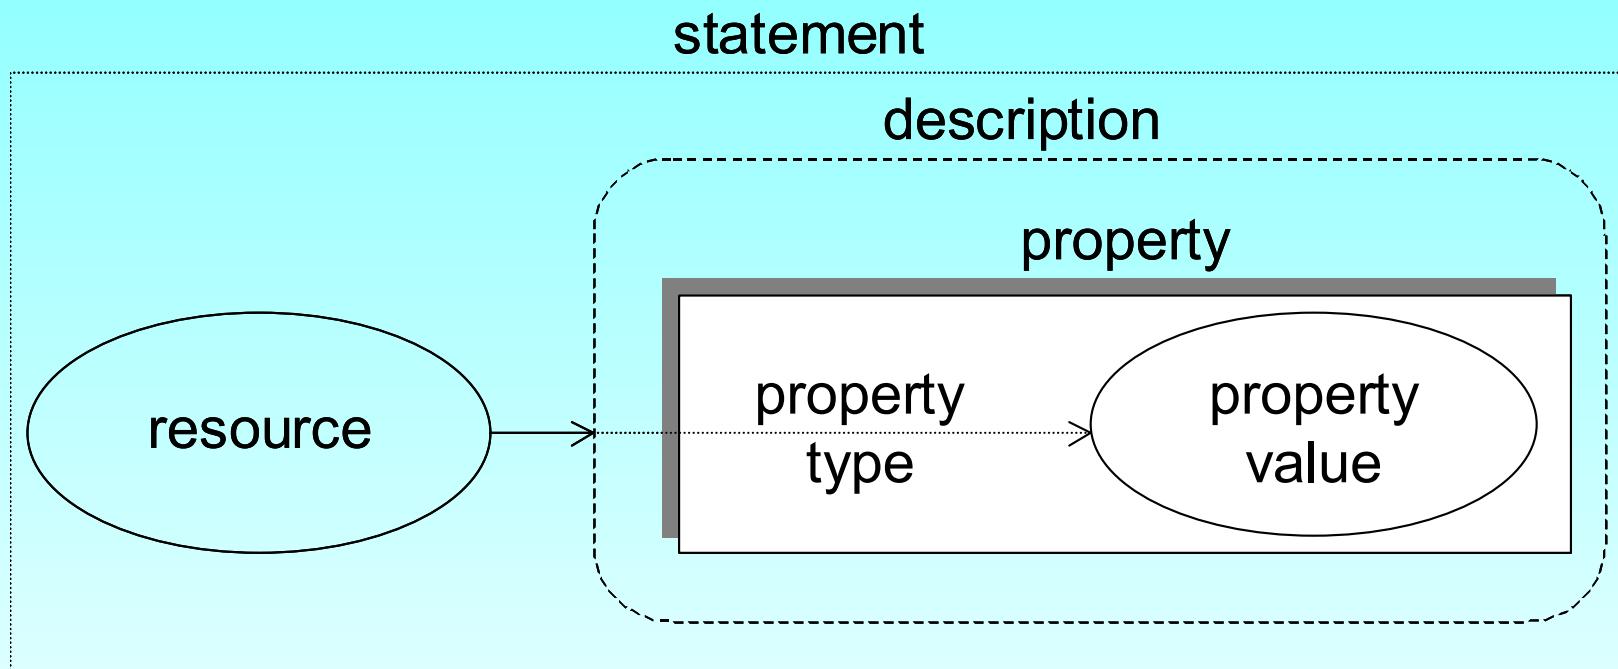
# Resource Description Framework

- W3C standard (<http://www.w3.org/RDF/>)
- generalizirani pogled na metapodatke
- opće namjene
- strukturirani, strojno “razumljivi” metapodaci
- metapodatkovni rječnici (sheme) mogu se razvijati decentralizirano (bez središnjeg nadzora)
- podrška za autentikaciju metapodataka (i povjerenje u njihovu kvalitetu)

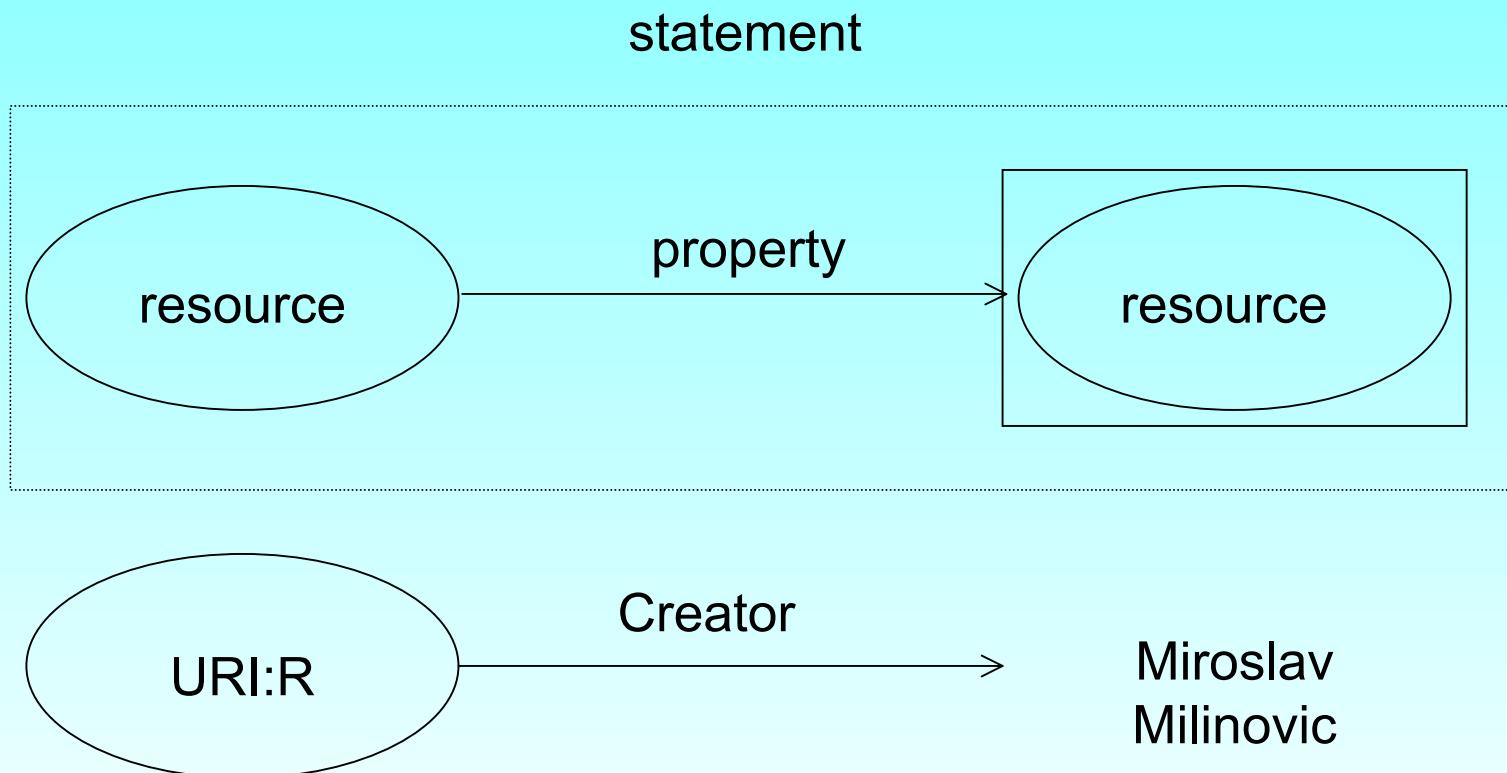
# RDF koncept

- model podataka
- sheme
- sintaksa (u XML)

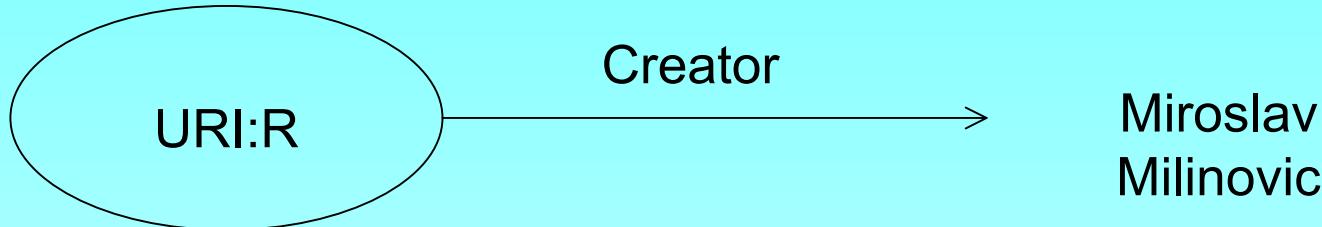
# RDF model podataka (1)



# RDF model podataka (2)



# RDF (XML) sintaksa



```
<RDF xmlns =“http://www.w3.org/TR/WD-rdf-syntax#”
      xmlns:dc=“http://dublincore.org/documents/dces/”>
  <Description about =“URI:R”>
    <dc:Creator>Miroslav Milinovic</dc:Creator>
  </Description>
</RDF>
```

# RDF kontejneri (containers)

- više vrijednosti za istu značajku (property)
- 3 tipa kontejnera:
  - **Bag**
    - grupa (unordered grouping)
  - **Sequence**
    - uređena grupa (ordered grouping)
  - **Alternatives**
    - alternativne vrijednosti

# RDF kontejneri - primjer

- grupa

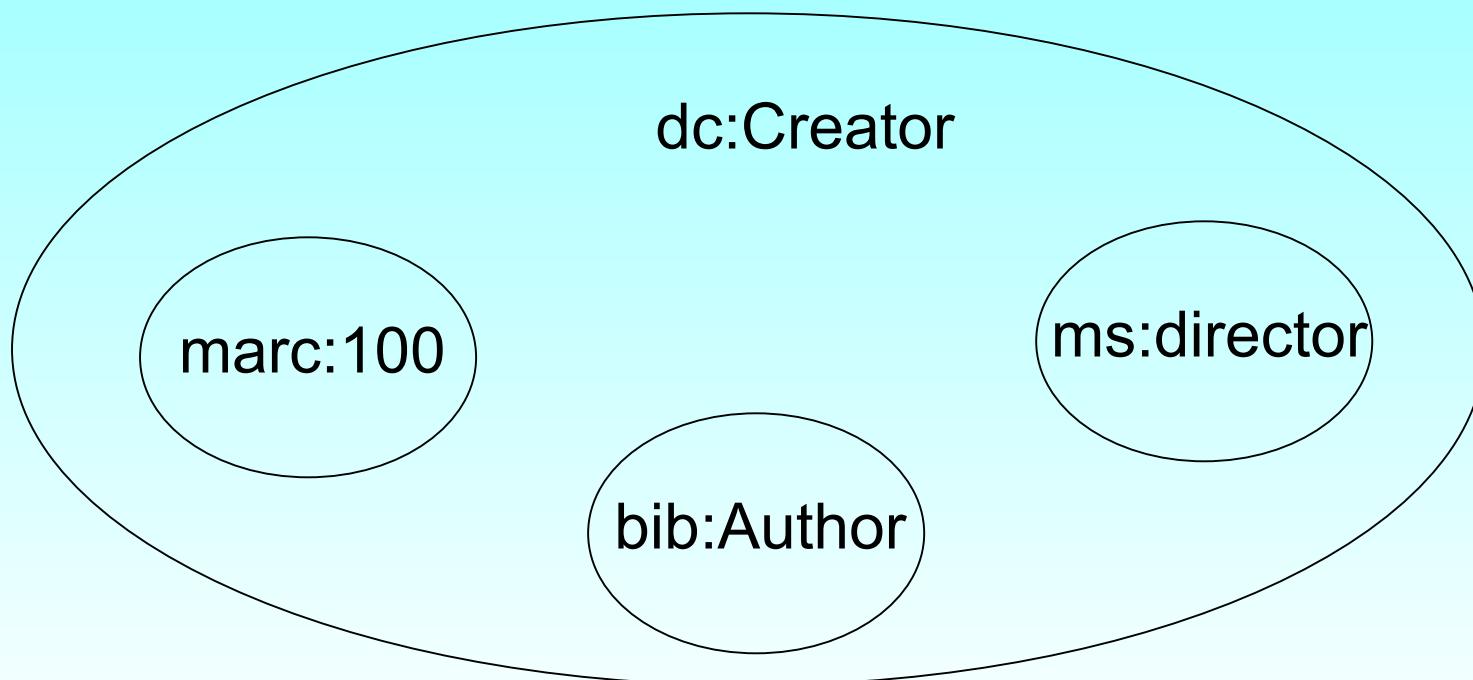
```
<BIB:Author>
  <Bag>
    <li> Miro </li>
    <li> Ivan </li>
  </Bag>
</BIB:Author>
```

- uređena grupa

```
<BIB:Author>
  <Seq>
    <li> Miro </li>
    <li> Ivan </li>
  </Seq>
</BIB:Author>
```

# RDF scheme

- deklaracije rječnika (sadrže definicije značajki)
- omogućuju interoperabilnost



# Ostali standardi

- P3P - Platform for Privacy Preferences Project
- PICS - Platform for Internet Content Selection
- DSig - Digital Signatures
- CC/PP - Composite Capabilities/Preference Profiles
- ...
- korisna adresa:
  - <http://www.w3.org/Metadata/>



# Metapodaci u praksi

- standardi (polako) dozrijevaju
- istraživanja: DC-DOT, Reggie, CORC, MAENAD, Nordic metadata project, SAFARI, ...
- alati:
  - su tu, ali još u razvoju
  - nedostaje veza s ostalim (popularnim) programima
  - traži se bolja konfigurabilnost (sheme, jezici, formati, ...)
  - W3C RDF Validation Service: <http://www.w3.org/RDF/Validator/>

*“Pity the poor fanatic! When he loses sight of his objective he redoubles his efforts!” (Einar Stefferud)*

# Trenutno stanje

- nema pravog standarda (?)
  - Dublin Core je dobar kandidat
- HTML ima META oznaku
  - treba rabiti uz nužan oprez
- pretraživački mehanizmi rabe metapodatke (?)
- korisne adrese:
  - W3C: <http://www.w3.org/Metadata/>
  - Dublin Core: <http://dublincore.org/>



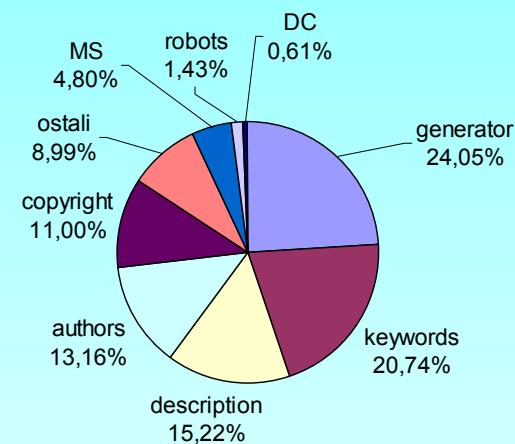
# Trenutno stanje (2)

- oko 800 miliona Web stranica
- 15 TB (6 TB) podataka
- običnu HTML META oznaku ima 34% stranica
- Dublin Core standard poštuje 0,3 % stranica
- META oznaka se šaroliko rabi - 123 različita tipa

*Steve Lawrence, Lee Giles (Nec Institute, February 1999)*

# Metapodaci u hrvatskom Web prostoru

- 31% HTML resursa ima META oznaku
- 744 različite vrijednosti NAME atributa META oznake
- nebriga autora (?)
- udio "standarda":
  - Dublin Core – 0,09%
  - alati za izradu Web stranica – 25%
  - tražilice – 19,7%
  - ROBOTS META oznaka – 1,35%

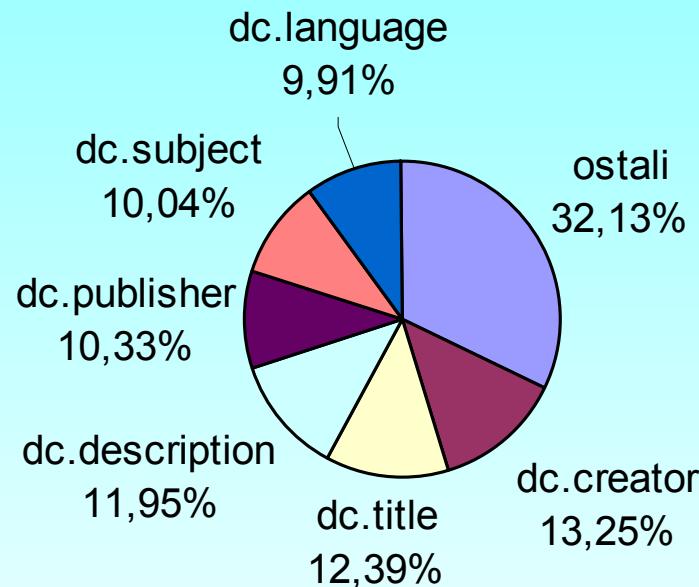


izvor: <http://www.srce.hr/mwp/>



# Dublin Core u hrvatskom Web prostoru

## Frekvencija uporabe različitih DC elemenata



izvor: <http://www.srce.hr/mwp/>

# O čemu je bilo riječi?

- Dio 1. - Pronalaženje informacija na Internetu
  - Internetski prostor informacija
  - pretraživanje Weba
  - tražilice
  - tematski katalozi
- Dio 2. - Metapodaci
  - motivi i koncepti
  - Dublin Core
  - RDF