



VIKMA06

Vyhledávání informací

25. 11. 2016: Přednáška P09: Vyhledávání
netextových informací, vyhledávání a internet

FF MU, podzim 2016

Mgr. Josef Schwarz

126172@mail.muni.cz



Netextové informace

- obraz, zvuk, kombinace
 - textová složka je marginální
- internet
 - velký objem netextových informací
 - omezené možnosti vyhledávání
 - vyhledávače (podle popisku – příklad [1](#), [2](#), [3](#))
- způsoby přístupu
 - prohlížení (příklad [1](#), [2](#))
 - vyhledávání (příklad [1](#))



Indexace netextových inf.

- podstatně složitější než indexace textových inf.
- hlediska indexace/vyhledávání
 - hlediska 1
 - věcnost (ofness) → „tvrdá“ indexace
 - výrazovost (aboutness) → „měkká“ indexace
 - hlediska 2
 - základní vlastnosti (barva, tvar)
 - logické vlastnosti (vztah mezi objekty)
 - abstraktní vlastnosti (metaforický význam)



Vyhledávání netextových inf.

- content-based image retrieval (CBIR)
 - vyhledávání podle obsahu
 - automatické zpracování obrazu (*image processing*)
- description-based image retrieval
 - (context-based, concept-based)
 - vyhledávání podle popisu (kontextu, pojmového vyjádření) (*image indexing*)



CBIR

- vyhledávání na úrovni pixelů
 - QBIC - Query by Image Content (IBM)
- objektové vyhledávání
 - extrahování obrazových objektů
- image mining (dolování obrazových informací)
 - extrakce podobných znaků z celé db
 - extrakce všech vlastností bez prvotní znalosti



Vyhledávání podle popisu

- výhoda: sémantický obsah obrazu
- nevýhoda: subjektivita → inkonzistence indexace
- způsob indexace závisí na typu kolekce a požadavcích uživatelů
- indexace
 - biografických vlastností
 - předmětových vlastností
 - fyzických vlastností
 - vztahových vlastností



Řízené slovníky pro popis netextových dokumentů

- ICONCLASS
- ATT (Art & Architecture Thesaurus)
- Thesaurus for Graphic Materials



Aplikační oblasti


- průmyslové vlastnictví (ochranné známky)
- lékařství
- umění a architektura
- astronomie
- kriminologie
- ...atd.



Vyhledávání a internet

- Skrytý web
- Sémantický web

Neviditelný web





Typy „neviditelnosti“

- Nepřehledný web (Opaque web)
- Soukromý web (Private web)
- Vlastnický web (Proprietary web)
- Skutečně neviditelný web (Truly invisible web)



Nepřehledný web

Obsahuje soubory, které mohou být, ale z určitých příčin nejsou vyhledávací indexované.

Důvody:

- hloubka indexování (depth of crawling)
- frekvence indexování (zprávy, inzerce, ceny akcií)
- maximální počet viditelných výsledků
- odpojené stránky



Soukromý web

Obsahuje stránky, které by robot dokázal zaindexovat, ale správce webu to znemožňuje.

- stránky chráněné heslem
- soubor robots.txt
- metatagy „noindex“, „nofollow“



Vlastnický web

Část webu, ke které je přístup pouze po splnění určitých podmínek.

- stránky vyžadující souhlas s podmínkami pro vstup
- stránky dostupné po zaplacení poplatku



Skutečně neviditelný web

Stránky, které roboty neindexují kvůli svým technickým omezením.

- dynamicky generované stránky
- relační databáze (Oracle, MS SQL Server, IBM DB2)



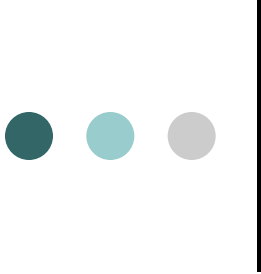
Přednosti hlubokého webu

- specializovaný obsah – komplexnější informace
- sofistikovanější uživatelské rozhraní
- větší důvěryhodnost
- oborovost



Přístup k hlubokému webu

- metavyhledávače
- specializované vyhledávače, katalogy, adresáře
- oborové (předmětové) vyhledávače, katalogy, adresáře
- referenční zdroje
- weby knihoven
- digitální a virtuální knihovny
- oborové databáze
- weby organizací
- knihy (archivy, e-books)
- blogy



Výběr vyhledávačů hlubokého webu

- [Complete Planet](#)
 - adresář více než 70 000 databází a specializovaných vyhledávačů
- [ResourceShelf](#)
 - blog s informacemi a novinkami o informačních zdrojích (připravovaný informačními profesionály)



Sémantický web



klasický x sémantický web

- Tvořen tak, aby jeho obsahu porozuměl pouze člověk
- Citlivý na použitou terminologii
- Nalezených dokumentů je obvykle příliš mnoho nebo naopak příliš málo (případně žádné)
- Výsledkem vyhledávání je pouze jedna stránka
- Rozšíření klasického webu
- Obsah ve strojově přístupné formě
- Vyhledávání podle klíčových slov nahrazeno zodpovídáním dotazů
- Dotaz je možno zodpovědět na základě extrakce informací z více stránek



Klasická podoba webu

<h1>Agilitas Physiotherapy Centre</h1>

Welcome to the home page of the Agilitas Physiotherapy Centre.

Do you feel pain? Have you had an injury? Let our staff

Lisa Davenport, Kelly Townsend (our lovely secretary)

and Steve Matthews take care of your body and soul.

<h2>Consultation hours</h2>

Mon 11am - 7pm

Tue 11am - 7pm

Wed 3pm - 7pm

Thu 11am - 7pm

Fri 11am - 3pm<p>

But note that we do not offer consultation

during the weeks of the

State Of Origin games.



Web s explicitními metadaty

- *XML + XML schéma*
- *RDF + RDF schéma*


```
<company>
  <treatmentOffered>Physiotherapy</treatmentOffered>
  <companyName>Agilitas Physiotherapy
    Centre</companyName>
  <staff>
    <therapist>Lisa Davenport</therapist>
    <therapist>Steve Matthews</therapist>
    <secretary>Kelly Townsend</secretary>
  </staff>
</company>
```



Sémantický web

- Základní složky (předpoklady) SW
 - strukturace dokumentů
 - vyjádření sémantiky - ontologie
 - vyhledávací nástroje - agenti
- standardy
 - syntaktická složka
 - URI
 - strukturální složka
 - XML
 - sémantická složka
 - RDF + RDFS (schéma RDF)
 - OWL, OIL

Vrstvy sémantického webu





Sémantický web – příklady řešení

- W3C
- příklad aplikace RDF
 - energetika
- Výzkum
 - The Open University London, Knowledge Media Institut
 - Magpie
 - Stanford Knowledge Systems Laboratory
 - DAML (agenti)
 - EU, 5. rámcový program
 - On-to-knowledge