

# INTEGRACIJA NESTRUKTURIRANIH PODATAKA U DATA WAREHOUSE



M. Srzentić, M. Arbanas

3.10.2010

# SADRŽAJ

- Uvod
- Teoretska podloga
- Primjer iz prakse
- Zaključak
- Q&A

## UVOD

- **Velika količina podataka u nestrukturiranom obliku**
- **Različiti izvori podataka**
  - e-mail, dokumenti, dopisi, ...
  - forumi, blogovi, Facebook, Twitter, Linkedin, ...
- **Odgovori na posebnu vrstu pitanja**
  - Kakvo je mišljenje o našim proizvodima i uslugama?
  - Koliko su zadovoljni naši klijenti?
  - ...
- **Premala iskorištenost mogućnosti**
  - nedostatak strukture
  - nedostatak kvalitetnih alata


## TEORETSKA PODLOGA



## TEORETSKA PODLOGA

### EKSTRAKCIJA PODATAKA

- Različite metode ekstrakcije
  - export/import teksta
  - web crawleri
  - API web aplikacija
- Cilj je isti: dovesti sirove podatke u Data Staging Area



## TEORETSKA PODLOGA

### DOMENSKI POJMOVI

- Pojmovne kategorije

- vremena/datuma
- proizvoda i usluga
- imena (osoba, org. dijelova)
- geografskih lokacija

- Postoje specijalizirane taksonomije

- preopćenite
- preporučeno razvijati i koristiti svoje

# TEORETSKA PODLOGA

## DOMENSKI POJMOVI

- Primjer taksonomije proizvoda tvornice automobila:

1. Vozilo
  - 1.1. Osobno vozilo
    - 1.1.1. Automobil
      - 1.1.1.1. Model Mali
      - 1.1.1.2. Model Mali 2
      - 1.1.1.3. Model CC
      - 1.1.1.4. Model Sport
    - 1.1.2. Motocikl
      - 1.1.2.1. Model Ef 50
      - 1.1.2.2. Model Ef 125
      - 1.1.2.3. Model Ef S250
    - 1.2. Teretno vozilo
      - 1.2.1. Kamion
        - 1.2.1.1. Model 3T
        - 1.2.1.2. Model 7T
        - 1.2.1.3. Model 10T
      - 1.2.2. Kombi vozilo
        - 1.2.2.1. Model DG 2
        - 1.2.2.2. Model DGi

## TEORETSKA PODLOGA

### PARSIRANJE I TAGIRANJE

- Traže se pojmovi iz definiranih kategorija i tagiraju se
  - jednostavni (#) ili XML tag

"U **kolovozu** ove godine počinje prodaja novog modela **iPhonea** u našim trgovinama"

"U <DATUM> kolovozu </DATUM> ove godine počinje prodaja novog modela <PROIZVOD> iPhonea </PROIZVOD> u našim trgovinama"

- Temelj za narativni data mart
  - tagovi po kategorijama se pretvaraju u dimenzije

## TEORETSKA PODLOGA

### DOMENSKO ZNANJE

- Tezaurus – domensko znanje uređeno jednostavnim relacijama
- Ontologija – sličan koncept proširen atributima i većim brojem relacija
  - temelj semantičkog weba
  - OWL i RDF

```
<IVO IVIĆ – godina - 20>
<IVO IVIĆ – zanimanje - STUDENT>
<IVO IVIĆ – otac – PERO IVIĆ>
<IVO IVIĆ – majka – KATA IVIĆ>
```

- Preopširno definirane ontologije
  - potrebno naći optimalan broj tripleta

## TEORETSKA PODLOGA

### POVEZIVANJE POJMOVA

- Cilj: ujedinjavanje značenja i eliminiranje redundancije u pojmovima

```
<DOBAR – sinonim - ODLIČAN>
<DOBAR – sinonim - SUPER>
<DOBAR – sinonim - ZADOVOLJAN>
<DOBAR – sinonim - KORISTAN>
<LOŠ – sinonim - KATASTROFA>
<LOŠ – sinonim - NEPRIKLADAN>
<LOŠ – sinonim - NEUPOTREBLJIV>
<LOŠ – sinonim - PRESKUP>
```

- Moguće definirati i JAKO DOBAR, JAKO LOŠ i NEUTRALAN
  - povećava se mogućnost neispravnog tumačenja podataka

## TEORETSKA PODLOGA

### NARATIVNI I SINTETIZIRANI PODATKOVNI MODEL

- Narativni
  - dimenzije i fact tablice vrlo općenite, veze neobavezne
  - mora postojati referenca na originalne podatke
  - odgovara na veći broj pitanja
  - skloniji greškama
  - indikator povjerenja

- Sintetizirani
  - usko specijalizirana namjena
  - vrlo precizni podaci
  - odgovara na manji broj pitanja – vrlo fokusiran

- Obično jedan narativni i mnoštvo sintetiziranih data martova

## PRIMJER IZ PRAKSE

- Mnoštvo primjera
  - obrada help-desk tiketa,
  - analiza odnosa s klijentima,
  - obrada prijavljenih šteta u osiguranju,
  - usporedba dijagnoza u medicini,
  - analiza interakcija lijekova u farmaciji,
  - rezultati marketinških kampanja...
- Cilj: Dobiti precizne, upotrebljive, općenite i/ili specifične informacije iz mnoštva sirovih podataka

## PRIMJER IZ PRAKSE

- Marketinška kampanja izmišljene pivovare pri plasiraju novog proizvoda
  - Proizvođač: Pivovara Zlatica
  - Proizvod: Zlatno pivo
  - Izvor: Twitter
    - jednostavan izvor
    - olakšano pretraživanje
- Platforma
  - Oracle DB
  - Oracle Text
    - indeksiranje, pretraživanje i analiza teksta
    - ključne riječi, kontekst, teme, korijeni riječi...

## PRIMJER IZ PRAKSE

### DOHVAT KOMENTARA S TWITTERA

Pivoljubac	27.07.2010 12:46:17:	Izašlo novo pivo iz Zlatice, je li itko probao? #zlatnopivo
Majstor	27.07.2010 13:50:50:	Kod nas još nije stiglo u trgovine, ali jedva čekam... #zlatnopivo
Oskosk	27.07.2010 14:00:10:	Meni je pregorko, ne valja :( #zlatnopivo
Pro777	27.07.2010 14:07:34:	Jedno od najkvalitetnijih piva na tržištu, ali preskupo #zlatnopivo
Veseli	27.07.2010 14:31:10:	Meni je cijena OK, okus super, ja odsad pijem samo #zlatnopivo
Mrgud	27.07.2010 14:59:59:	Ambalaža totalni #fail, ostalo može proći

## PRIMJER IZ PRAKSE

### DEFINIRANJE POJMOMA O PROIZVODU I DOJMU

pivo, pivovara, zlatica, zlatno, hmelj, okus, cijena, ambalaža, skupo, jeftino, prihvatljivo, OK, dobro, loše, ukusno, najbolje, najgore, gorko, blago, fail, win, kvalitetno, super, katastrofa, ...

#### DOM\_POJMOVI

ID	Number
POJAM	Varchar2(140)
KATEGORIJA	Varchar2(140)

#### • Dodatni pojmovi

- sve izvedenice iz istog korijena
- uobičajeni kolokvijalni nazivi (piva, bira, vopi, pivica, ...)
- uobičajene pravopisne greške (cjena, supr, dorbo, ...)

## PRIMJER IZ PRAKSE

### PARSIRANJE I TAGIRANJE TWEETOVA

- Potrebno kreirati kontekstni indeks na koloni  
**DSA\_TWITTER\_KOMENTARI.TWEET**

```
CREATE INDEX dsa_twt_kom_twitter_idx
  ON DSA_TWITTER_KOMENTARI (tweet)
  INDEXTYPE IS CTXSYS.CONTEXT;
```

- Oracle Text automatski parsira i tokenizira tekst
  - tokeni spremljeni u jednu od indeksnih tablica (DR\$<ime\_indexa>\$I)
- Tagiranje i povezivanje pomoću operatora **CONTAINS**

...

## PRIMJER IZ PRAKSE

### PARSIRANJE I TAGIRANJE TWEETOVA

```
SELECT t.id,
       t.tweet,
       p.pojam,
       p.kategorija
  FROM DSA_TWITTER_KOMENTARI t, DOM_POJMOVI p
 WHERE CONTAINS (t.tweet, p.pojam) > 0
```

ID	TWEET	POJAM	KATEGORIJA
2	Izašlo novo pivo iz Zlatice, je li itko probao? #zlatnopivo	pivo	PROIZVOD
4	Jedno od najkvalitetnijih piva na tržištu, ali preskupo #zlatnopivo	preskupo	DOJAM
4	Jedno od najkvalitetnijih piva na tržištu, ali preskupo #zlatnopivo	najkvalitetnijih	DOJAM
5	Meni je cijena OK, okus super, ja odsad pijem samo #zlatnopivo	okus	PROIZVOD
5	Meni je cijena OK, okus super, ja odsad pijem samo #zlatnopivo	cijena	PROIZVOD
5	Meni je cijena OK, okus super, ja odsad pijem samo #zlatnopivo	OK	DOJAM
5	Meni je cijena OK, okus super, ja odsad pijem samo #zlatnopivo	super	DOJAM
6	Ambalaža totalni #fail, ostalo može proći	ambalaža	PROIZVOD
6	Ambalaža totalni #fail, ostalo može proći	fail	DOJAM

## PRIMJER IZ PRAKSE

### DEFINIRANJE RELACIJA MEĐU POJMIMA

- Sinonimi pojmove iz kategorije DOJAM (relacija SYN)
  - svi koji znače pozitivno mišljenje – WIN
  - svi koji znače negativno mišljenje – FAIL
- Oracle Text nudi mogućnost korištenja postojećeg tezaurusa ili kreiranje novog
- Moguće definirati i hijerarhijske odnose
  - NT – narrower term (uži pojam, podpojam)
  - BT – broader term (širi pojam, nadpojam)
  - SYN – sinonim

# PRIMJER IZ PRAKSE

## DEFINIRANJE RELACIJA MEĐU POJMOMA

```
begin
CTXSYS.CTX_THES.CREATE_THESSAURUS('thes_dojam');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'win', 'SYN',
'najkvalitetnijih');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'win', 'SYN', 'super');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'win', 'SYN',
'kvalitetno');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'win', 'SYN', 'blago');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'win', 'SYN', 'jeftino');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'win', 'SYN',
'prihvatljivo');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'win', 'SYN', 'OK');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'win', 'SYN', 'dobro');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'win', 'SYN', 'ukusno');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'win', 'SYN', 'najbolje');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'fail', 'SYN',
'preskupo');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'fail', 'SYN',
'katastrofa');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'fail', 'SYN', 'gorko');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'fail', 'SYN', 'najgore');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'fail', 'SYN', 'skupo');
CTXSYS.CTX_THES.CREATE_RELATION('thes_dojam', 'fail', 'SYN', 'loše');
end;
```

## PRIMJER IZ PRAKSE

### STVARANJE DOJMA SINTEZOM POJMOVA

- Sinonimi se koriste operatorom CONTAINS

```
SELECT t.id, t.tweet, 'win' dojam
  FROM DSA_TWITTER_KOMENTARI t
 WHERE CONTAINS (tweet, 'syn(win, thes_dojam)') > 0
UNION ALL
SELECT t.id, t.tweet, 'fail' dojam
  FROM DSA_TWITTER_KOMENTARI t
 WHERE CONTAINS (tweet, 'syn(fail, thes_dojam)') > 0;
```

ID	TWEET	DOJAM
4	Jedno od najkvalitetnijih piva na tržištu, ali preskupo #zlatnopivo	win
5	Meni je cijena OK, okus super, ja odsad pijem samo #zlatnopivo	win
4	Jedno od najkvalitetnijih piva na tržištu, ali preskupo #zlatnopivo	fail
6	Ambalaža totalni #fail, ostalo može proći	fail


# PRIMJER IZ PRAKSE

## KREIRANJE DATA MARTA

- Narativni data mart
- Pojmovne kategorije pretvaraju se u dimenzije

```
INSERT INTO DIM_DOJAM (ID, NAZIV)
SELECT id, pojam
FROM dom_pojmovi
WHERE kategorija = 'DOJAM';

INSERT INTO DIM_PROIZVOD (ID, NAZIV)
SELECT id, pojam
FROM dom_pojmovi
WHERE kategorija = 'PROIZVOD';
```



## PRIMJER IZ PRAKSE

### KREIRANJE DATA MARTOVA

- Fact tablica puni se povezivanjem tweetova s kategorijama DOJAM i PROIZVOD


- operator NEAR zbog umnožavanja redaka ("cijena OK, okus super")

```
INSERT INTO FACT_TWEET (ID, DOJAM_ID, PROIZVOD_ID, KORISNIK,
DATUM_TWEETA, TWEET)
(SELECT id, dojam_id, proizvod_id, korisnik, datum_tweeta, tweet
FROM (SELECT d.* , p.proizvod_id, proizvod_pojam
      FROM (SELECT t.id,
                    p.id dojam_id,
                    p.pojam dojam_pojam,
                    korisnik,
                    datum_tweeta,
                    tweet
               FROM DSA_TWITTER_KOMENTARI t, DOM_POJMOVI p
              WHERE CONTAINS (t(tweet, p.pojam) > 0
                            AND kategorija = 'DOJAM') d
      JOIN
        (SELECT t.id, p.id proizvod_id, p.pojam proizvod_pojam
         FROM DSA_TWITTER_KOMENTARI t, DOM_POJMOVI p
         WHERE CONTAINS (t(tweet, p.pojam) > 0
                            AND kategorija = 'PROIZVOD') p
        ON (d.id = p.id))
 WHERE CONTAINS (tweet,
 'near(||proizvod_pojam|| , ||dojam_pojam|| ) ,1 ,FALSE)' ) > 0)
```

## PRIMJER IZ PRAKSE

### KREIRANJE DATA MARTOVA

- **FACT\_SIN\_TWEET** sadrži sintetizirane podatke o dojmu
  - pozitivan tweet ima vrijednost 1, negativan tveet ima vrijednost -1, a neutralan tweet ima vrijednost 0



```
INSERT INTO FACT_SIN_TWITTER (ID, KORISNIK, DATUM_TWEETA, UKUPNI_DOJAM)
(SELECT id, korisnik, datum_tweeta, SUM (dojam) ukupni_dojam
FROM (SELECT t.* , 1 dojam
      FROM DSA_TWITTER_KOMENTARI t
      WHERE CONTAINS (tweet, 'syn(win, dojam_o_pivu)') > 0
UNION ALL
      SELECT t.* , -1 dojam
      FROM DSA_TWITTER_KOMENTARI t
      WHERE CONTAINS (tweet, 'syn(fail, dojam_o_pivu)') > 0)
GROUP BY id, korisnik, datum_tweeta)
```

## ZAKLJUČAK

- Gdje postoji potreba, postoji i način
- Najveći problem nedostatak alata
  - postojeći alati nisu specijalizirani
  - pokrivaju samo dio integracijskog procesa
  - mogući problemi u korištenju alata različitih proizvođača
- Oracle aduti
  - Oracle Text za transformacije teksta
  - moguća integracija u OWB i ODI
  - OBIEE, Reports, BI Publisher za prezentacijski sloj
- Prednost je što počivaju na zajedničkoj platformi - Oracle DB
- Treba riješiti još neke probleme, ali postojećim alatima se može zadovoljiti potreba

N E O S



WWW.NEOS.HR