

# **Dotazování nad databázemi textů**

## **slajdy k přednášce NDBI006**

Jaroslav Pokorný

MFF UK, Praha

[pokorny@ksi.mff.cuni.cz](mailto:pokorny@ksi.mff.cuni.cz)

# Vývoj DIS



systémy zpracování  
sekundárních informací

systémy zpracování  
úplných textů

digitální  
knihovny

## Zdroje:

- vznik textů přímo v počítači
  - potřeba - vyhledávat, nejen listovat
  - ne vždy možné indexovat
- rozvoj velkých pamětí (CD ROM, WORM, hard disky\*)
- rozvoj komunikací (Internet)

# *Obsah*

1. Úvod
2. Měření relevance
3. Boolský model
4. Vektorový model
5. Zpětná vazba
6. Tezaurus
7. SQL/MM – Full-text
8. Závěr

# Vyhledávání v textech

*dotaz* - požadavek formulovaný v nějakém jazyku bývá zadán vzorkem textu (slovo, výraz, část slova, nebo i celý text) nebo několika vzorky (*konjunktivní dotaz*)

Obecněji: Boolský výraz

*odpověď* (množina *hitů*) - texty vyhovující dotazu

*relevance hitu* - míra rozsahu, kterou se hit shoduje s požadavkem uživatele

omezení odpovědi - maximálně M

- maximálně M nejrelevantnějších
- zadání prahové hodnoty  $\Theta$



# Vyhledávání v textech

Obor: **Information Retrieval**

(Vyhledávání informací)

IR je vše o vyhledávání toho, co chcete, když to, co chcete, je skryto v mase toho, co nechcete.

Přesněji: nalézt k dotazu relevantní dokumenty

Obor: **Information Filtering**


(Filtrování informací)

Přiřadit k dokumentu D profily tak, že D je pro ně relevantní.

# *DIS - základní architektura*

Subsystémy: zpřístupnění textu (1)  
dodání textu (2)


(1) viz informační služby  
sekundární informace vs. úplné texty



# *DIS - základní architektura*

Subsystémy: zpřístupnění textu (1)  
dodání textu (2)


(1) viz informační služby  
sekundární informace vs. úplné texty



# Měření relevance


*koeficient úplnosti R* (z angl. recall)

$$R = \frac{\text{\#vybraných relevantních záznamů}}{\text{\#relevantních záznamů v souboru}}$$




*koeficient přesnosti P* (z angl. precision)

$$P = \frac{\text{\#vybraných relevantních záznamů}}{\text{\#vybraných záznamů}}$$



# *Měření relevance*



# *Boolský model*

- reprezentace dokumentů: pomocí množin termů
- dotazování:
  - formálně: pomocí Boolských výrazů
  - způsob: na přesnou shodu
- nalezení termů - praxe:
  - odstranění **nevýznamových slov** (stop-words) z množiny termů
    - výsledek: redukce 30-50% (C.J. van Rijsbergen)
  - lingvistické zpracování (tokenizace)

# Boolský model

Jedna z možných syntaxí:

<term>

<jméno\_atributu> = <hodnota\_atributu> /porovnání/  
<jméno\_funkce>(<term>), /aplikace funkce/

X AND Y vyber D, obsahující jak X, tak Y.

X OR Y vyber D, obsahující buď X nebo Y.

X XOR Y vyber D, obsahující buď X nebo Y ale ne X AND Y

NOT Y vyber D, neobsahující Y

X adj Y vyber D, ve kterých se vyskytuje X následovaný Y

X (n)words Y vyber D, ve kterých se vyskytuje X následovaný Y nejdále ve vzdálenosti  $n$  slov

X sentence Y vyber D, ve kterých se vyskytuje X a Y ve stejné větě

# Boolský model

- . odpovídá libovolnému znaku.
- \* znak následovaný \* odpovídá libovolnému počtu výskytů (včetně nulového) tohoto znaku. Např.  $xy^*$  odpovídá  $x, xy, xyy$  atd.
- + znak následovaný + odpovídá libovolnému počtu výskytů (kromě prázdného) tohoto znaku. Např.  $xy^+$  odpovídá  $xy, xyy, xyyy$  atd.
- [] Znaky v [] odpovídají libovolnému jednomu znaku, který je v závorkách uveden, ale ne jinému. Např. [xyz] odpovídá x, y nebo z.
- [^] ^ na začátku řetězce v [] znamená negaci (not). Např.  $[^xyz]$  odpovídá libovolnému znaku kromě x, y nebo z.
- [-] – mezi znaky v [] označuje rozsah znaků. Např. [a-x] odpovídá libovolnému znaku od a do x.

# Boolský model: $P$ vs. $R$

- Upřesňováním dotazu v Boolském modelu získáváme větší  $P$ , ale menší  $R$ .

Př.: pokus (Blair, Maron, 1985) - 40000 právnických textů

Cíl: nejen vysoké  $P$ , ale i  $R$ .

Výsledky:  $P \rightarrow 80\%$ ,  $R \rightarrow 20\%$

Problém synonym - obecný jazyk, nelze podchytit tezaurem.

Př.: nehoda, neštěstí srážka, karambol, „něco se tam stalo“, ...

- automatická indexace neodstraní tyto problémy

# Boolský model: problémy

Co ovlivňuje vztah P a R?

Problémy s ručně indexovanými systémy:

*neurčitost*

- v indexování *vliv indexátora*
- ve výběru termů pro dotaz *vliv tazatele*

Př.:  $p_1, p_2$  pravděpodobnosti, že uživatel užije termy  $t_1, t_2$

$q_1, q_2$  pravděpodobnosti, že termy  $t_1, t_2$  se vyskytují v D

$\Rightarrow p$ , že tazatel zvolí  $t_1, t_2$  a vyhledá se D s  $t_1, t_2$ , je

$$p_1 * p_2 * q_1 * q_2$$

např.  $R = 0,6 * 0,7 * 0,5 * 0,6 = 0,126 \Rightarrow R < 13\%$

$\Rightarrow$  pro  $i=5$ ,  $p_i = q_i = 0,5 \Rightarrow R = 0,1\%$

$\Rightarrow$  je-li 1000 relevantních D, vybere se 1 !

# Boolský model: problémy

*kritérium predikce* - jak zajistit shodu mezi výběrem termů pro dotaz a dokumenty (dnes: podobnost ontologií)


- metoda: odstraňování neurčitosti

*kritérium maxima* - lze zvládnout 20-50 hitů

Problémy s db úplných textů:

- *velikost db* (vs. kritérium maxima)
- *výběr termů pro dotaz*
  - přecenění eliminace indexátorů
  - zůstává neurčitost tazatele
- *jednostranné chování tazatele* -  
tendence měnit poslední rozhodnutí, zachovávat první kroky

# Boolský model: problémy



hit

$A \cap B \cap C \cap D$

$A \cap B \cap C \cap E$

# *Boolský model: problémy*

*Řešení neurčitosti ve výběru termů pro dotaz:*

- najdeme D s vysokou relevancí pro uživatele (D je znám + je známo, že je v db),
- termy pro dotaz jsou vybrány z D,
- odstraňování termů resp. jejich nahrazování disjunkcemi.  
⇒ zmenšování neurčitosti tazatele

# *Boolský model: problémy*

*Řešení jednostranného chování tazatele vážením:*

| Př.:              | termy                   | pravděpodobnost (váha) |
|-------------------|-------------------------|------------------------|
| Autor:            | Pokorný                 | 0,3                    |
| Datum:            | 1995-1999               | 0,7                    |
| Časopisy:         | CW                      | 0,2                    |
|                   | Artificial Intelligence | 0,5                    |
|                   | ERCIM News              | 0,2                    |
| Předmětová hesla: | XML                     | 0,6                    |
|                   | databáze                | 0,8                    |
|                   | dotazovací jazyky       | 0,9                    |

Celkový počet konjunktivních dotazů je 255


# Boolský model: problémy

Součiny pravděpodobností pro

| 2 termy                   | 3 termy                            | max. pro 1, 2, ... |
|---------------------------|------------------------------------|--------------------|
| $p_{do} * p_{da} = 0,72$  | $p_{do} * p_{da} * p_{dat} = 0,5$  | 0,9                |
| $p_{do} * p_{dat} = 0,63$ | $p_{do} * p_{dat} * p_{xm} = 0,38$ | 0,72               |
| $p_{da} * p_{dat} = 0,56$ | $p_{do} * p_{da} * p_{ar} = 0,4$   | 0,5                |
| ...                       | ...                                | 0,3                |
|                           |                                    | 0,15               |

Algoritmus:

- vytvoř skupiny pro všechny kombinace
- spočti pro skupiny maxima
- je splněno kriterium maxima?
- nabídka tazateli



# *Boolský model: další problémy*

- Neintuitivní výsledky
  - A AND B AND C AND D AND E

D neobsahující pouze jeden z uvedených termů nebude vybrán.
  - A OR B OR C OR D OR E

D obsahující pouze jeden z uvedených termů jsou chápány jako stejně významné jako dokumenty obsahující všechny uvedené termy.
- Neumožňuje řízení velikosti výstupu.
- Všechny D vyhovující dotazu jsou chápány jako stejně důležité, není možné je uspořádat podle hodnoty relevance.

# *Boolský model: další problémy*

- Obtížně lze realizovat automatickou zpětnou vazbu, tj. na základě  $D$  označených v odpovědi za relevantní automaticky modifikovat dotaz.
- Vyjadřovací síla Boolského modelu je omezená. Jakákoli množina  $\{D\}$  popsatelná pomocí termů, může být v principu vybrána vhodným Boolským dotazem. Není ale garantováno, že pro jakoukoliv množinu  $\{D\}$ , které jsou v uživatelově zájmu, je v praxi jednoduché formulovat Boolský dotaz.
- Spíše umění než věda.

# Jak dál

Teze:

klasické Boolské systémy lze rozšířit o funkce  
ovlivňující kriterium maxima; nelze však současně  
dosahovat vysokého P i R bez přídavných informací.

# Přehled IR modelů

u  
ž  
i  
v  
a  
t  
e  
l  
ú  
v  
c  
í

Výběr:  
ad hoc  
filtrování

Listování



množinově teoretické  
fuzzy  
rozšířená Boolská logika

algebraické  
zobecněný vektorový LSI  
Neuronové sítě

pravděpodobnostní  
inferenční sítě  
věrohodnostní (belief) sítě

# Vektorový model

Předpoklad: kolekce  $m$  dokumentů  $\mathbf{D}$ ,  $n$  různých termů  $t_1 \dots t_n$   
Každý dokument  $D_i \in \mathbf{D}$  je reprezentován vektorem

$$D_i = (w_{i1}, w_{i2}, \dots, w_{in}), \text{ kde } w_{ij} \in \langle 0;1 \rangle$$

kde  $w_{ij}$  je váha náležející termu  $t_j$  v identifikaci dokumentu  $D_i$ .

$\mathbf{D}$  je reprezentovatelná maticí

$$\begin{matrix} w_{11} & w_{12} & \dots & w_{1n} \\ w_{21} & w_{22} & \dots & w_{2n} \\ \mathbf{D} = \dots & & & \\ \dots & & & \\ w_{m1} & w_{m2} & \dots & w_{mn} \end{matrix}$$

# Vektorový model

- dotazování:
  - formálně: pomocí vektoru dotazu
  - dotazování na částečnou shodu  
způsob: pomocí funkce (koeficientu) podobnosti

*výraz dotazu Q ve vektorovém modelu*

$$Q = (q_1, q_2, \dots, q_n), \text{ kde } q_j \in <0;1>.$$

Problém: jak počítat podobnost

# Vektorový model

## Úhel vs. vzdálenost

- Proč ne vzdálenost?
- Experiment: vezmeme dokument D a připojíme ho ještě jednou k D. Vznikne dokument D'.
- “Sémanticky” mají D a D' stejný obsah.
- Euklidovská vzdálenost mezi body v prostoru mezi D a D' (body prostoru) by byla velká
- Úhel mezi D a D' (jako vektorů) je 0, koresponduje maximální podobnosti.
- Klíčová idea: Pořadí dokumentu D podle úhlu, který svírá s vektorem dotazu Q.
- Vhodná: cosinus - klesající funkce v intervalu  $[0^\circ, 180]$

# Vektorový model

*koeficient podobnosti* (angl. *similarity*) dotazu Q a dokumentu  $D_i$

(a)  $Sim(Q, D_i) = \sum_{k=1, \dots, n} (q_k * w_{ik})$  (*skalární součin*)

(b)  $Sim(Q, D_i) = \sum_{k=1, \dots, n} (q_k * w_{ik}) / \sqrt{(\sum_{k=1, \dots, n} (w_{ik})^2 * \sum_{k=1, \dots, n} (q_k)^2)}$   
*(kosinová míra)*


Dělitel v (b) je *normalizační faktor*,

(c)  $Sim(Q, D_i) = 2 \sum_{k=1, \dots, n} (q_k * w_{ik}) / (\sum_{k=1, \dots, n} (w_{ik})^2 + \sum_{k=1, \dots, n} (q_k)^2)$   
*(Diceův koeficient)*

**Postulát:** Dokumenty, které jsou ve vektorovém prostoru „blízko sebe“ vypovídají o stejných věcech

# Vektorový model

geometrická interpretace



Pz.: *binární vektorový model* (tj. jediné nenulové  $w_{ik}$  v  $D_i$  i  $Q$  jsou rovny 1).

Pro všechny tři případy  $Sim =$

- $|Q \cap D_i|$
- $(|Q \cap D_i|)(\sqrt{|Q|} * \sqrt{|D_i|})$
- $2(|Q \cap D_i|)(|Q| + |D_i|)$

# Vektorový model

Výhody: R i P lze zvýšit až o 20%.

Pragmatický přístup: jednoslovné termy + vhodná metoda vážení

$TF_{ij}$       *frekvence termu  $t_j$  v dokumentu  $D_i$*

$NTF_{ij}$       *normalizovaná frekvence termu  $t_j$  v dokumentu  $D_i$*

$$((TF_{ij}/\max TF_{ik})+1)/2$$

kde max je přes všechny termy v  $i$ -tém řádku matice  $\mathbf{D}$ .

Nevýhoda: term s vysokou TF v mnoha  $D_i \Rightarrow$  nízký P

# Vektorový model

*IDF inverzní frekvence termu v dokumentech*

klesá se zvyšujícím se počtem dokumentů, ke kterým je term přiřazen.

*IDF* pro term  $t_j$  je definována jako

$$IDF_j = \log(m/DF_j) + 1$$

kde  $m$  je celkový počet dokumentů v  $\mathbf{D}$  a  $DF_j$  je frekvence  $t_j$  v  $\mathbf{D}$ , tj. počet dokumentů, ke kterým je term  $t_j$  přiřazen.

Pz.:

- Pro řazení dokumentů není základ logaritmu důležitý
- IDF je skutečně inverzní vzhledem k DF.

# Vektorový model

Chování:

term se vyskytuje ve všech dokumentech  $\Rightarrow \log(1) = 0$  (term patří mezi nevýznamová slova)

term se vyskytuje pouze v 1 dokumentu  $\Rightarrow$

$$IDF = \log m + 1$$

Př.: pro  $m = 10$  je  $IDF = 2$ , pro  $m = 10\ 000$  je  $IDF = 5$  atd.

# Vektorový model

*TD rozlišení pomocí termů* (vysoké TF i IDF)

$$TD_{ij} = TF_{ij} * IDF_j \text{ nebo } TD_{ij} = NTF_{ij} * IDF_j$$

Značení v literatuře: tf-idf, tf.idf, tf x idf

Pak:  $w_{ij}$  se *definuje jako*  $TD_{ij}$

Pz.: nevyplatí se udržovat příliš malé váhy termů (k prahové hodnotě).

Nejlepší váhy v Q:

$$q_k = (0,5 + (0,5 * TF_k) / \max TF) * IDF_k$$

kde  $TF_k$  je frekvence termu  $t_k$  v Q,  $\max TF$  je maximální frekvence nějakého termu v Q a  $IDF_k$  je *IDF* termu  $t_k$  v D.

# Vektorový model

Speciální případy pro Q a D:

- zadána pouze množina termů  $\Rightarrow q_k = IDF_k$
- dlouhé dotazy approximace  $q_k = TF_k$
- krátké dokumenty  $\Rightarrow$  approximace vah pomocí 0, 1
- dlouhé dokumenty  $\Rightarrow$  jednotkou výběru *pasáž*



# Vektorový model: problémy

- předpoklad: nezávislost termů
- chybějící syntaktická informace (fráze, pořadí slov, vzdálenosti)
- chybějící sémantika: polysémie (2 slova stejně zní a jejich významy mají nějakou genetickou souvislost), synonymita stále neřešeny

Historie: součást systému SMART (1970)

Dnes: open source software Apache Lucene (od r. 1999) – kombinuje vektorový a Boolský model

# Vektorový model v Boolském systému - příklad implementace


Předpoklady:

- soubor indexů s invertovanými seznamy
- v invertovaných seznamech  $TF_{ji}$  (modelujeme jimi  $w_{ji}$ )
- soubor obsahující  $IDF_j$
- soubor SKÓRE[1:m]
- Váhy termů dotazu jsou rovny 1

Algoritmus:

- (1) podle termů dotazu přistupuj invertované seznamy.
  - (1.1) Oprav součty v SKÓRE
- (2) Setříd SKÓRE a vydej např. 20 nejvyšších.

# Vektorový model v Boolském systému - příklad implementace



# Vektorový model a signatury - příklad implementace




Předpoklady:

- $D_j$  má  $b_j$  bloků, dotaz má Q termů
- soubor signatur - pro každý blok existuje signatura
- soubor obsahující  $IDF_i$  (modelujeme jimi  $q_i$  - stačí  $DF$ )
- soubor SKÓRE[1:20] (udržuje se 20 nevyšších)

Algoritmus: Pro všechny  $D$  proved:


- (1) Vynuluj POM.
- (2) Signaturu každého z  $b$  bloků textu  $D$  porovnej s Q signaturami dotazu. Výsledky ulož do POM.
- (3) Pro každý  $t_i$  dotazu spočti  $bc_i = \sum_{j=1 \dots b_{\max}} POM[i,j]$
- (4) Spočti  $s = \sum_{i=1 \dots Q} (bc_i * q_i) / b$

# Vektorový model a signatury - příklad implementace



# *Složitost indexování vektorovým modelem*

- vytváření vektorů a indexování dokumentu o  $n$  jednotkách je  $O(n)$ .
- indexování  $m$  takových dokumentů je  $O(m \cdot n)$ .
- počítání IDFs lze dělat při téžem průchodu
- počítání délek vektorů je také  $O(m \cdot n)$ .
- $\Rightarrow$  celková časová složitost je  $O(m \cdot n)$



# *Techniky pro “inteligentní” IR*

## 1. Zpětná vazba

- přímá zpětná vazba
- pseudo zpětná vazba

## 2. rozšiřování dotazu

- „přirozeným“ tezaurem
- „umělým“ tezaurem

Výhody: zvyšují R, ale jen zřídka P.

# Zpětná vazba

Intuice:

- vektory relevantního dokumentu a dotazu si jsou podobné
- vektory nerelevantního dokumentu a dotazu si nejsou podobné;

⇒ *reformulace dotazu* na základě odpovědi na dotaz

Předpoklady: vektor dotazu  $\vec{q}$

odpověď obsahuje relevantní  $D_1^r, \dots, D_{mr}^r$   
nerelevantní  $D_1^n, \dots, D_{mn}^n$

# Zpětná vazba

$$\vec{q}' = \alpha \vec{q} + \frac{\beta}{m_r} \sum_{i=1 \dots m_r} \vec{D}_i^r - \frac{\gamma}{m_n} \sum_{i=1 \dots m_n} \vec{D}_i^n$$

pro  $\alpha=1$  Rocchio 71

$$\vec{q}' = \alpha \vec{q} + \beta \sum_{i=1 \dots m_r} \vec{D}_i^r - \gamma \sum_{i=1 \dots m_n} \vec{D}_i^n$$

pro  $\alpha=\beta=\gamma=1$  Ide 71

$$\vec{q}' = \alpha \vec{q} + \beta \sum_{i=1 \dots m_r} \vec{D}_i^r - \gamma \vec{D}_1^n$$

kde  $\alpha, \beta, \gamma$  jsou vhodné konstanty

# Zpětná vazba - inkrementálně

## REPEAT

Systém vybere  $D$  s max.  $\text{SIM}(Q, D)$ ;

Tazatel označí  $D$  za relevantní nebo nerelevantní;

IF  $D$  je relevantní THEN  $D$  jde do výstupního seznamu;

$\vec{q}$  se modifikuje pomocí  $\vec{D}$ ;

## UNTIL $\varphi$

modifikace dotazu:

$$\vec{q}_{j+1} = \begin{cases} \alpha \vec{q}_j + \beta \vec{D}_j & \text{D}_j \text{ je relevantní} \\ \alpha \vec{q}_j - \gamma \vec{D}_j & \text{D}_j \text{ je nerelevantní} \end{cases}$$

Pz.: vybírá se vždy  $D$ , který ještě nebyl vybrán.

# Zpětná vazba – další možnosti

*převážení termů:* zvýšení vah termů v relevantních dokumentech a snížená vah termů v nerelevantních dokumentech

*pseudozpětná vazba:* předpokládej k-prvních dokumentů jako relevantních a podle nich dej upravit dotaz.

# *Rozšíření dotazu pomocí tezauru*

- *tezaurus* (též *thesaurus*, starořecky poklad, pokladnice) poskytuje informace o synonymech a sémanticky vztažených slovech a frázích.
- Př.: Eurovoc – pro oblast práva a legislativy, je od r. 2005 i pro češtinu.

# Tezaurus

Výrazy s použitím tezauru (standard ISO-2788)

|              |                                  |
|--------------|----------------------------------|
| NT('text')   | NARROWER TERM o úroveň užší term |
| NT('text',n) | užší pojmy o <i>n</i> úrovni     |
| NT('text',*) | všechny užší pojmy               |
| BT('text')   | BROADER TERM o úroveň širší term |
| BT('text',n) | širší pojmy o <i>n</i> úrovni    |
| BT('text',*) | všechny širší pojmy              |
| TT('text')   | TOP TERM - nejširší term         |
| SYN('text')  | SYNONYMS - synonyma              |
| PT('text')   | PREFERRED TERM preferovaný term  |
| RT('text')   | RELATED TERMS - příbuzné termy   |

# Tezaurus

Další relace:

SN (scope note) - poznámka připojená k danému termu,

USE - k danému termu přiřazuje jeho preferovaný term,

UF - k danému termu přiřazuje jeho synonymní  
(nepreferovaný) term

Další standard (pro textové DB):

ANSI Z39.58 Common Command Language for Online  
Interactive Information Retrieval - vyvinuty institucí NISO  
(National Information Standards Organization) v r. 1992.

Pz: skutečné jazyky jsou pouze podobné těmto standardům

# Příklad: Wordnet

- detailnější databáze semantických vztahů mezi slovy (pro angličtinu, ..., češtinu).
- vyvinuta Prof. George Millerem a jeho týmem na univerzitě v Princetonu.
- okolo 150,000 anglických slov.
- Podstatná jména, přídavná jména, slovesa a příslovce seskupená do cca 110,000 synonymních množin zvaných *synsety*.

# Příklad: Wordnet

## Příklady typů vztahů:

- antonyma (opozita): vpředu → vzadu
- atributace: dobročinnost → dobrý (od podstatného jména k přídavnému)
- podobnost: bezpodmínečný → absolutní
- příčina: zabítí → úmrtí
- holonyma: kapitola → text (být částí)
- meronyma: počítač → cpu (být částí)
- hyponyma (podřízené pojmy): strom → rostlina (specializace)
- hyperonyma (nadřazené pojmy): ovoce → jablko (generalizace)

# Příklad: Wordnet

- Měření sémantické podobnosti a vztaženosti zavedené pro WordNet Pedersonem, et al v r. 2005 – (software WordNet::Similarity)
- koeficienty podobnosti
  - založené na délkách cest:  
Lch, wup, Path
  - založené na informačním obsahu:  
res, lin, jcn
- koeficienty vztažnosti
  - hso, lesk, vector

# *Texty v SQL: Textový extender (v DB/2)*

```
CREATE TABLE ČLÁNKY(
```

|             |              |
|-------------|--------------|
| časopis     | VARCHAR(50), |
| titul       | VARCHAR(50), |
| datum       | DATE,        |
| text_článku | FULLTEXT)    |

```
SELECT časopis, datum, titul  
FROM ČLÁNKY  
WHERE CONTAINS(text_článku, (“databáze” AND  
(“SQL” | “SQL92”) AND NOT “dBASE”)) = 1;
```

D: Najdi všechny články v časopisech, které obsahují v textu „objektově-relační“ ve stejné větě jako slovo „databáze.“

```
SELECT časopis, titul  
FROM ČLÁNKY  
WHERE CONTAINS(popis, “databáze” IN SAME  
SENTENCE AS “objektově-relační”)
```

# *Texty v SQL: Textový extender (v DB/2)*

Další funkce: **NO\_OF\_MATCHES** (kolikrát se zadaný vzorek vyskytoval v textu), **RANK** (hodnota pořadí v odpovědi na základě nějaké míry).

```
SELECT časopis, titul  
FROM ČLÁNKY  
WHERE NO_OF_MATCHES (text_článku, 'databáze') > 10;  
SELECT časopis, datum, titul, RANK(text_článku, ('"databáze"  
        AND ("SQL" | "SQL92") )) AS relevantní  
FROM ČLÁNKY  
ORDER BY relevantní DESC;
```

možnost  
různých  
implementací

# Texty v SQL: Fulltext v MySQL 5.1

Typy FT vyhledávání:

- Boolské
- FT s indexem

```
CREATE TABLE ČLÁNKY (
    časopis      TEXT
    text_článku  VARCHAR(200)
    FULLTEXT (časopis, text_článku)
) engine=MyISAM
```

```
SELECT *
FROM ČLÁNKY
WHERE MATCH(časopis, text_článku)
AGAINST('database' IN NATURAL LANGUAGE MODE);
```

FULLTEXT je typ indexu

paměťový stroj  
další: InnoDB,...

Třídění výsledku: implicitně dle relevance  
Dotazovací jazyky

# *Texty v SQL: Fulltext v MySQL 5.1*

Typy FT vyhledávání:

- Boolské
- FT s indexem

```
SELECT *  
FROM ČLÁNKY  
WHERE MATCH(časopis, text_článku)  
AGAINST('+database -relational' IN BOOLEAN MODE);
```

Třídění výsledku:


- + (AND), - (NOT), žádný operátor (OR)
- implicitně žádné třídění

# *Texty v SQL: SQL/MM – Full-text*

- Konstruktory
  - Řetězec znaků
  - Řetězec znaků + zadání jazyka
- Konverzi do běžných SQL znak. řetězců
  - FullText\_to\_Character
- Vyhledávací metody
  - Ano/Ne (**CONTAINS**)
  - Rank (**RANK**)


# *Texty v SQL: Full-text - vyhledávání*

- Vzorek (+ wildcards)
- Odvozená slova (**STEMMED**)
- Slova s podobným nebo stejným významem  
(**THESAURUS, SYNONYM**)
- Stejně znějící slova (**SOUNDS LIKE**)
- Dle pozice v textu (**NEAR, ...**)
- Dle konceptu textu (**IS ABOUT**)



# *Texty v SQL: Full-text - vyhledávání*

```
CREATE TABLE INFORMACE (
    číslo_dokumentu INTEGER,
    dokument        FULLTEXT
);
```



## *Texty v SQL: Full-text - vyhledávání*

```
SELECT číslo_dokumentu  
FROM INFORMACE  
WHERE dokument.CONTAINS  
(  
    STEMMED FROM OF "standard"  
    IN SAME PARAGRAPH AS  
    SOUNDS LIKE "sequel"  
) = 1;
```

# Závěr

Současné (nové) aplikace:

- klasifikace textů
- extrakce (sumarizace) textů
- digitální knihovny
- vyhledávání na Webu
- multilingvální prostředí
- detekce spamu
- plagiátorství textů