

Věcné vyhledávání pomocí věcných SJ - cvičení

Předmět: Selekční jazyky
10. 12. 2010

Přednášející: Mgr. Silvie Kořínková Presová
<http://kisk.phil.muni.cz/mgr-silvie-korinkova-presova-dis>

Úvod do věcného vyhledávání

věcné vyhledávání - ang. ekv. - subject searching

- tj. vyhledávání, kdy uživatel/rešeršér usiluje o nalezení dokumentů k určitému tématu **X** Uživatel ví, jaký dokument hledá, zná např. autora, část titulu apod.

Jeden z klíčových problémů při vyhledávání v rešeršních systémech:

Jaké vyhledávací výrazy by měly být vybrány pro formulaci dotazu?

→ *Odkud by měly být termíny vybrány?*

Interaction in Information Retrieval : Selection and Effectiveness of Search Terms / A. Spink, T. Saracevic

Výzkum zdrojů a efektivnosti využití vyhl. výrazů během zprostředkovaného online vyhledávání.

Identifikace 5-ti zdrojů:

- ☞ **dotaz uživatele** – termíny získané z písemně formulované žádosti, formulace informačního problému
- ☞ **interakce s uživatelem** – využití jeho znalostní struktury, termíny navržené uživatelem během interakce
- ☞ **termíny navržené rešeršérem** – před či během vyhledávání
- ☞ **řízené slovníky**
- ☞ **termíny zpětné vazby, tj. získané z vyhledaných záznamů** – termíny navržené uživatelem či rešeršérem z vyhledaných záznamů, které byly uživatelem uznány jako relevantní

Úvod do věcného vyhledávání

Věcné vyhledávání lze realizovat

- pomocí pořádacích znaků věcných SJ – deskriptorů, předmětových hesel, klasifikačních znaků
- pomocí přirozeného jazyka

V praxi se doporučuje kombinovat vyhledávání pomocí přirozeného jazyka i pomocí věcného SJ – obojí v konkrétních případech přispívá ke zlepšení přesnosti a úplnosti.

Efektivní věcné vyhledávání vyžaduje následující druhy znalostí:

- Znalost polí, které mohou být pro vyhledávání využity a jejich charakteristiky.
- Znalost věcného SJ, který systém využívá.
- Znalost strategií, kde a jak je aplikovat.
- Znalost vyhledávacích možností systému a jak je použít.
- Znalost tématu.

(Poo, 2005)

Efektivní věcné vyhledávání vyžaduje následující druhy znalostí:

- Znalost toho, jak převést informační požadavek na informační dotaz.
(Poo, 2005)

Příklad:

- Informační požadavek:
Využití aplikací webu 2.0 v knihovnách.
- Informační dotaz
SU(Web 2.0) AND SU(libraries)

Formulace dotazu pomocí SJ

Převedení na pořádací znaky věcného SJ

→ Odvíjí se od schopnosti rešeršéra pracovat s věcným SJ (ale mnohé rešeršní systémy nabízejí řízené termíny po zadání prvního dotazu)

Převod může mít různé podoby:

1. termín v seznamu je shodný s řízeným termínem
2. termín v seznamu je synonymem/ekvivalentem – více ekvivalentů – výběr významově shodného řízeného t.
3. pro termín v seznamu existuje pouze širší termín SJ – ztráta specifickosti původního termínu
např. v tezauru databáze LISTA (EBSCO) nelze vyjádřit termín **thesauri** jako deskriptor, použití nadřazeného deskriptoru **subject headings**
4. pro termín v seznamu existují pouze speciálnější/podřazené termíny SJ – rozsah původního termínu je redukován
např. v SVA – nelze vyjádřit - organizace poznání

Formulace dotazu pomocí SJ - příklad v db ProQuest

Informační požadavek:

Využití tvůrčího psaní v psychoterapii či pro zlepšení duševního zdraví.

Pojmová analýza:

tvůrčí psaní

inventive writing

psychoterapie

psychotherapy

duševní zdraví

mental health

Deskriptory z tezauru:

Psychotherapy, Mental health, Creative writing

Informační dotaz:

SUB(Psychotherapy) OR SUB(Mental health)) AND
SUB(Creative writing)

Formulace dotazu pomocí SJ - cvičení v OPACu Aleph NK ČR

Informační požadavek: Nalezněte v katalogu NK ČR dokumenty pojednávající o postavení žen ve společnosti v ČR.

Temat. autority ze SVA

ženy

společenské poměry, společenské postavení
Česko

Informační dotaz: WKW=(česko AND ženy) AND
WKW=("společenské poměry" OR "společenské
postavení")

Formulace dotazu pomocí SJ - cvičení

- Jakými jinými tematickými autoritami ze SVA byste nahradili chybný termín organizace poznání/pořádání informací?
 - zpracování dokumentů
 - zpracování informací
 - selekční jazyky
 - katalogizace

Selekční jazyk - usnadňuje vyhledávání tím, že

→ umožňuje kontrolovat **synonyma a kvazisynonyma** (tím zvyšuje úplnost - vyhledání relevantních informací v databázi)

např. v tezauru ProQuest deskriptor Taxonomy

Used for: Scientific classification

Vyhledávání pomocí znaků SJ - stačí jeden termín/deskriptor
Taxonomy

Vyhledávání pomocí neřízených termínů - k zajištění úplnosti je nutné zohlednit více variant - **(taxonom?) OR (scientific classification)**

→ umožňuje rozlišit **homonyma**, kvalifikátor v závorce (tím zlepšuje přesnost - vyloučení irelevantních výsledků)
např. **Soubor věcných autorit NK ČR** (SVA) *postmodernismus (literatura), postmodernismus (kultura)*

Selekční jazyk - usnadňuje vyhledávání tím, že

→ poskytuje vysvětlující poznámky

např. v tezauru ProQuest poznámka k deskriptoru **Central content management systems** Scope Note: *Systems that enable the management of data and workflow in a collaborative environment; includes web CMS and enterprise CMS,*

v SVA **Informační věda** - Teoreticko-praktický interdisciplinární vědní obor zaměřený na výzkum a zabezpečení informačně-komunikačních procesů ve společnosti.

v tezauru db LISA **Information retrieval** - *Very general - avoid if possible*

Selekční jazyk - usnadňuje vyhledávání tím, že

→ zobrazuje vztahy – hierarchické, asociace, ekvivalence – využití při specifikaci či zobecnění dotazu
např. v db **LISTA (EBSCO)** hledáme **články o folksonomiích**

deskriptor *FOLKSONOMIES*, možnost rozšířit výsledek vyhledávání pomocí asociovaného deskriptoru TAGS (Metadata)

Selekční jazyk - usnadňuje vyhledávání tím, že

→ vyjadřuje termíny, které nejsou obsaženy v záznamu

např. v katalogu NK ČR Hrdinové Pacifiku / Edwin P. Hoyt

SOD:

námořní letectvo -- Spojené státy americké -- 1939-1945

námořní letci -- Spojené státy americké -- 1939-1945

stíhací jednotky -- Spojené státy americké -- 1939-1945

letecké operace -- Spojené státy americké -- 1939-1945

druhá světová válka, 1939-1945 -- Tichý oceán

Selekční jazyk - usnadňuje vyhledávání tím, že

- odstraňuje problémy se syntaxí

Dokument je reprezentován těmito slovy
v přirozeném jazyku:

např. vyhledávací výrazy:

import, export, Česká republika, Norsko

Možné významy

- ☞ dovoz do České republiky z Norska
- ☞ dovoz do Norska z České republiky

Řešení pomocí PH – dán kontext, hledání pomocí fráze

! Vyzkoušejte v katalogu NK ČR - „**letectvo Japonsko**“ versus **letectvo AND Japonsko**

Selekční jazyk

Při vyhodnocování relevantnosti výsledků vyhledávání (řazení vyhledaných záznamů) mají selekční jazyky větší váhu než slova přirozeného jazyka

PROČ?

Pořádací znak SJ byl přiřazen dokumentu na základě obsahové analýzy, z toho plyne indexace/postižení významného tématu, a to je pro vyhodnocení dotazu relevantnější.

příklad: db LLIS: <http://www.hwwilson.com/Documentation/WilsonWeb/searchrules.htm>

Selekční jazyk – slabé stránky

→ nedostatek specifičnosti

SOD - Online katalog
Národní knihovny ČR -
indexace pomocí SVA

Viceslovné
předložky
v současné
češtině

Renata Blatná

http://www.korpus.cz/cechova-kniha-renata-blatna-soucasne-cestiny

Předmět. heslo	 čeština
	 předložky (lingvistika)
	 korpusová lingvistika
Forma, žánr	* monografie

Selekční jazyk – slabé stránky

- není okamžitá aktualizace – časová prodleva než je termín zahrnut do slovníku SJ, např. termín „ontologie“ (nástroj sémantického webu)“ v SVA
- slova autora mohou být nesprávně interpretovaná – nepochopení látky
- časové ztráty související s tvorbou, údržbou a osvojením si SJ

Selekční jazyk – slabé stránky

- některá téma mohou být při indexování opomenuta – např. indexace článku Kapucu, A. Getting users to library resources: A Delicious alternative. *Journal of Electronic Resources Librarianship* [serial online], December 2008; Vol. 20, Issue 4, p228-242 v DB LISTA. Chybí deskriptor FOLKSONOMIES

Selekční jazyk – slabé stránky

- chyby v indexaci zapříčinují ztráty
- rešeršéři se musí učit selekční jazyk
- nekompatibilita – znesnadnění paralel. vyhledávání, bariéra snadné výměny
 - různé pořádací znaky označující jeden pojem - např. označní pro *věcné SJ*
db LLIS *Indexing vocabularies* Used for: Controlled vocabulary; Descriptors; Index languages, Index terms; Indexing languages; Vocabulary control
 - db LISA Controlled vocabulary, Index languages, Retrieval languages
 - anglická literatura - notace **820** (DDC) X notace **PR** (LCC) X notace **821.111** (MDT)

Odlišný zkušenostní rámec indexátora a uživatele

Uživatel popisuje něco, co nezná. Na druhé straně indexátor má dokument v ruce, „všechno je před ním“.

Indexátor by měl zkoušet předvídat, podle jakých termínů budou vyhledávat uživatelé. **Jakou informaci jim daný dokument poskytne, že povede k uspokojení jejich informační potřeby?**

Odlišný zkušenostní rámec indexátora a uživatele

Indexátoři neindexují dokumenty takovým způsobem, aby zachytily nekonečně mnoho rozmanitých dotazů.

- Většinou jsou indexována hlavní a dílčí téma, tj. what is in the record.

ALE

- Nekonečně mnoho dotazů může být uspokojeno dokumentem.
- Jde o úhel pohledu - document-oriented approach x user-centered indexing

Přirozený jazyk - výhody

- vysoká specifičnost ovlivňuje pozitivně přesnost - např. vlastní jména (osob, institucí apod.)
- schopnost vyčerpávajícím způsobem pokrýt téma, zvyšuje úplnost - neplatí u neanotovaných záznamů, zejména tam, kde je zahrnut abstrakt a plný text
- aktualizace – nové termíny jsou okamžitě dostupné
- slova užitá autorem – nemůže dojít k dezinterpretaci indexátorem
- snadnější výměna materiálu mezi databázemi – jazyková neslučitelnost odstraněna
- není třeba se jazyku učit (rodilý mluvčí)

Přirozený jazyk – slabé stránky

- intelektuální úsilí rešeršéra – problém související se synonymy (formulace dílčích dotazů) a homonymy (nutnost uvedení do kontextu)
- problémy se syntaxí – nesprávné spojení termínů, asociace – řešení pomocí proximitních operátorů
- schopnost vyčerpávajícím způsobem pokrýt téma může vést ke ztrátě přesnosti
- odlišná terminologie u jednotlivých autorů

Doporučená a použitá literatura

- Aitchison, J. *Thesaurus construction and use : a practical manual.* London : Aslib, 2000. Kapitola B1, *Is a thesaurus necessary?*, s. 5-7. ISBN 0851424465
- Bates. *Indexing and Access for Digital Libraries and the Internet : Human, Database, and Domain Factors.* *Journal of the American Society for Information Science and Technology.* 1998, roč. 49, č. 13.
- Chu, H. *Information representation and retrieval in the digital age.* Medford : Information Today, 2007. Kapitola 4, *Language in Information Representation and Retrieval*, s. 47-58.
- Poo, D. C. C.; Khoo, C. S. G. *Online Catalog Subject Searching.* In *Encyclopedia of Library and Information Science 1* [online]. 2005, č. 1 [cit. 2007-02-27]. Dostupné na World Wide Web:
<http://www.dekker.com/sdek/abstract~db=enc~content=a713531961>
- Spink, A., et. al. *Interaction in information retrieval : selection and effectiveness of search terms.* *Journal of the American Society for Information Science,* 1997, roč. 48, č. 8, s. 741-61.