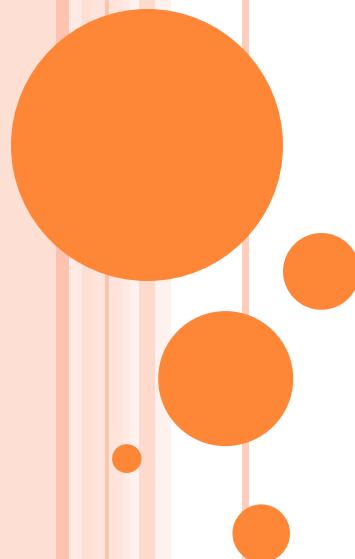


Upravljanje poslovnim podacima



DIMENZIJSKO MODELIRANJE

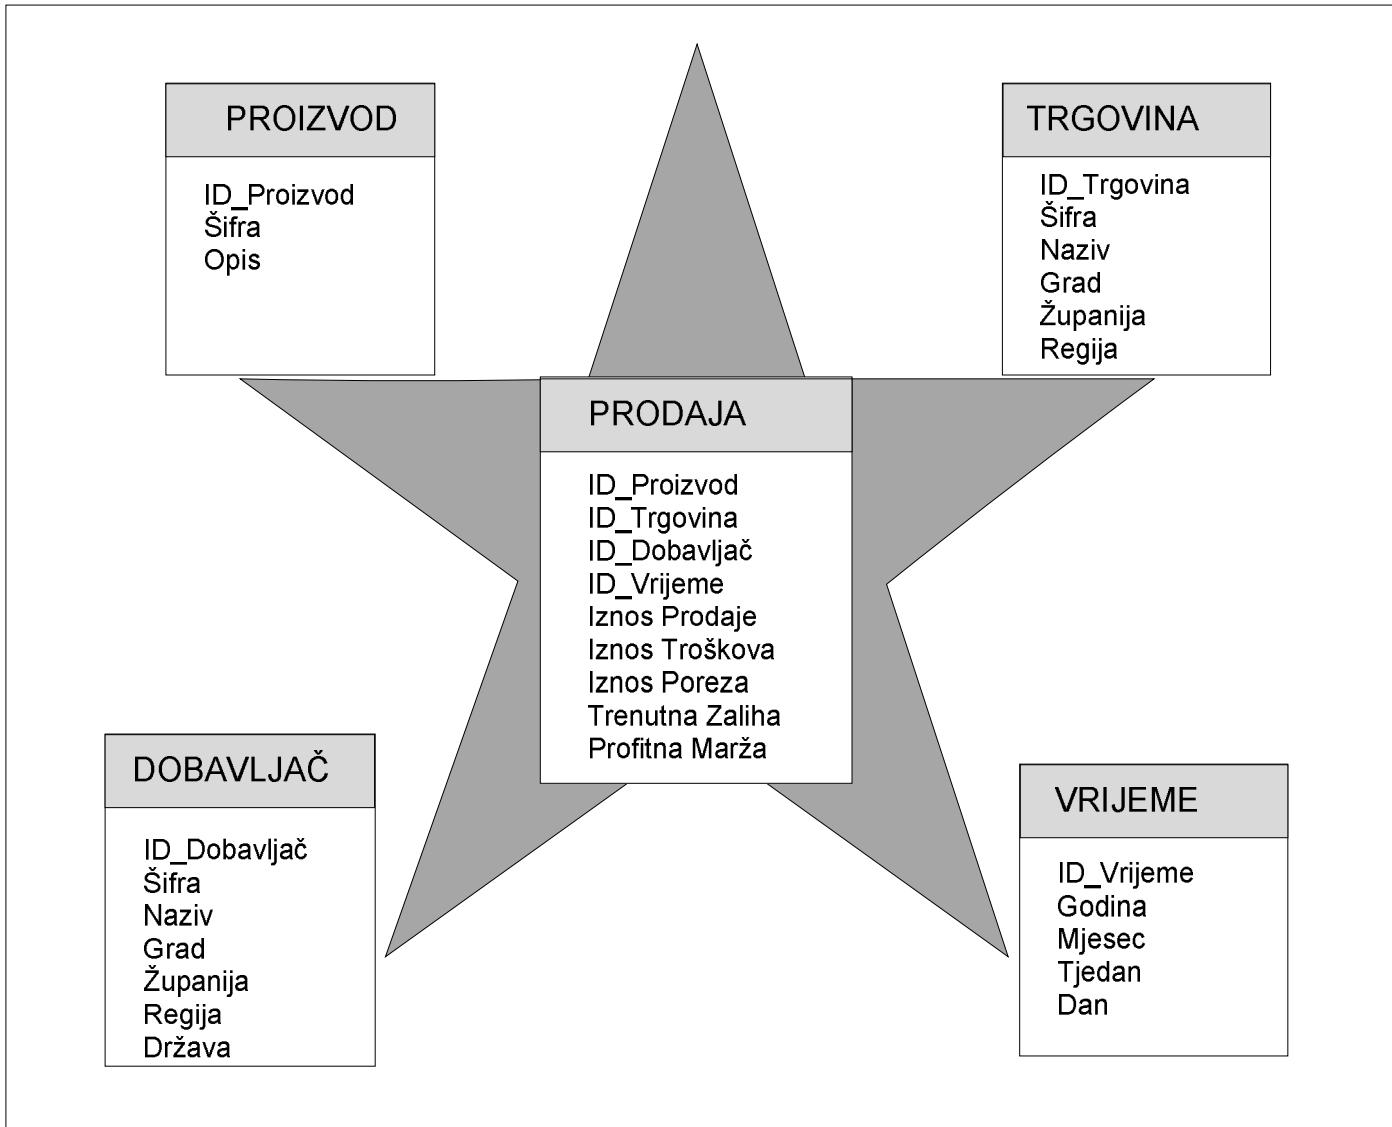
PROF. DRAŽENA GAŠPAR

17.11.2015.

ŠTO JE DIMENZIJSKO MODELIRANJE (DM)?

- DM je tehnika logičkog dizajna koja pokušava predstaviti podatke na standardan, intuitivan način koji omogućava visoku razinu performansi pristupa.
- Može se implementirati koristeći relacijsku ili višedimenzijsku bazu podataka.
- Svaki dimenzijski model se sastoji od jedne tablice sa složenim ključem – tablice činjenica (vrijednosna tablica, činjenična tablica, fakt tablica) i skupa manjih tablica – dimenzijskih tablica.
- Svaka dimenzijska tablica ima jednostavni primarni ključ koji odgovara točno jednom dijelu složenog ključa iz fakt tablice.
- Grafički prikaz ovog modela podsjeća na zvijezdu, pa se ova struktura naziva zvijezda spajanje (zvijezda schema).

ZVIJEZDA SHEMA



STRUKTURA ZVIJEZDA SPAJANJA

2 Tipa tablica

1. Vrijednosna / tablica činenica / fact table
2. Dimenzijske tablice



FAKT TABLICA

- Fakt tablica pohranjuje mjere – vrijednosti poslovanja i pokazuje na vrijednost ključa na najnižoj razini svake dimenzijske tablice Mjere su kvantitativni ili činjenični podaci o predmetu.
- Mjere su općenito numeričke i odgovaraju na pitanje *koliko?*
- Primjeri mjera su: cijena, prodaja proizvoda, inventurna količina, prihod i sl. Mjera se može odnosi na stupac u tablici ili može biti izračunata.



FAKT TABLICA

- Najkorisnije činjenice u fakt tablici su numeričke i po njima se može zbrajati.
- Zbrajanje je bitno iz razloga što DW aplikacije skoro nikada ne rade s jednim retkom fakt tablice, već obično rade sa stotinama, tisućama ili čak milijunima slogova (redaka) u jednom trenutku. Vrlo često, najskorisnije što se može učinit s tolikom brojem slogova je zbrojiti ih.

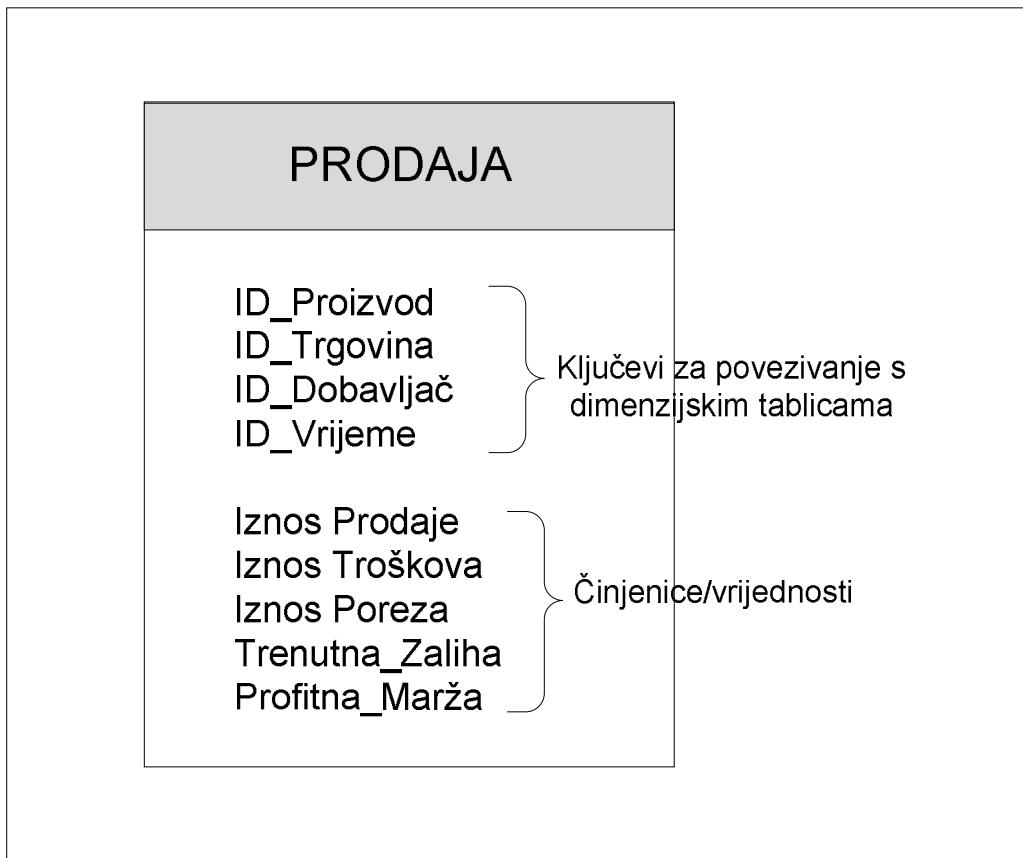
FAKT TABLICA

Tri osnovna tipa numeričkih vrijednosti u tablici
činjenica:

- Zbrojive
- Poluzbrojive
- Nezbrojive.



TABLICA ČINJENICA

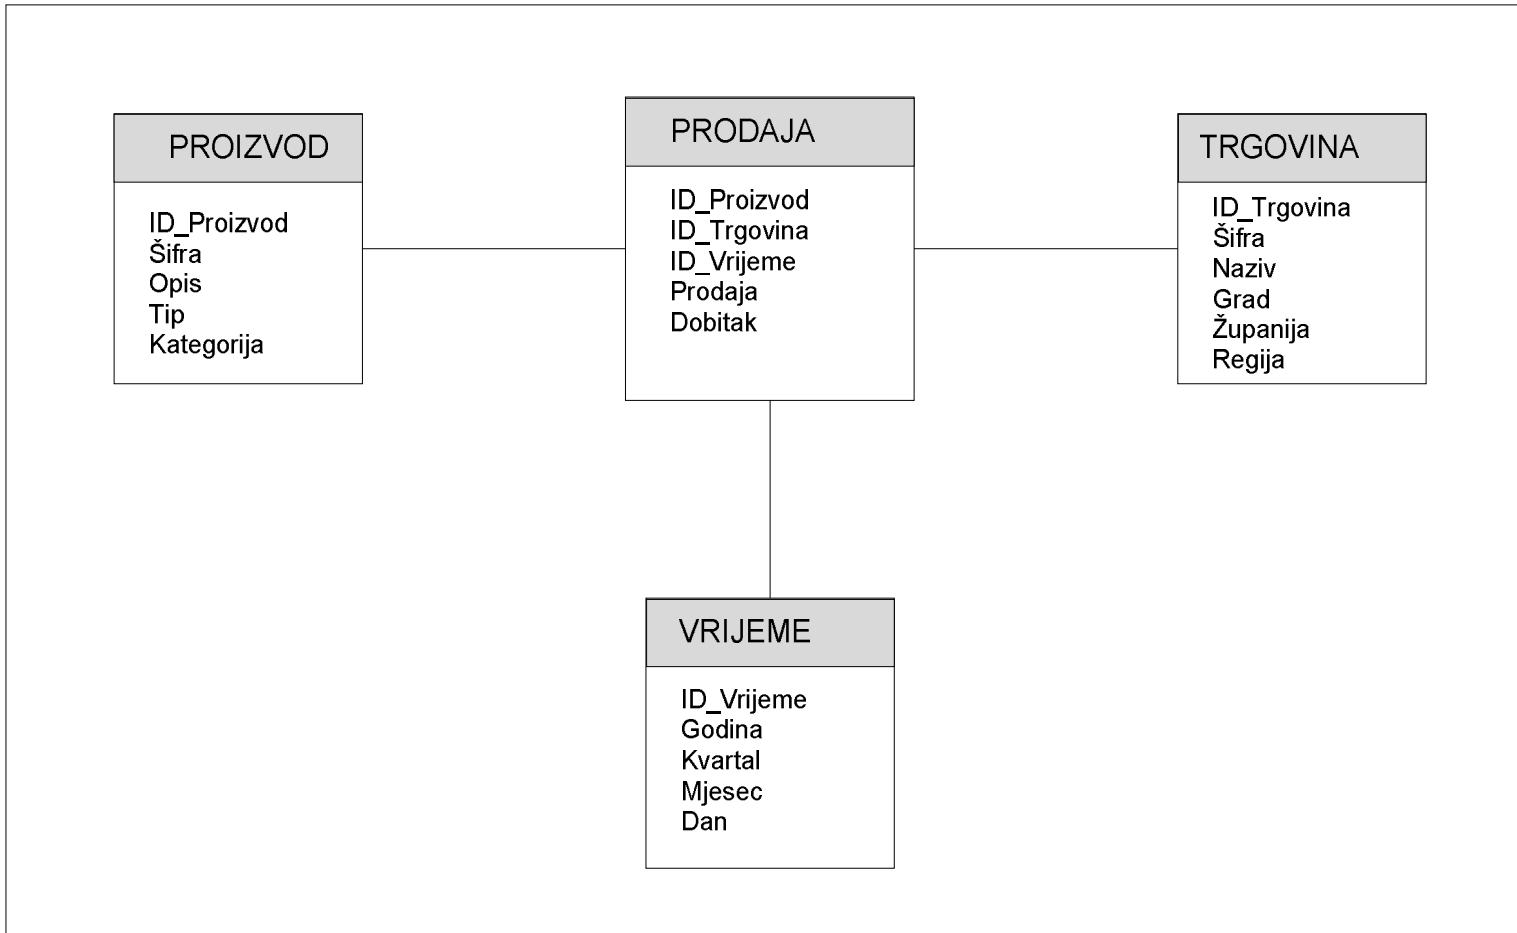


FAKT TABLICA

- Prije dizajna fakt tablice – usitnjenost (*granularnost*) fakt tablice mora biti određena.
- Usitnjenost odgovara definiciji pojedinačnog sloga najniže razine u toj fakt tablici.
- Usitnjenost se može odnositi na pojedinačnu transakciju, dnevni snapshot ili mjesečni snapshot.



FAKT TABLICA - USITNjenost



FAKT TABLICA - USITNJENOST

- „*Prodaja i dobitak za jedan proizvod u jednoj trgovini u jednom danu.*“

Jedan redak tablice činjenica Prodaja sadrži prodaju i dobitak agregiran (zbrojen) po jednom proizvodu (najniža razina hijerarhije u dimenziji proizvod), po jednoj trgovini (najniža razina hijerarhije za dimenziju trgovina) i po jednom danu (najniža razina hijerarhije za dimenziju vrijeme).



STRUKTURA FAKT TABLICE

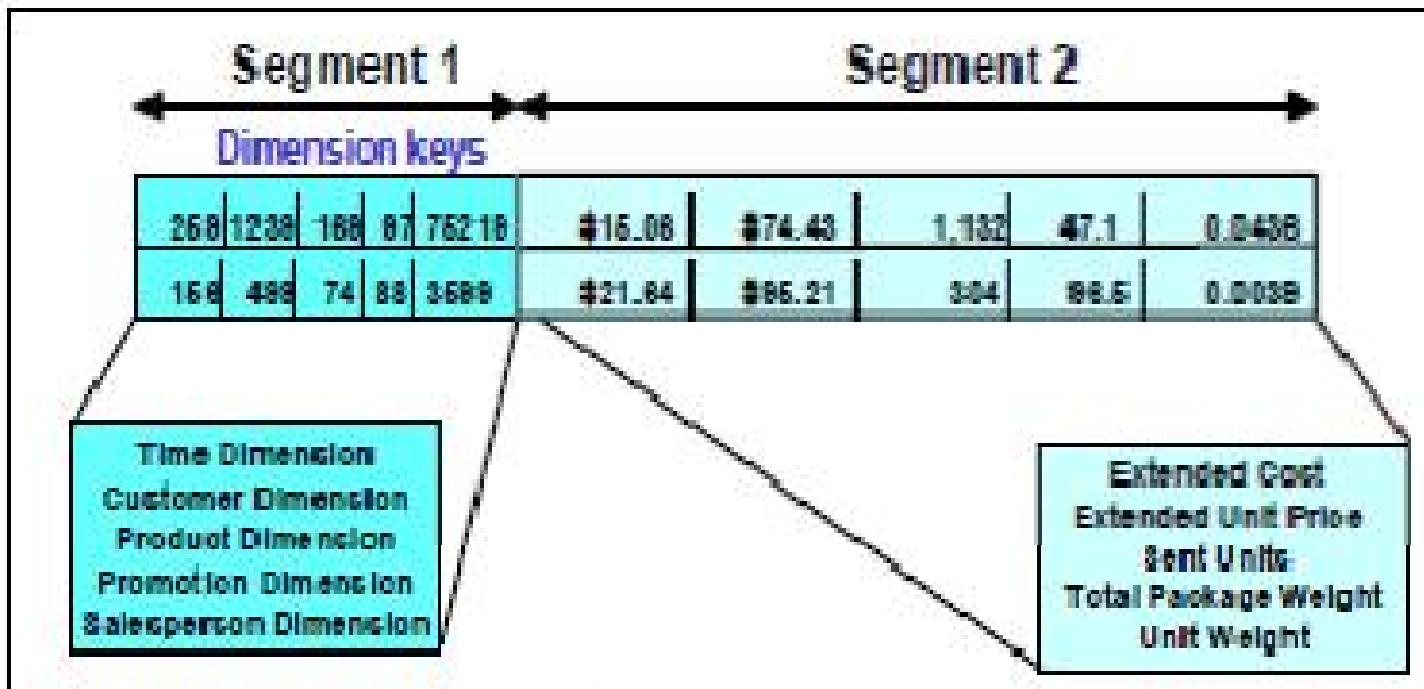


Figure 3-4 Fact table structure

LOŠA FAKT TABLICA

- Sadrži ne-numeričke vrijednosti – to znači da nema agregiranja podataka
- Problem zbrajanja – popust prikriven u cijeni
- Nema izravne relacije s postojećom strukturom ključeva (rezultat: problem zbrajanja)



PRIMJER "DOBRE" I "LOŠE" FAKT TABLICE

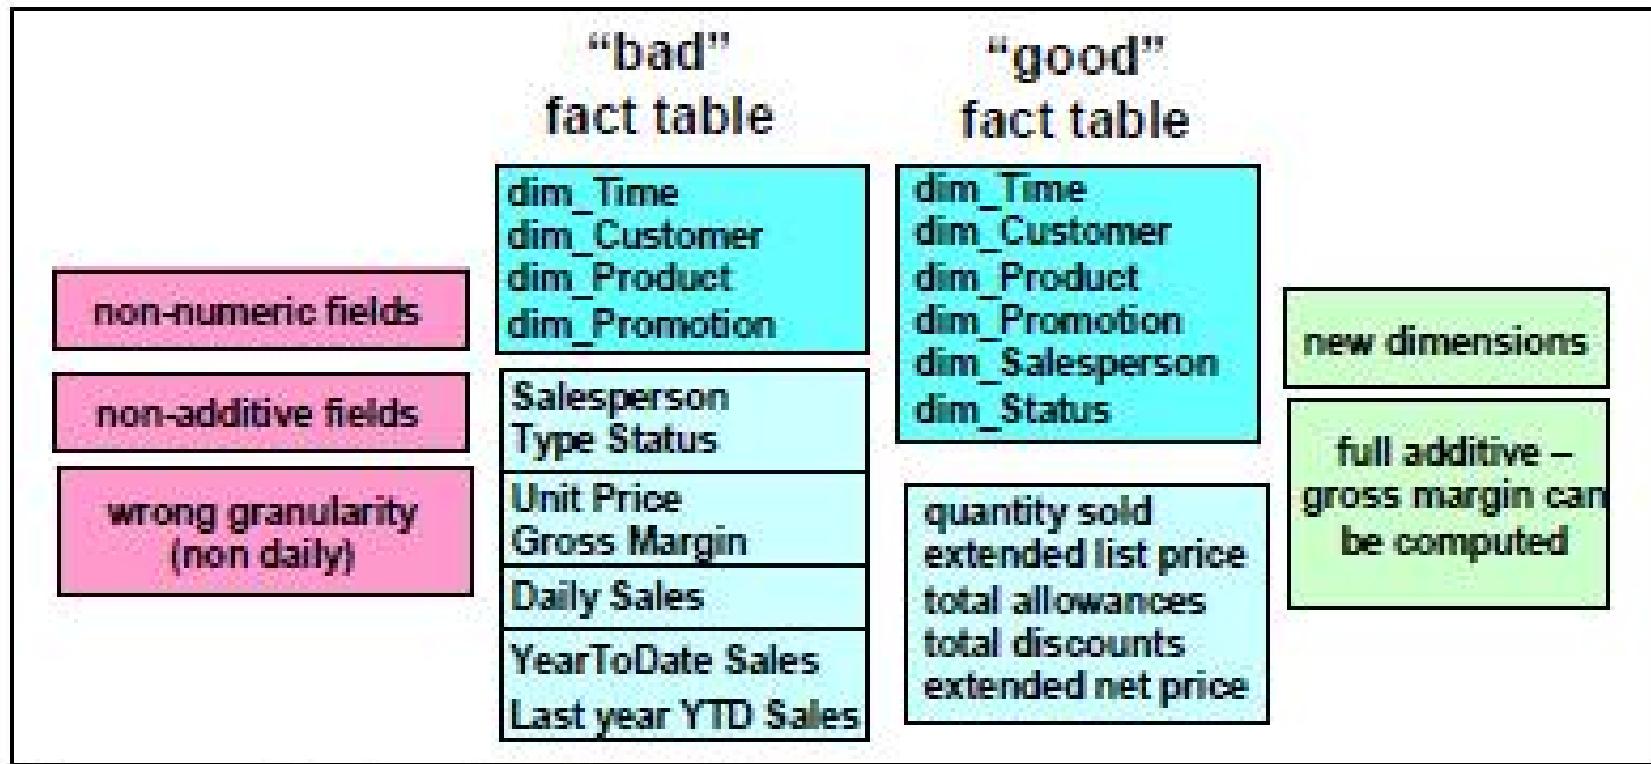
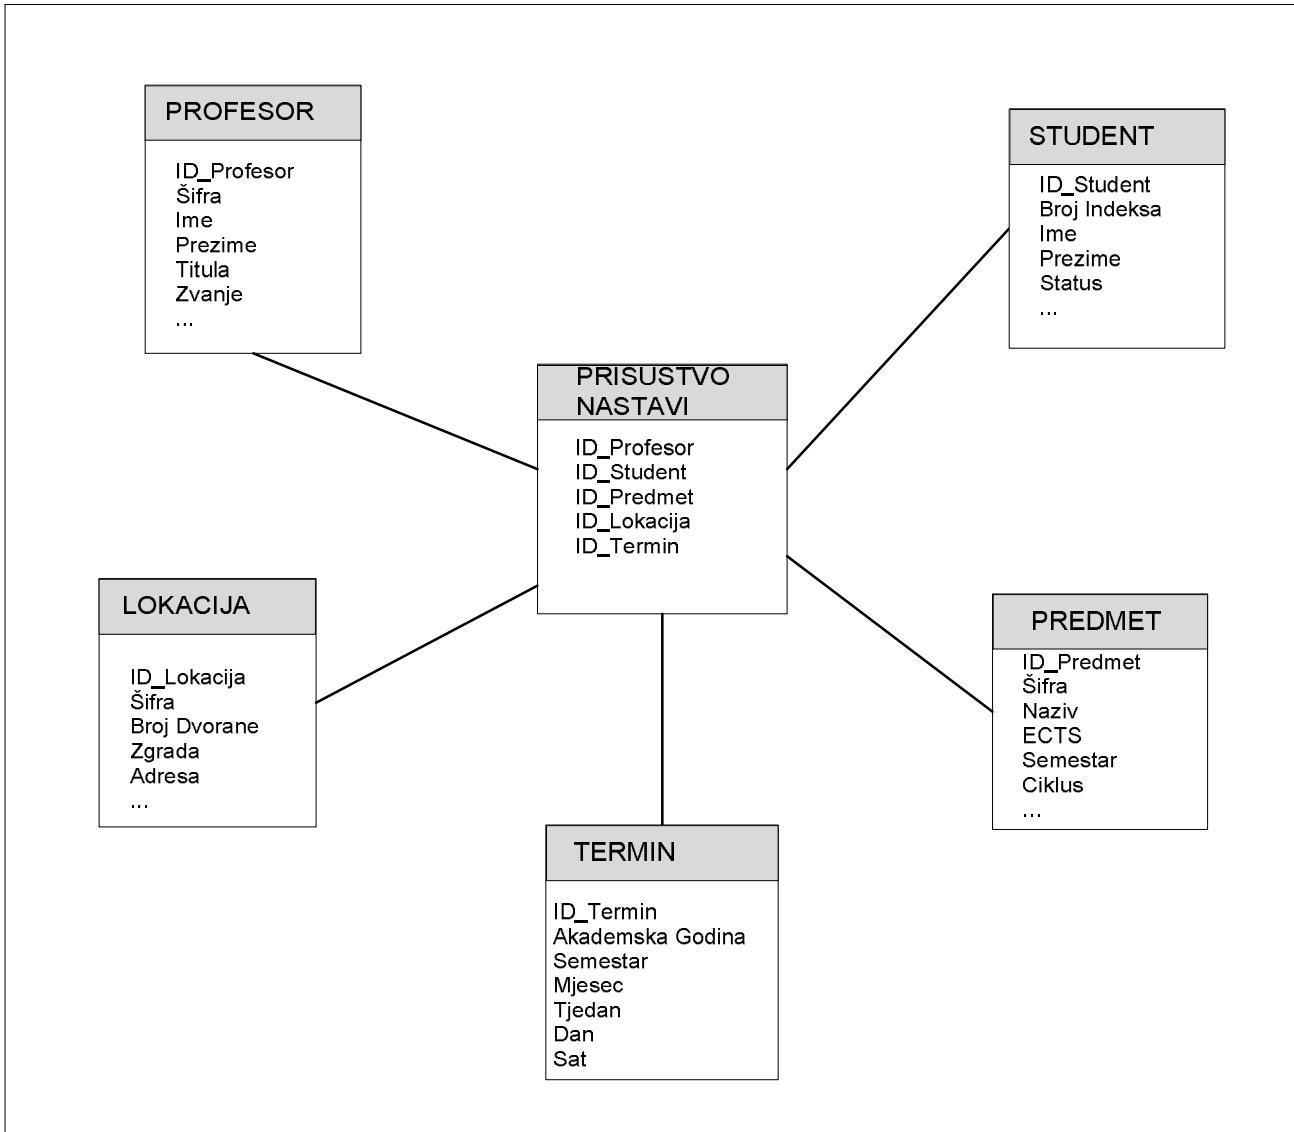


Figure 3-5 Good and bad fact table

TABLICA ČINJENICA BEZ VRIJEDNOSTI



DIMENZIJSKA TABLICA

Dimenzija predstavlja jedan skup objekata ili događaja u stvarnom svijetu.

Svaku dimenziju koju korisnik identificira za model podataka implementira se kao dimenzijska tablica.

Dimenzije su kvalifikatori koji daju značenje mjerama iz fakt tablice, zato što daju odgovor na što, koji, kada, koliko i gdje aspekte pitanja. Na primjer:

Koji *kupci* su ostvarili najveći promet prošle godine?

Koliki je bio naš profit po *dobavljačima*?

Koliko je prodano jedinica svakog *proizvoda*?

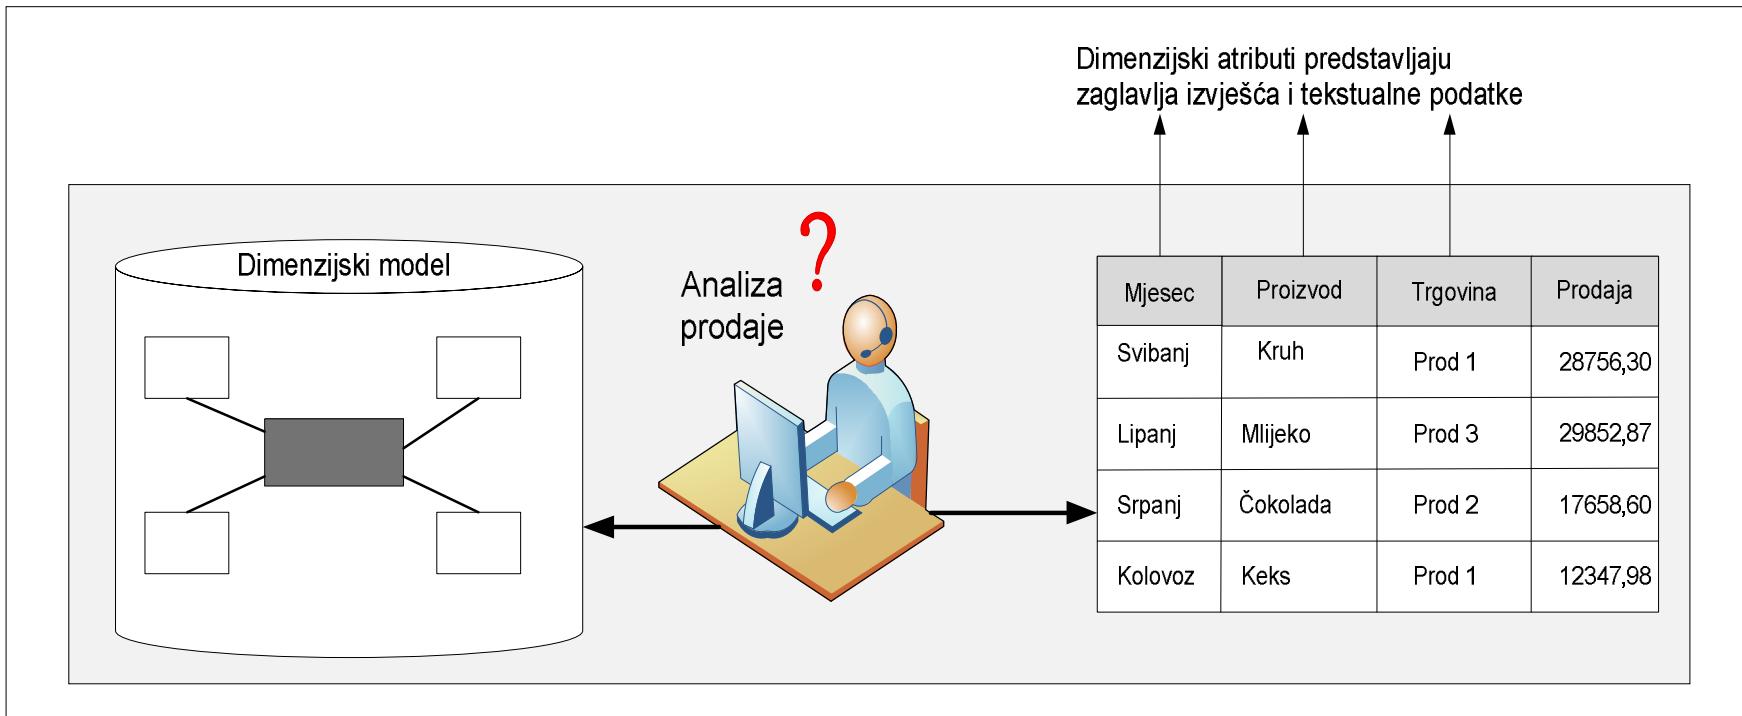


DIMENZIJSKA TABLICA

- Dimenzijska tablica sadrži informacije o tome kako organizacija želi analizirati činjenice:
 - "Prikazati prodaju (činjenica) za prošli tjedan (vrijeme) za crvene šalice (proizvod) u zapadnoj hercegovini (zemljopisni pojam)"
- Dimenzijska tablica najčešće sadrži opisne tekstualne informacije "crvene šalice", "zapadna hercegovina"
- Dimenzijski atributi se koriste kao izvor najzanimljivijih "ograničenja" u DW upitima, oni su uvijek zaglavlja redaka u SQL odgovoru na upit.



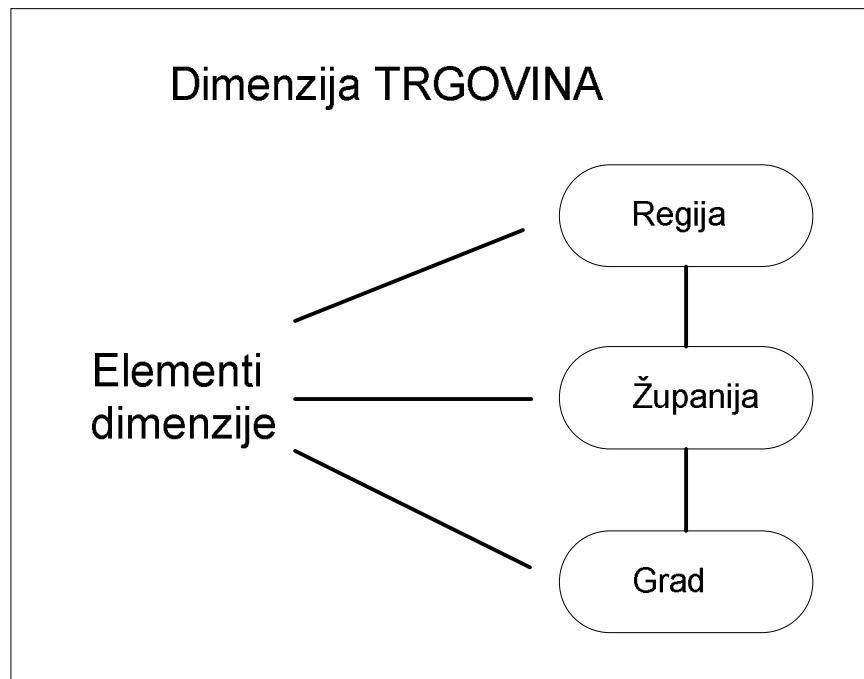
DIMENZIJE



DIMENZIJSKE TABLICE

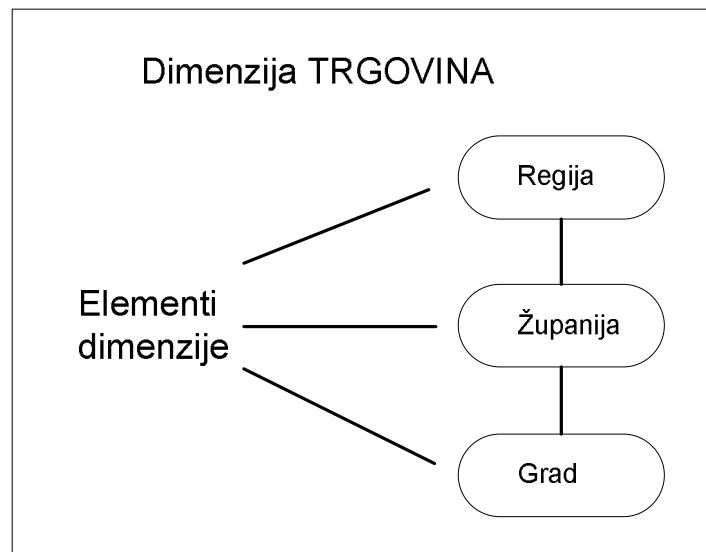
Dimenzija može definirati višestruke dimenzijske elemente za različite razine zbrajanja.

Na primjer, svi elementi koji se odnose na strukturu prodaje organizacije mogu činiti jednu dimenziju.



DIMENZIJSKA TABLICA

- Dimenzijske tablice su napravljene od hijerarhija elemenata.
- Zbog hijerarhijskog aspekta dimenzijskih tablica, korisnici mogu postaviti upite koji pristupaju podacima na višoj (*roll up*) ili nižoj razini (*drill down*).
- Slika prikazuje hijerarhijsku vezu dimenzijskih elemenata: prodaja se može zbrajati (*roll up*) po gradu, gradovi po županijama a županije po regijama. Korisnici mogu postavljati upite na različitim razinama dimenzijskih tablica. Na primjer: upit za sve regije i onda drill down prema županiji ili gradu za detaljne informacije.



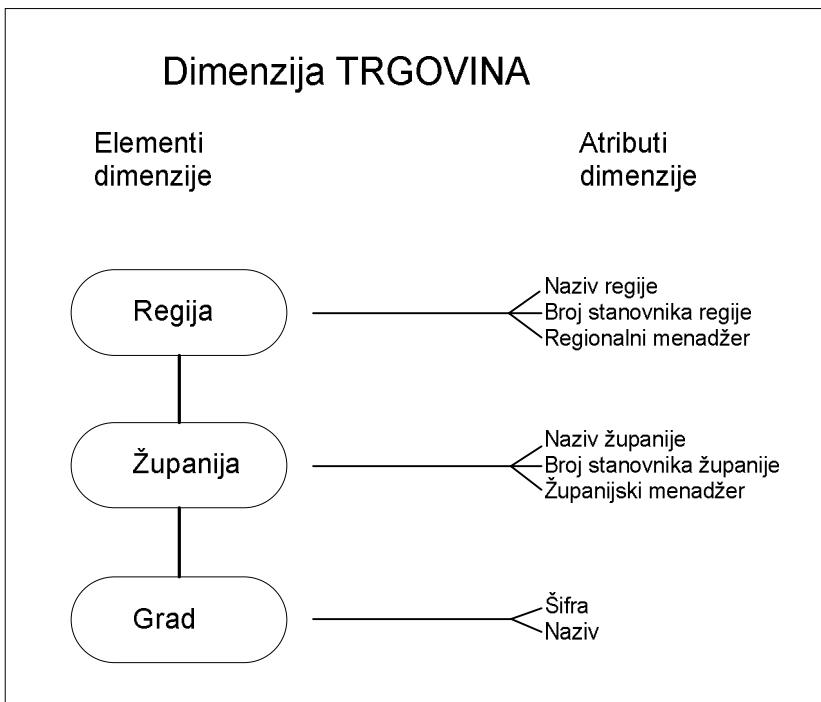
DIMENZIJSKA TABLICA

Atribut dimenzijske tablice je stupac u dimenzijskoj tablici.

Svaki atribut opisuje razinu agregacije u okviru dimenzijske hijerarhije.

Dimenzijski elementi definiraju hijerarhijske veze unutar dimenzijske tablice; atributi opisuju dimenzijske elemente na način blizak korisnicima.

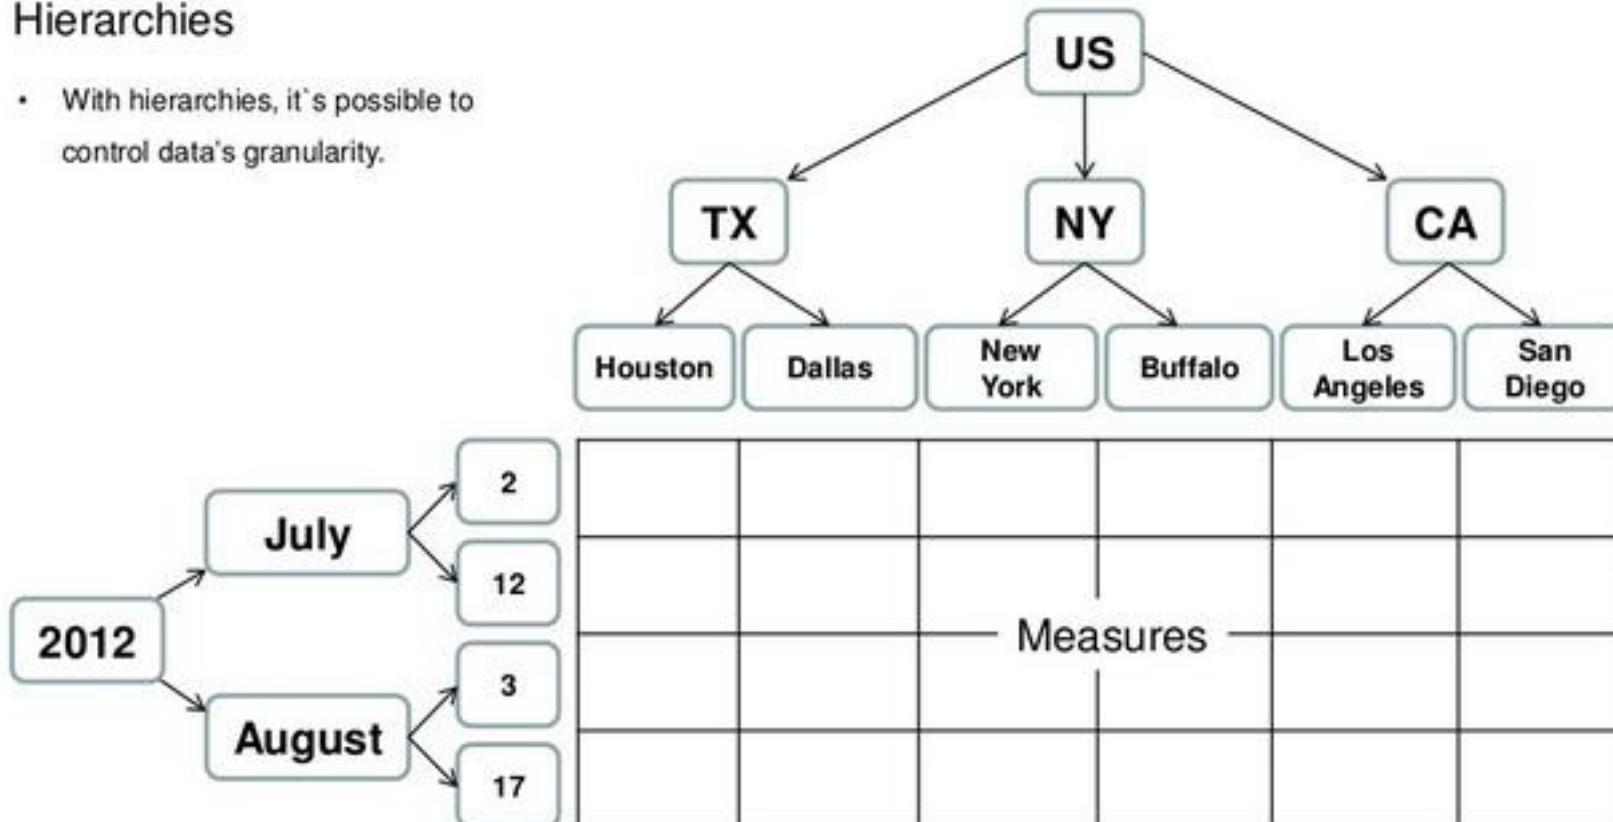
Slika prikazuje dimenzijske elemente i odgovarajuće attribute dimenzijske tablice.



Dimensions and hierarchies

Hierarchies

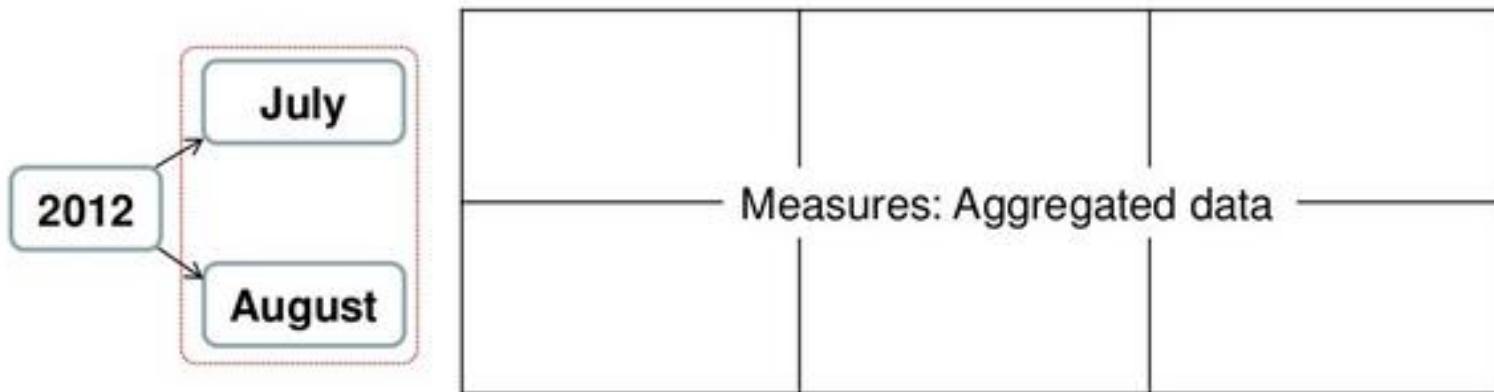
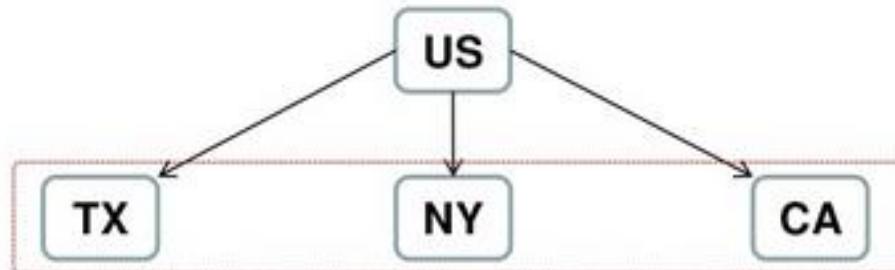
- With hierarchies, it's possible to control data's granularity.

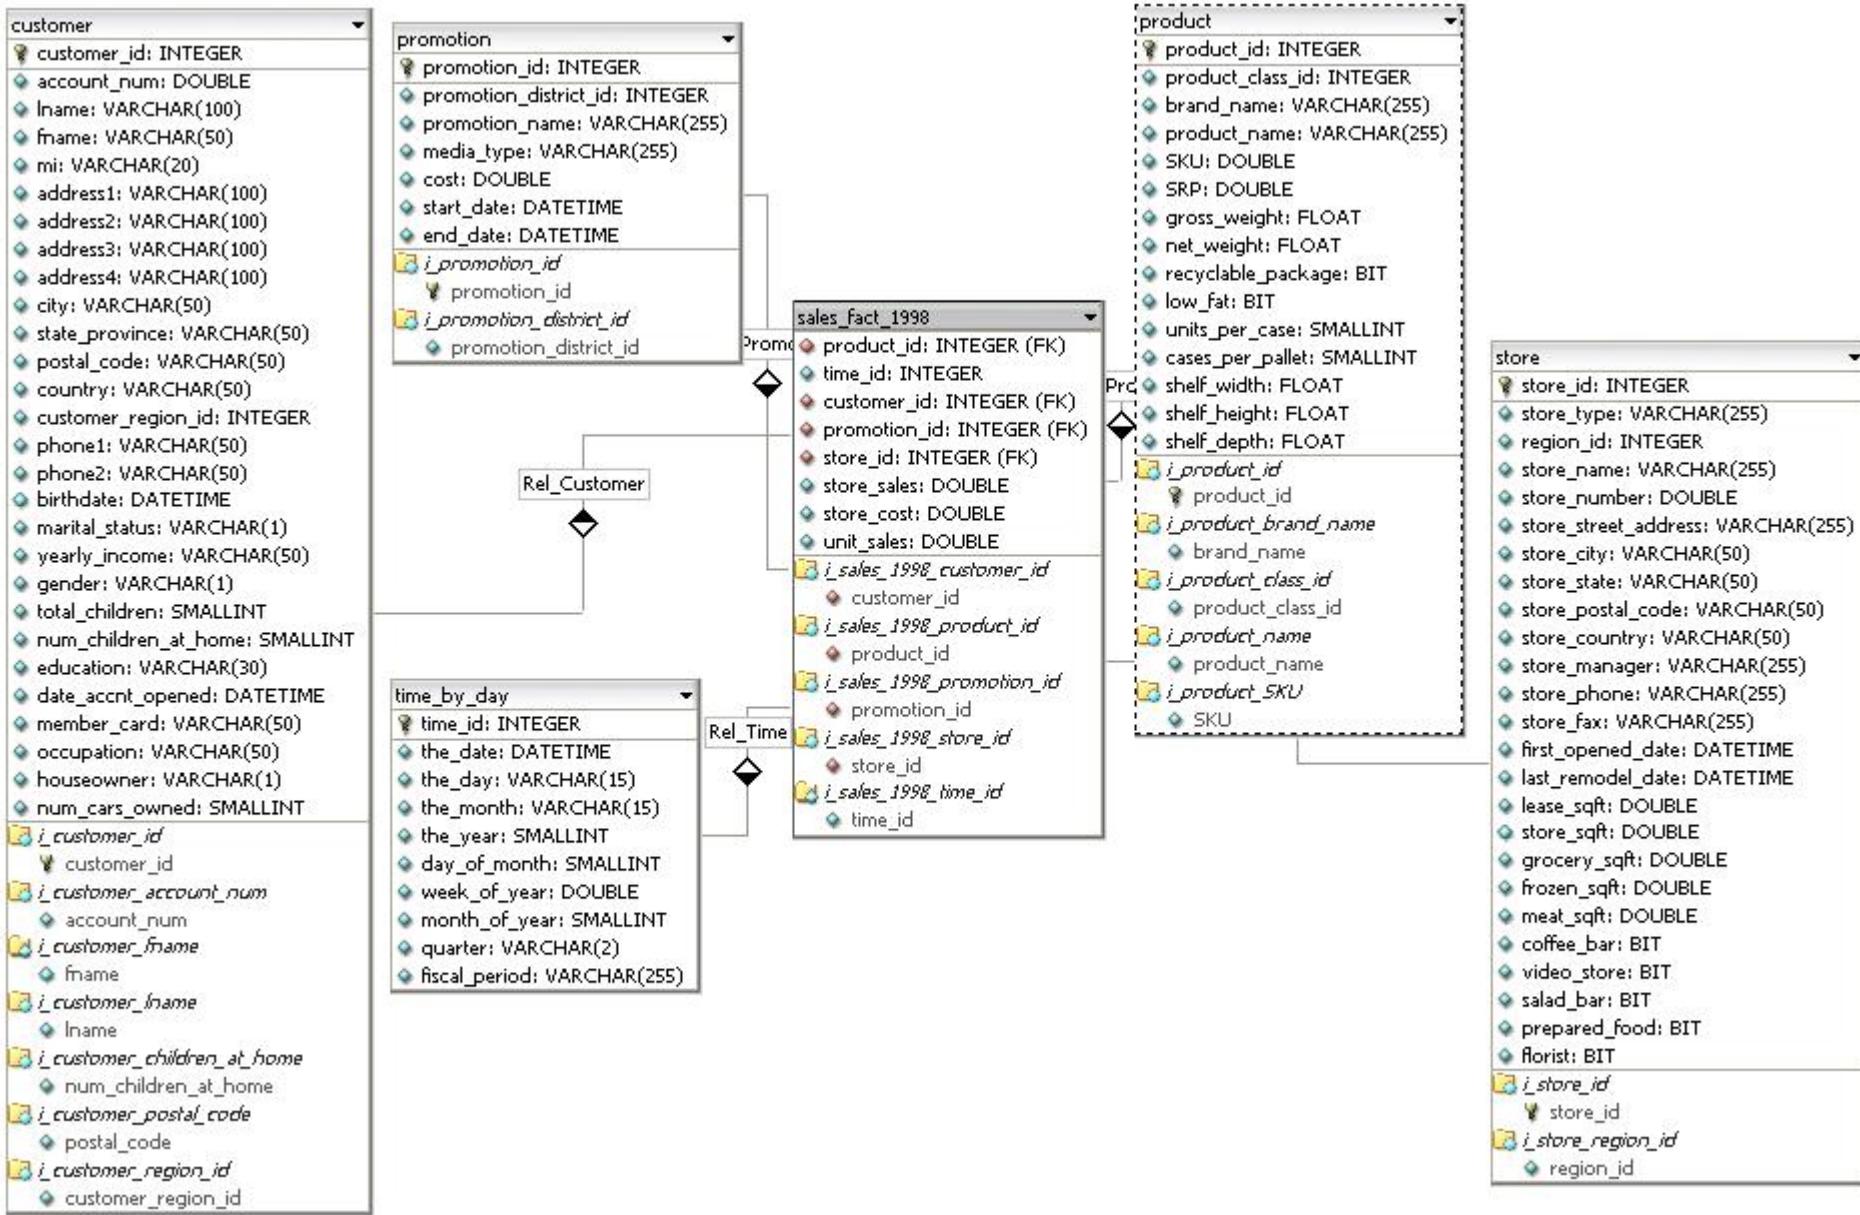


Dimensions and hierarchies

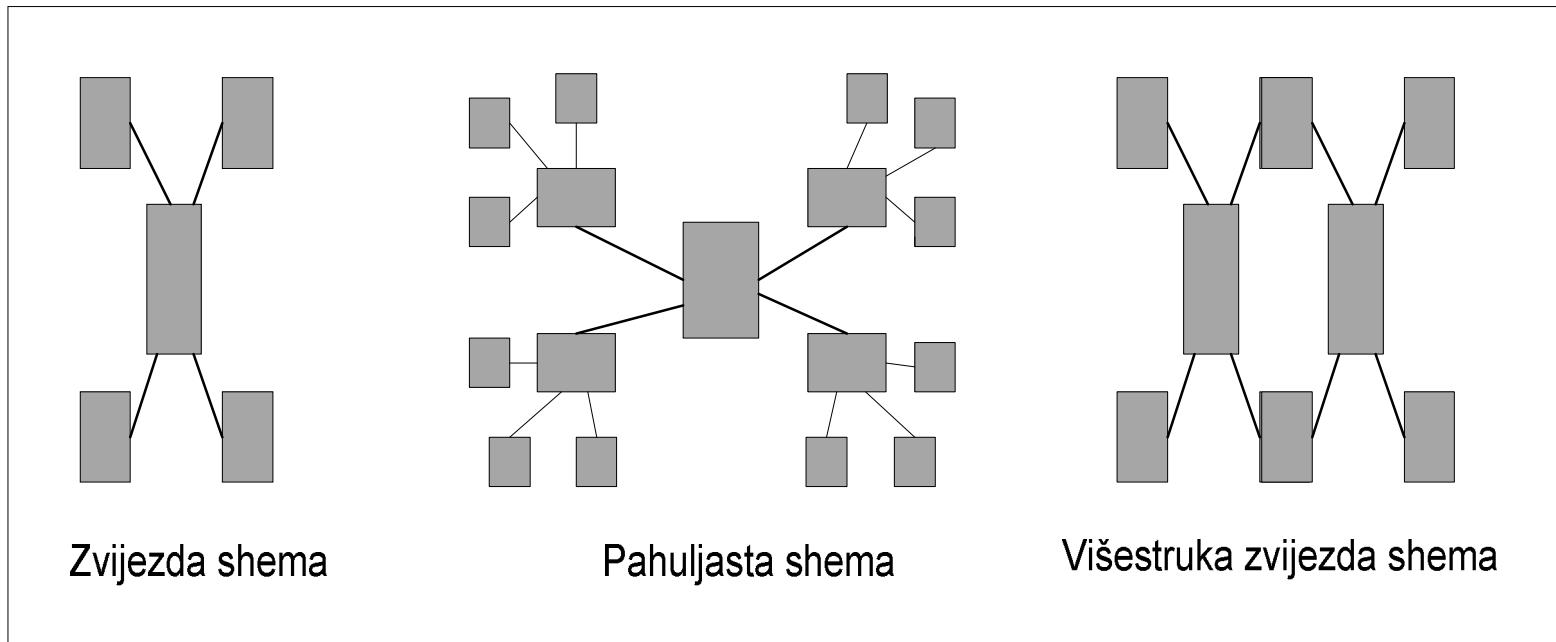
Data aggregation

- A query in a higher level of a dimension, brings aggregated data to a measure.





TIPOVI DIMENZIJSKIH MODELA



Zvijezda shema

Pahuljasta shema

Višestruka zvijezda shema



TIPOVI DIMENZIJSKIH MODELA

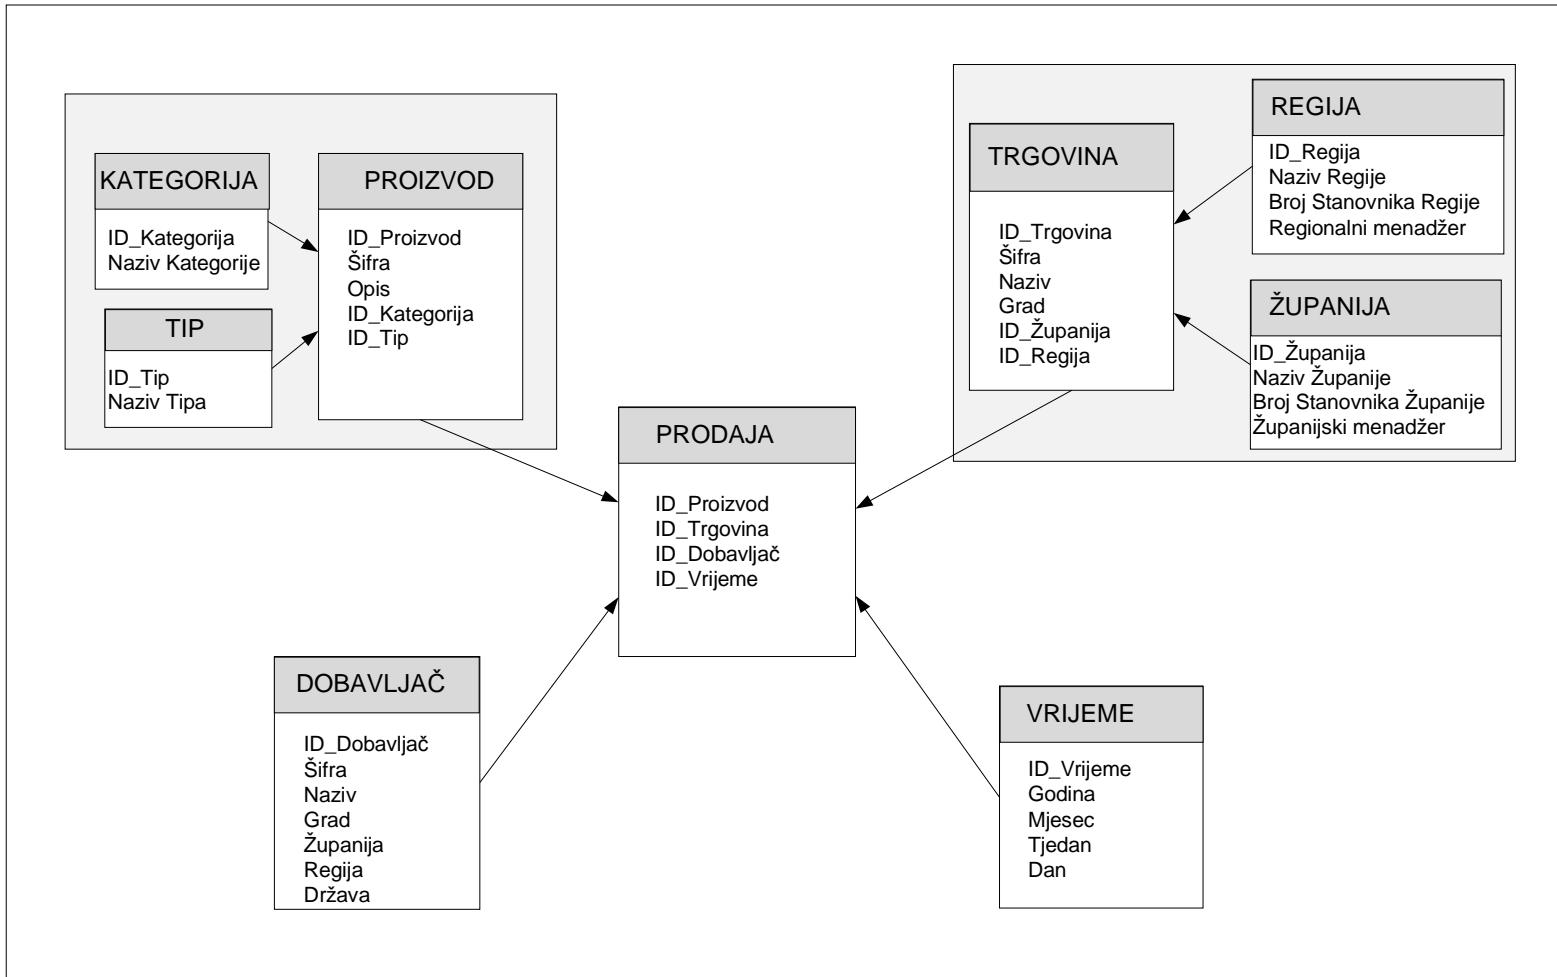
Star model (zvijezda shema): Jedna vrijednosna tablica i nekoliko dimenzijskih tablica. Denormaliziran model.

Snowflake model (pahuljasta shema): Normalizacija i proširenje dimenzijskih tablica tako što se stupci niže kardinalnosti premještaju i posebne normalizirane tablice koje povezuju s izvornom dimenzijskom tablicom.

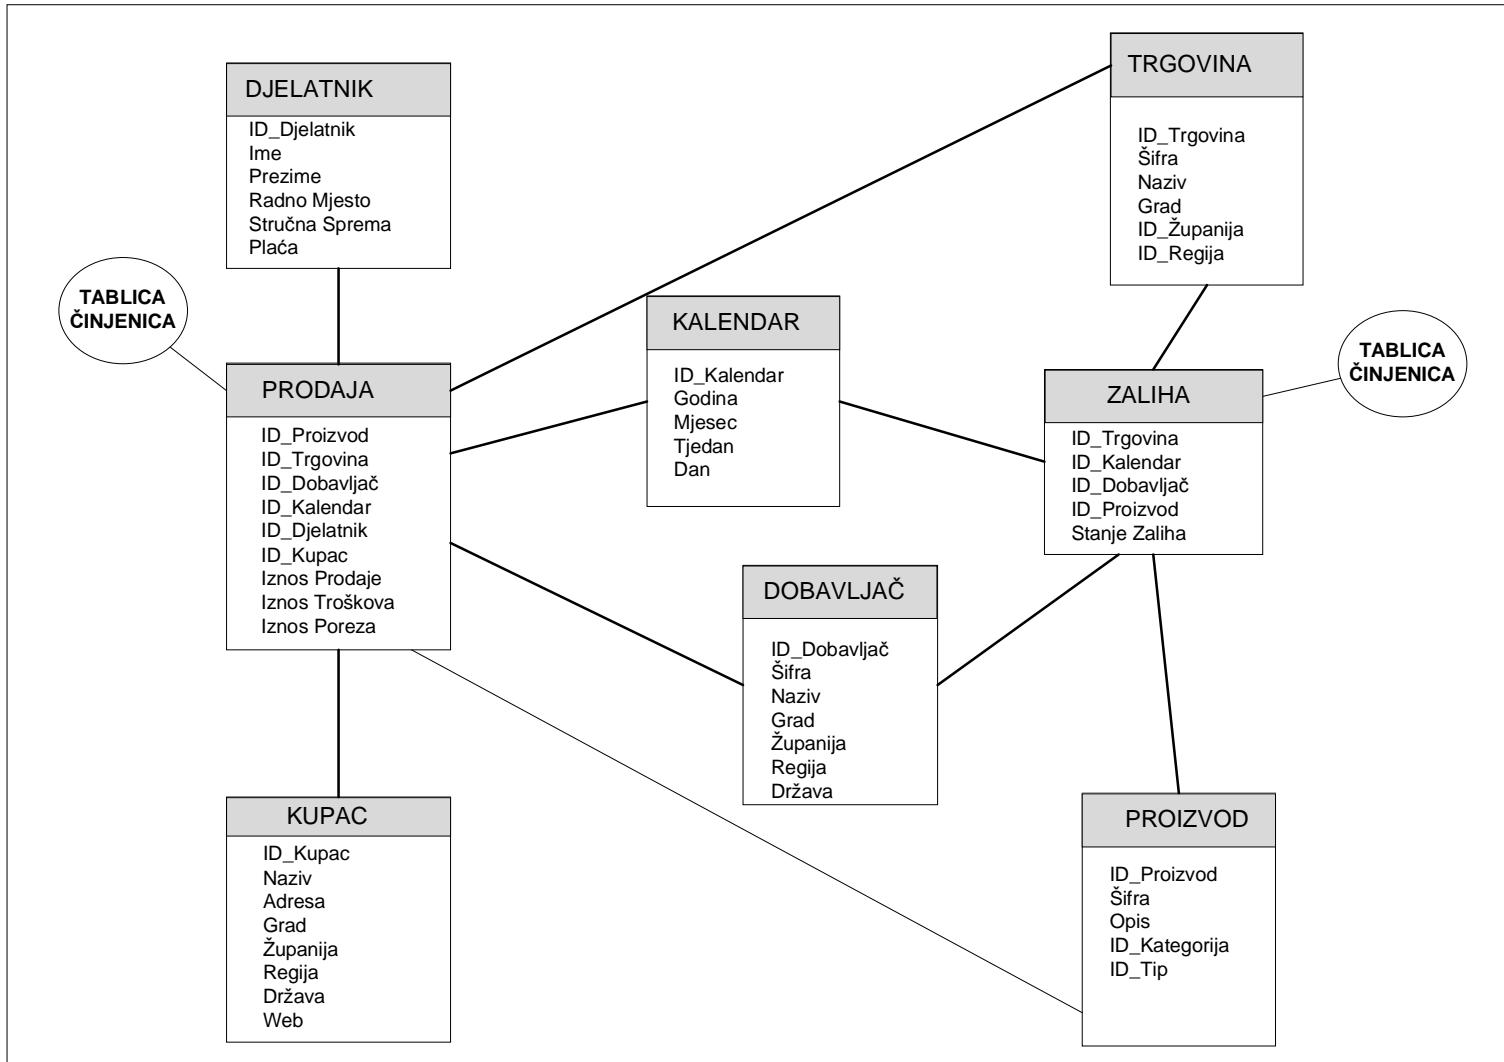
Multi-star model (višestruka zvijezda shema): Dimenzijski model koji ima veći broj vrijednosnih tablica povezanih preko dimenzija.



SNOWFLAKE SCHEMA



MULTI-STAR SHEMA



ZAKLJUČAK

Dimenziјe

- Vremenski neovisni, tekstualni i opisni atributi pomoću kojih korisnici opisuju objekte.
- Kombiniranje svih atributa uključujući hijerarhije, svrdlanja i pod-referenciranja u jednu dimenziju je denormalizacija.
- Često "po" riječ u upitima ili izvješćima
- Nisu vremenski ovisne

Fakti

- Poslovna mjerjenje
- Većina činjenica su numeričke
- Zbrojivi, polu-zbrojivi, nezbrojivi
- Izgrađeni od najniže razine detalja (usitnjenošć)
- Vrlo efikasni
- Vremenski ovisni



TIPIČNI OPERATORI

- Roll up (drill-up): zbrajanje (agregiranje) podataka
 - *Po hijerarhiji prema gore ili po dimenziji*
 - Drill down: suprotno od roll-up [svrdlanje]
 - *od više razine agregiranja prema nižoj tj. prema detaljnim podacima, ili uvođenje novih dimenzija*
- Slice and dice [raslojavanje i presijecanje]:
 - *Projekcija i selekcija*
- Pivot (rotate) [rotiranje] :
 - *Zaokretanje kocke, vizualizacija, 3D prema seriji 2D.*
- Drugi operatori
 - *drill across [svrdlanje preko]: uključivanje (preko) više od jedne fakt tablice*
 - *drill through [svrdlanje kroz]: kroz najnižu razinu kocke do njenih relacijskih tablica u pozadini (koristeći SQL)*

DRILL DOWN / ROLL UP

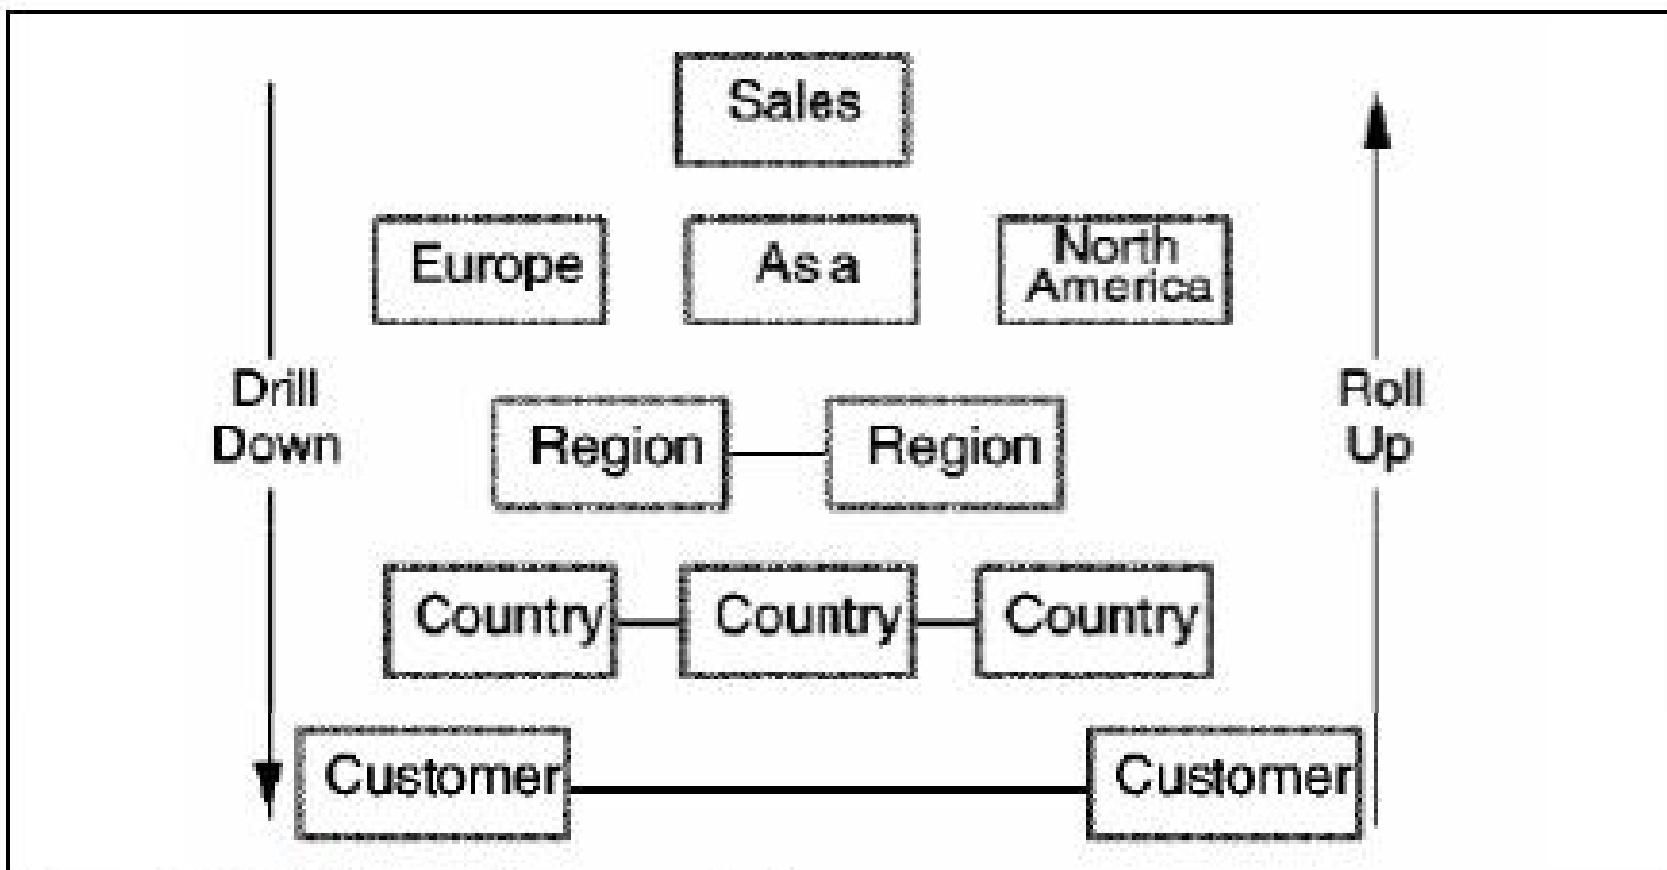


Figure 4-7 Drill-down and roll-up analysis

DRILL DOWN / DRILL UP

The diagram illustrates a drill-down process across three tables:

- Beverage -> Group Class:** The first table shows sales data grouped by Beverage class. A callout bubble highlights the "Beverage" group.
- Beverage -> Group:** The second table shows sales data grouped by product type (Pop and Water). A callout bubble highlights the "Group" category.
- Beverage -> Group -> Pop:** The third table shows sales data broken down by individual product (Milk and Juice).

Table 1: Beverage -> Group Class

	STORE	CA	OR	LA	Total
Metrics	Sales	in Sales in	Sales in	Sales in	
	USD	USD	USD	USD	USD
Group-Class					
Beverage	180	7,722	13,882	21,784	
Total	180	7,722	13,882	21,784	

Table 2: Beverage -> Group

	STORE	CA	OR	LA	Total
Metrics	Sales	in Sales in	Sales in	Sales in	
	USD	USD	USD	USD	USD
Group					
Pop	140	7,662	11,452	19,254	
Water	40	60	2,430	2,530	
Total	180	7,722	13,882	21,784	

Table 3: Beverage -> Group -> Pop

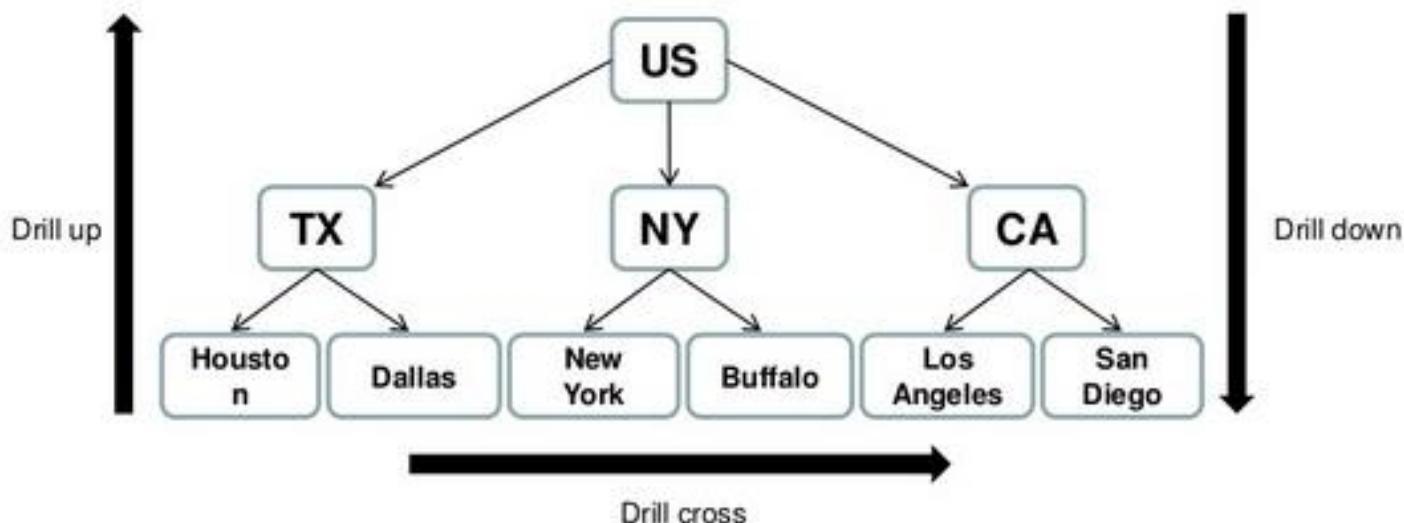
	STORE	CA	OR	LA	Total
Metrics	Sales	in Sales in	Sales in	Sales in	
	USD	USD	USD	USD	USD
PRODUCT					
Milk	60	1,452	2,346	3,858	
Juice	80	6,210	9,106	15,396	
Total	140	7,662	11,452	19,254	

Figure 4-12 Drill-down on product dimension

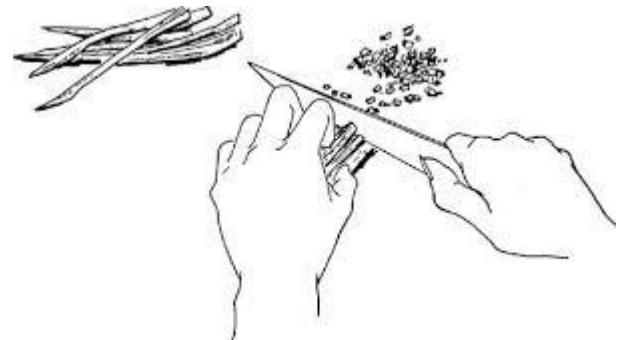
Operations over OLAP Cube

Drilling

- Drill up (Roll up): Decrease data's granularity.
- Drill down: Increase data's granularity.
- Drill Across: Navigation over dimension.



SLICE AND DICE

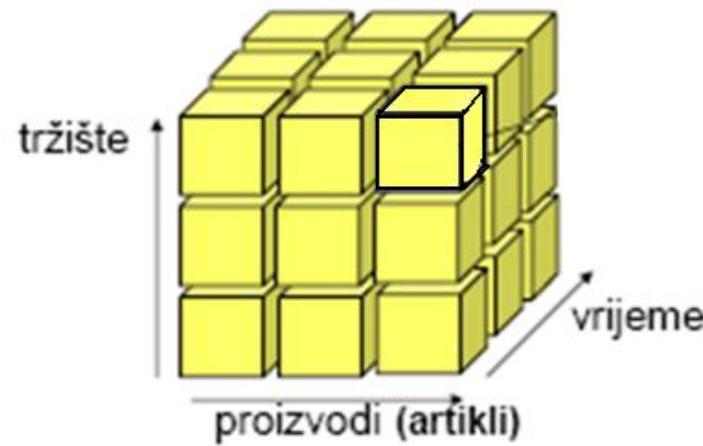
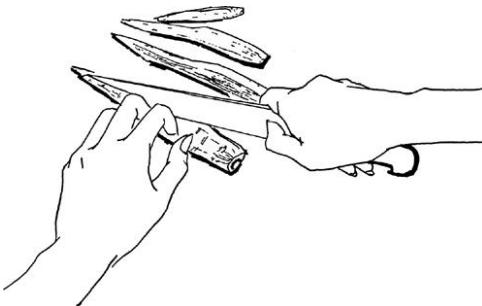


Slice [Raslojavanje]

Definira člana ili grupu članova koji su odvojeni (od svih drugih dimenzija) i onda se evaluiraju kroz sve dimenziije. Član dimenziije znači vrijednost unutar stupca.

Primjer:

3 dimenziije: proizvod, trgovina i vrijeme



SLICE

Slice – odabir jednog ili više članova dimenzije (proizvod) i konsolidiranje (agregiranje) duž svih ostalih dimenzija (trgovina i vrijeme)

➡ (For ALL Stores and Dates)

Product	Sales in USD
Soda	2,530
Milk	3,858
Juice	15,396
Total	21,784

Figure 4-8 Slice for product

- Slicing – raslojavanje
(horizontalni presjek kocke)



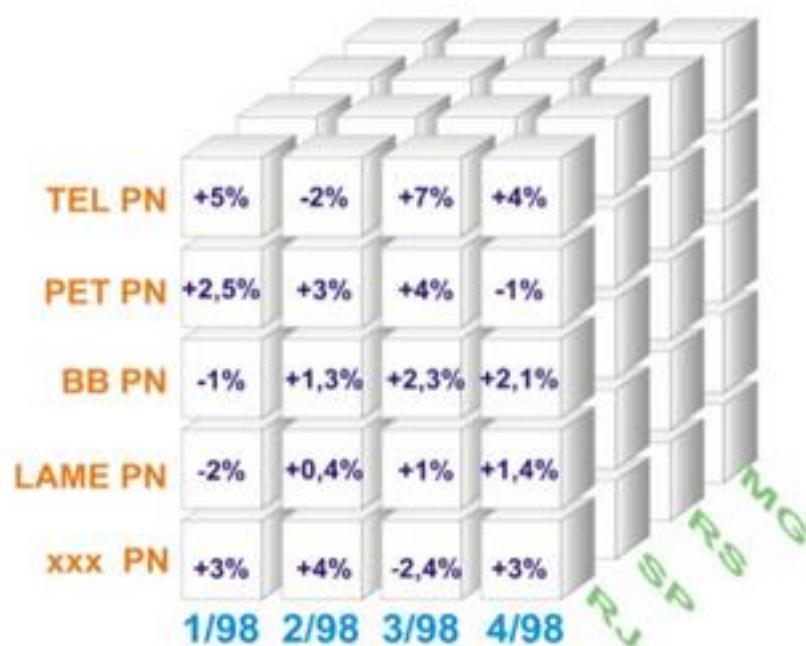
- Dicing – presijecanje
(vertikalni presjek kocke)



Operations over OLAP Cube

Slicing

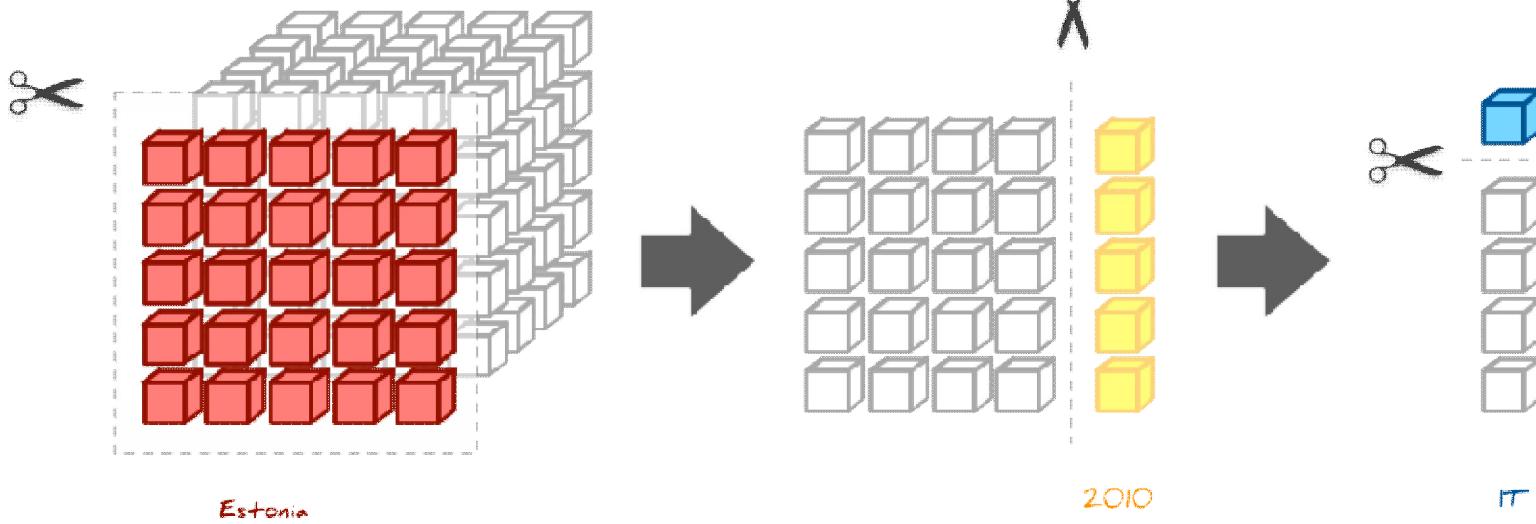
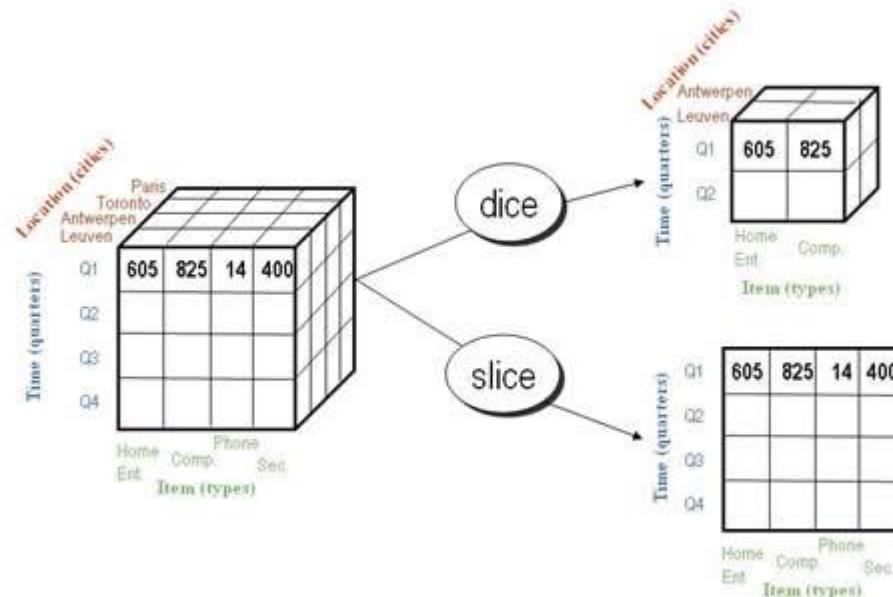
- Two dimensions vary, and one is kept fixed.



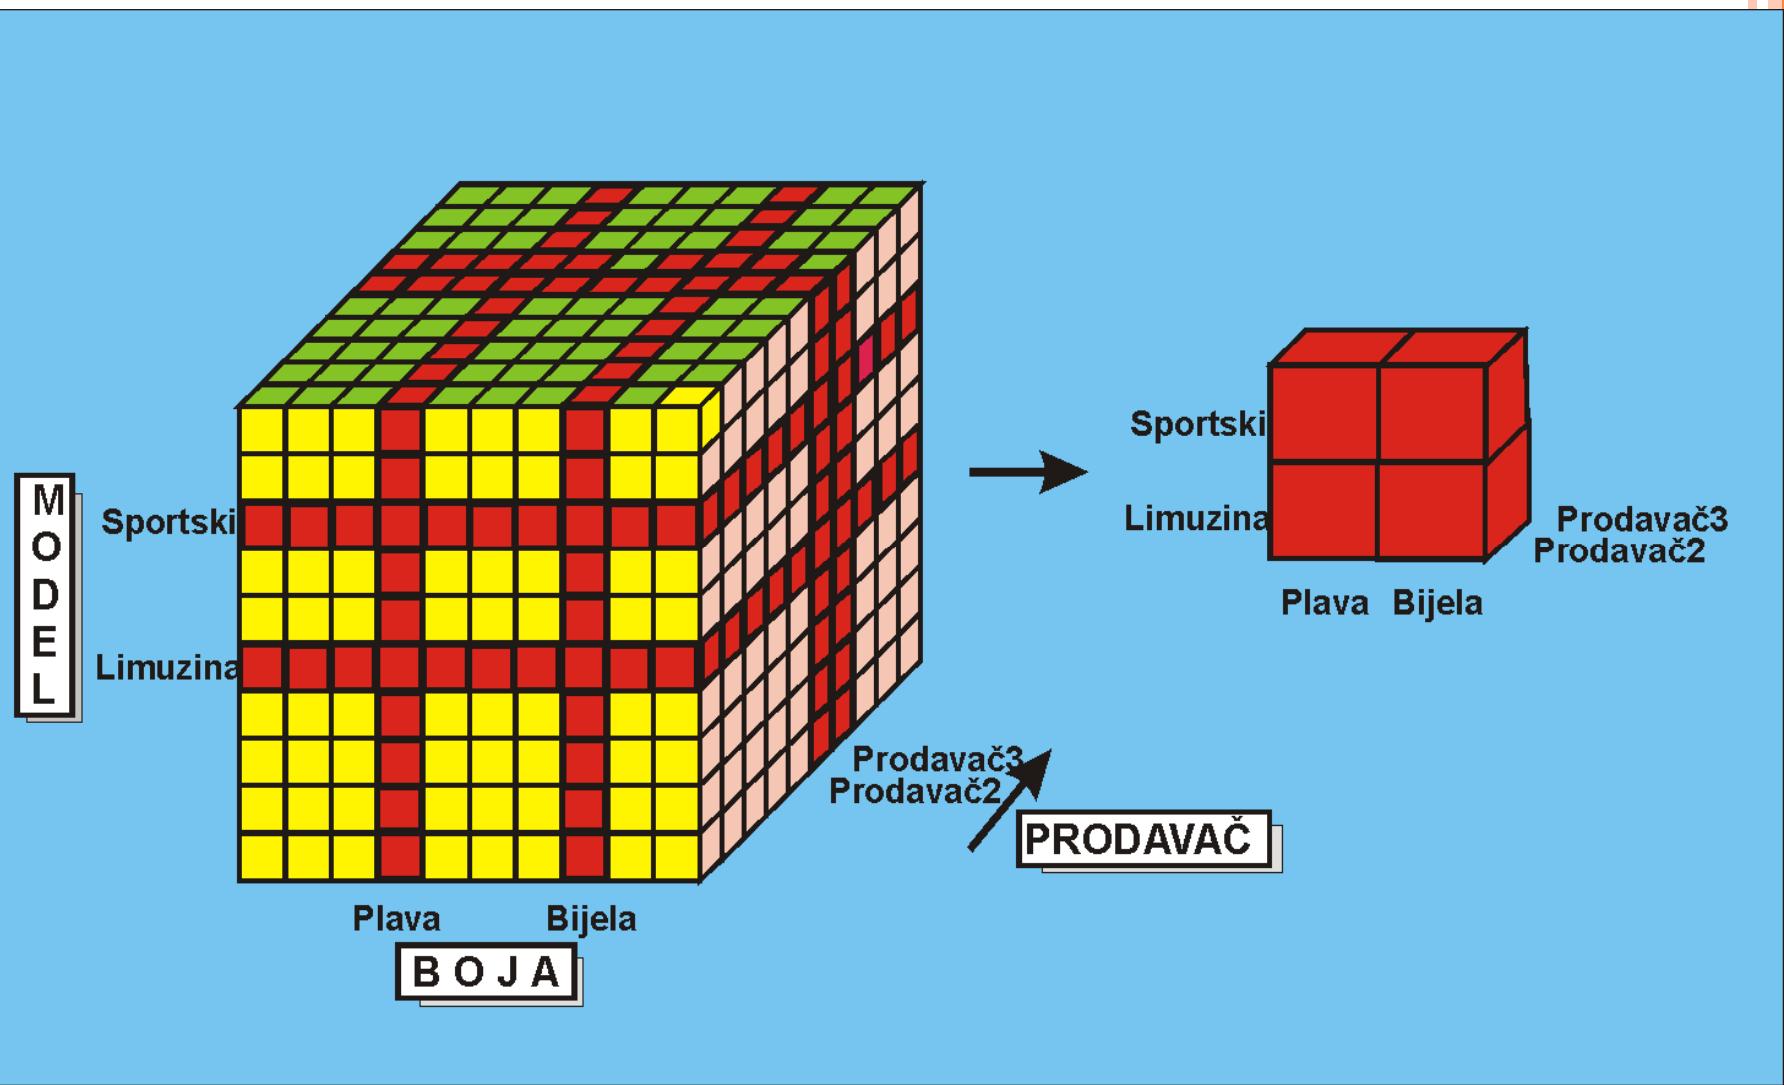
Fixed dimension: State
Value: RJ

Stock	1/98	2/98	3/98	4/98
TEL PN	+5%	-2%	+7%	+4%
PET PN	+2,5%	+3%	+4%	-1%
BB PN	-1%	+1,3%	+2,3%	+2,1%
LAME PN	-2%	+0,4%	+1%	+1,4%

SLICE & DICE



SLICE & DICE



PIVOTING [ROTIRANJE]

Pivoting – Analiza istih podataka iz različitih perspektiva



PIVOTING

The diagram illustrates the process of pivoting a data table. It shows two tables: the original wide-format table at the top and its tall-format pivot at the bottom, connected by a large black arrow labeled "Pivot".

Original Table (Wide Format):

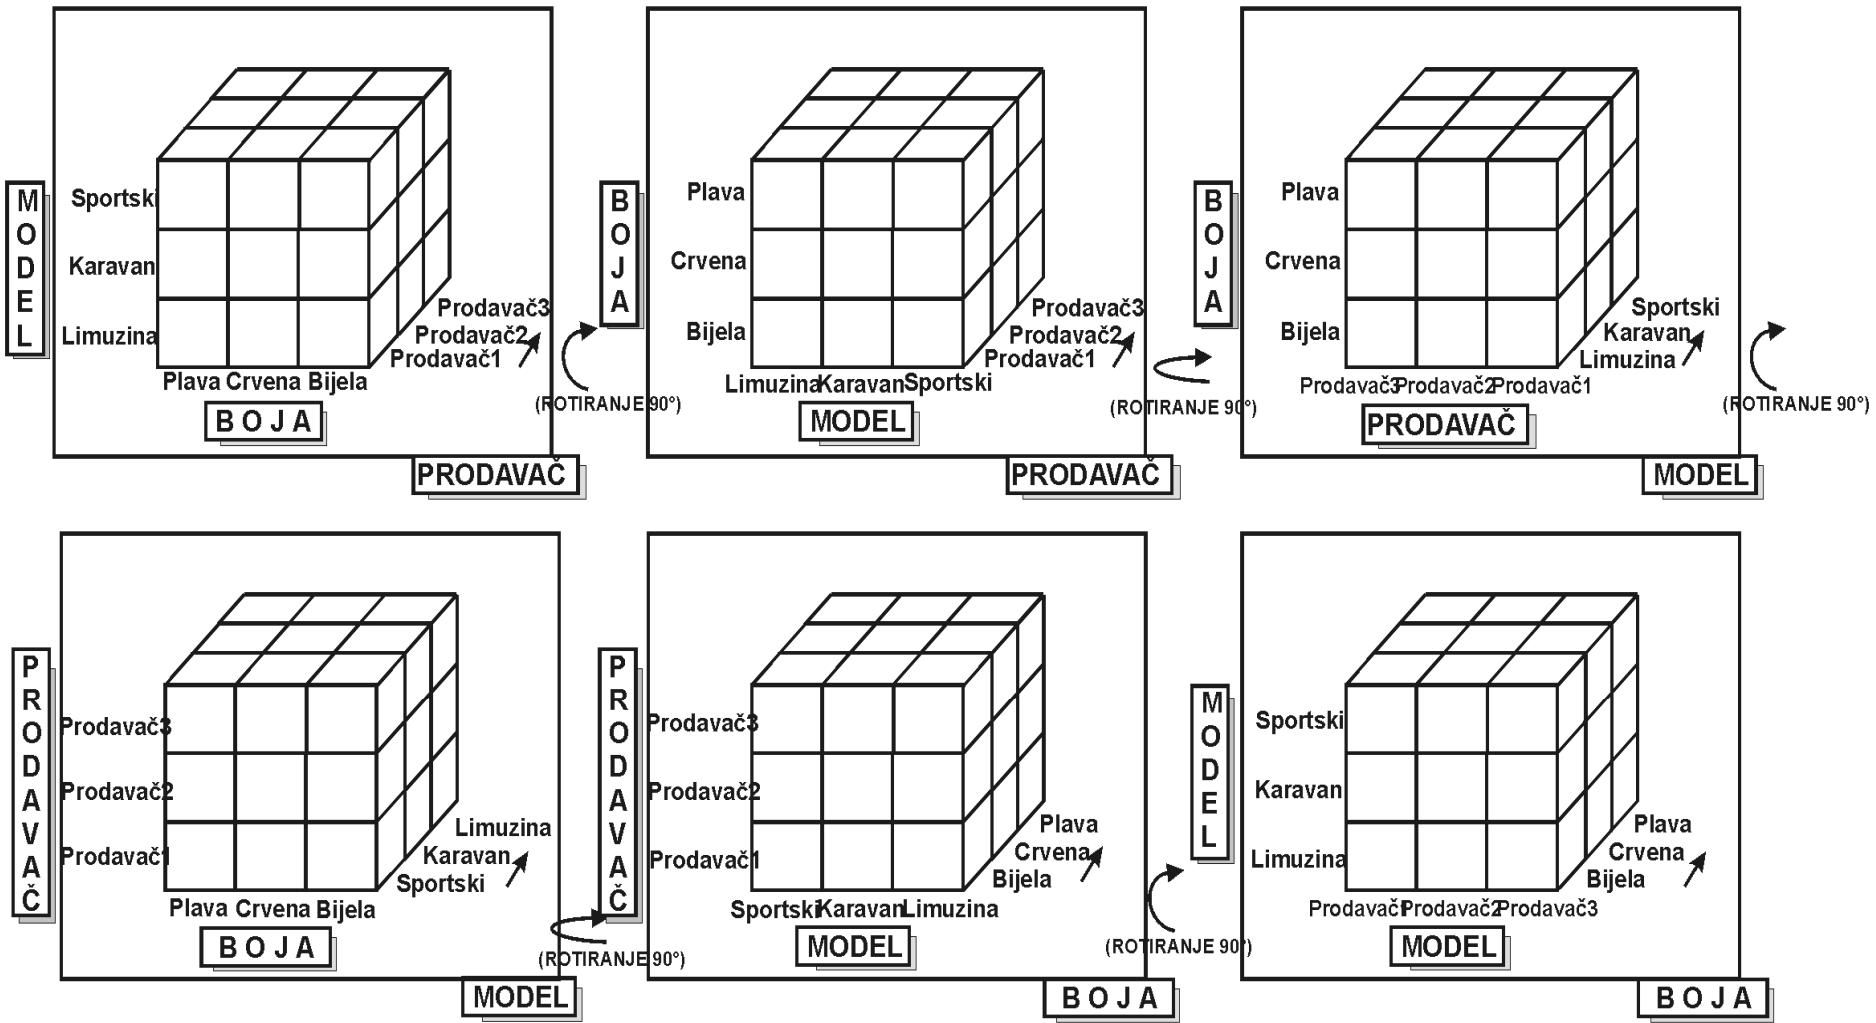
Metrics	PRODUCT	Milk	Coke	Juice	Total
	Sales in USD	Sales in USD	Sales in USD	Sales in USD	
STORE					
CA		40	60	80	180
OR		60	1,452	6,210	7,722
LA		2,430	2,346	9,106	13,882
Total		2,530	3,858	15,396	21,784

Pivoted Table (Tall Format):

Metrics	STORE	CA	OR	LA	Total
	Sales in USD	Sales in USD	Sales in USD	Sales in USD	
PRODUCT					
Soda		40	60	2,430	2,530
Milk		60	1,452	2,346	3,858
Juice		80	6,210	9,106	15,396
Total		180	7,722	13,882	21,784

Figure 4-11 Pivoting

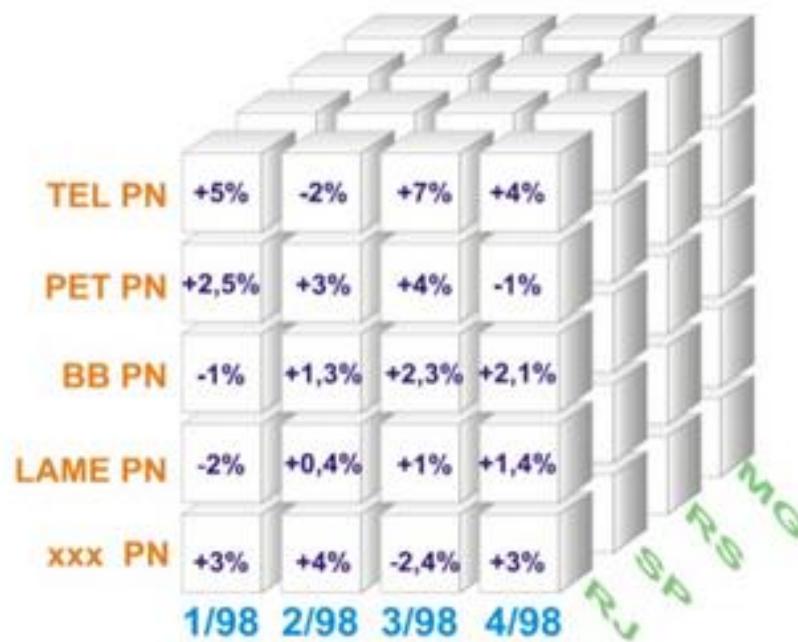
PIVOTING



Operations over OLAP Cube

Rotation

- Change of dimensions axis.



Fixed dimensions: State, Date, Stock
Values: RJ, 2/98, BB PN

Data	TEL PN	PET PN	BB PN	LAME PN
1/98	5%	2,50%	-1%	-2%
2/98	-2%	3%	1,30%	0,40%
3/98	7%	4%	2,30%	1%
4/98	4%	-1%	2,10%	1,40%

MODELIRANJE – DIZAJN PROCES

1. Identificirati poslovni proces
 - Izvor "mjerenja"
2. Identificirati usitnjenost
 - Što 1 redak u fakt tablici predstavlja ili znači?
3. Identificiranje dimenzija
 - Deskriptivni kontekst, odgovara usitnjenosti
4. Identificiranje činjenica
 - Numeričke zbrojive mjere, odgovaraju usitnjenosti



KORAK 1 – IDENTIFICIRANJE POSLOVNOG PROCESA

- Ova poslovna aktivnost se obično odnosi na izvorni sustav.
- Ne smije se pomiješati s poslovnim odjelom ili funkcijom. Dimenzijski model Naručivanja trebao bi podržati aktivnosti i Prodaje i Marketinga.
- Ako uspostavimo dimenzijski model koji predstavlja odjele, slijedi neosporno duplicitanje podataka s različitim oznakama i terminologijom.



KORAK 2 – IDENTIFICIRATI USITNJENOST

- Razina detalja povezana s mjerama iz fakt tablice.
- Kritičan korak neophodan prije koraka 3 i 4.
- To bi trebala biti najdetaljnija moguća razina.
- Kako opisujete pojedinačni redak u fakt tablici?



KORAK 3 – IDENTIFICIRANJE DIMENZIJA

- Lista svih diskretnih, tekstualnih atributa koji proizlaze iz fakt tablice.
- Najčešće se koristi "po" riječ kako bi se opisali zahtjevi.
- Svaka dimenzija se može promatrati kao "ulazna točka" za fakte (činjenice).
- Kako poslovni ljudi opisuju podatke koji proizlaze iz poslovnog procesa?



KORAK 4 – IDENTIFICIRANJE ČINJENICA

- Mora odgovarati usitnjenosti definiranoj u koraku 2.
- Tipične činjenice su numerički zbrojive.
- Činjenice koje pripadaju različitoj granularnosti pripadaju i odvojenim fakt tablicama.
- Činjenice su određene odgovorom na pitanje: "Što mi mjerimo?"
- Postotci i stope, kao što su postotak dobiti su nezbrojivi. Brojitelj i nazivnik bi trebali biti pohranjeni u fakt tablici.



PRIMJER

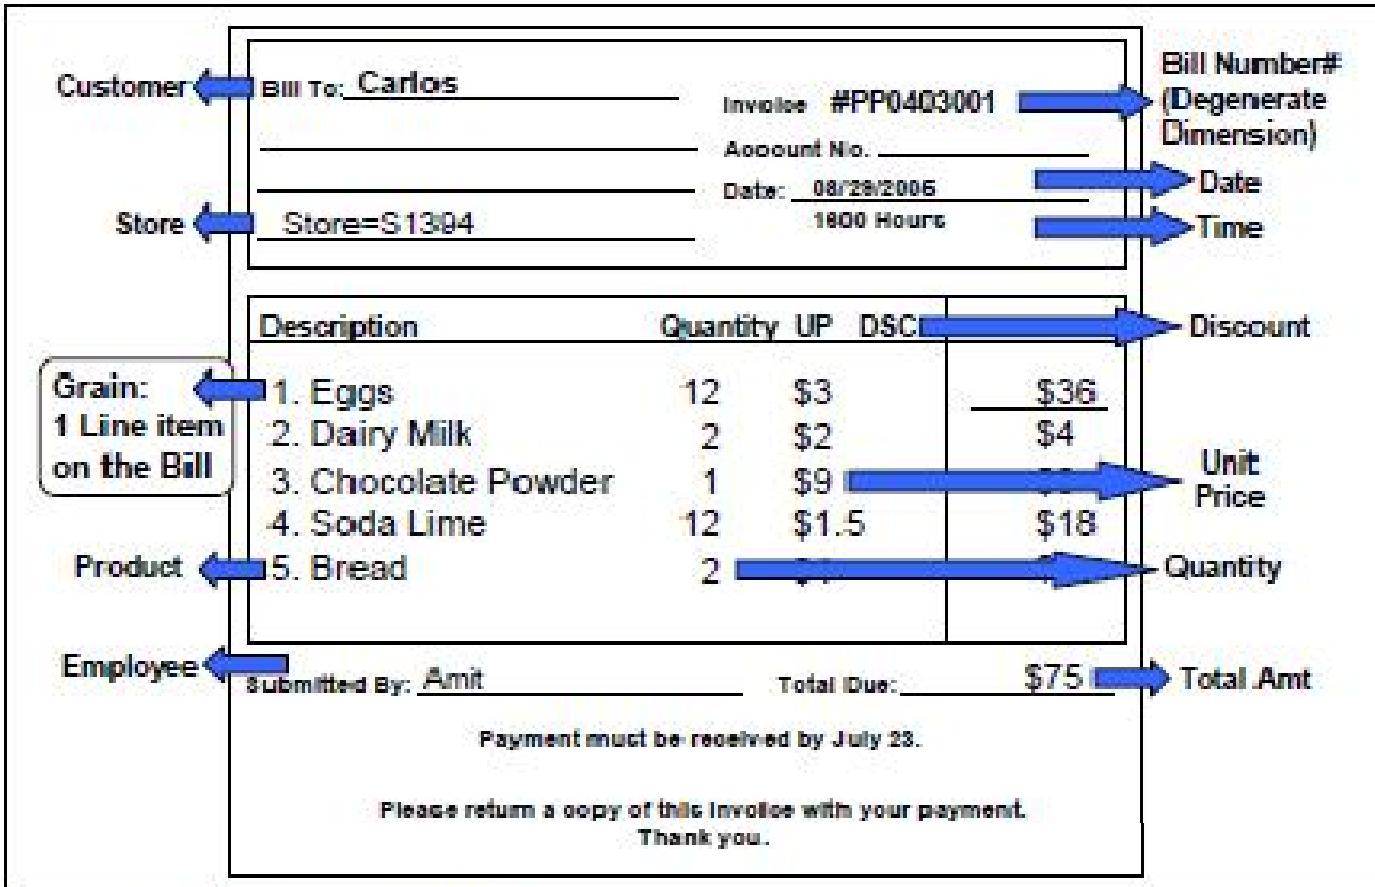


Figure 5-25 Grocery store bill

DM - PREDNOSTI

- Predvidiv, standardan okvir (OLAP, Alati za izvješćivanje i upite, korisnička sučeljamogu imati ugrađene čvrste pretpostavke o DM i učiniti korisničko sučelje razumljivijim, a obradu efikasnijom)
- Umjesto uporabe optimizatora, DBMS može napraviti vrlo čvrstu pretpostavku o tome da prvo "ograniči" dimenzijske tablice, a onda "napadne" fakt tablicu, sve odjednom s Kartezijevim proizvodom onih ključeva dimenzijskih tablica koji zadovoljavaju korisnička ograničenja.

DM - PREDNOSTI

- Predvidljivi okvir zvijezda sheme podnosi nepredvidljive promjene u ponašanju korisnika. Svaka dimenzija je isto vrijedna. Sve dimenzije se mogu promatrati kao simetrično jednake ulazne točke u fakt tablicu.

Logički dizajn može biti urađen neovisno o očekivanom uzorku upita.

Korisnička sučelja su simetrična, strategije upita su simetrične i SQL generiran nad dimenzijskim modelom je simetričan.



DM - PREDNOSTI

- DM je “elegantno proširiv” u kako bi omogućio nove neočekivane podatkovne elemente i nove dizajn odluke.
- Elegantno proširiv:
 - Sve postojeće tablice (i fakt i dimenzijske) se mogu promjeniti jednostavnim dodavanjem novih redaka u tablicu, odnosno tablica može biti promijenjena SQL Alter table naredbom.
 - Podaci ne moraju biti ponovno učitani.
 - Nijedan upitni ili izvještajni alat ne treba reprogramirati da prihvati promjenu.
 - Stare aplikacije nastavljaju s radom bez davanja različitih rezultata. Moguće je dodavanje novih zbrojivih numeričkih polja u fakt tablicu sve dok su konzistentni s temeljnom granulacijom fakt tablice.



DM - PREDNOSTI

- Postoje standardni pristupi za rad sa sličnim situacijama modeliranja u poslovnom svijetu:
 - Sporo promjenjive (Slowly changing) dimenzije, gdje "konstantna" dimenzija kao što je Proizvod ili Kupac se stvarno mijenja sporije i asinkrono.
 - Događajima upravljane (Event-handling) baze podataka gdje u je fakt tablica u pravilu bez vejdnosti tj. činjenica (factless).

DM - PREDNOSTI

- Upravljanje agregacijama:

Agregacije su zbrojeni slogovi koji su u pravilu redundantni ali se koriste za poboljšanje performansi upita.

Potrebna je sveobuhvatna agregacijska strategija u svakoj implementaciji DW-a.

Svi softverski paketi za upravljanje agregacijama ovise o specifičnoj strukturi fakt i dimenzijskih tablica, odnosno o dimenzijskom modelu.



1. Identificirati poslovni proces
 - Izvor "mjerenja"
2. Identificirati usitnjenost
 - Što 1 redak u fakt tablici predstavlja ili znači?
3. Identificiranje dimenzija
 - Deskriptivni kontekst, odgovara usitnjenosti
4. Identificiranje činjenica
 - Numeričke zbrojive mjere, odgovaraju usitnjenosti



KORAK 1 – IDENTIFICIRANJE POSLOVNOG PROCESA

Analiza rezultata ispitnih rokova na Sveučilištu

- Osnovni cilj (svrha) analize???
- Koje vrste izvješća korisnici očekuju???
- Koji su podaci neophodni da bi se omogućila izvješća???
- Izvori podataka???



KORAK 1 – IDENTIFICIRANJE POSLOVNOG PROCESA

Analiza rezultata ispita na Sveučilištu

- Svrha:
 - Dobiti informacije o (ne)uspjehu provjere znanja
 - Dobiti informacije o stopi prolaznosti
 - Dobiti informacije o najvišoj, najnižoj i prosječnoj ocjeni po ispitu, predmetu, studentu, profesoru, ispitnim rokovima, akademskim godinama, smjerovima, fakultetima



KORAK 1 – IDENTIFICIRANJE POSLOVNOG PROCESA

Analiza rezultata ispita na Sveučilištu

- Izvori podataka: Sveučilišni IS
 - Fakulteti
 - Smjerovi/Studijske grupe
 - Ispitni rokovi
 - Nastavno osoblje
 - Predmeti
 - Studenti
 - Ocjene (1-5)



KORAK 2 – IDENTIFICIRANJE GRANULARNOSTI

- Razina detaljnosti povezana s vrijednostima u fakt tablici.
- Kritični korak neophodan prije koraka 3 i 4.
- Poželjno je da bude što je moguće više atomizirana (detaljna) razina.
- "Kako opisujete jedan redak u fakt tablici?"

USITNJENOST



KORAK 2 – IDENTIFICIRANJE GRANULARNOSTI

- Razina detaljnosti povezana s vrijednostima u fakt tablici.
- Kritični korak neophodan prije koraka 3 i 4.
- Poželjno je da bude što je moguće više atomizirana (detaljna) razina.
- "Kako opisujete jedan redak u fakt tablici?"

USITNJENOST (GRANULARNOST):

Jedan redak za svaki ispit po predmetu i po studentu za ispitni rok !!



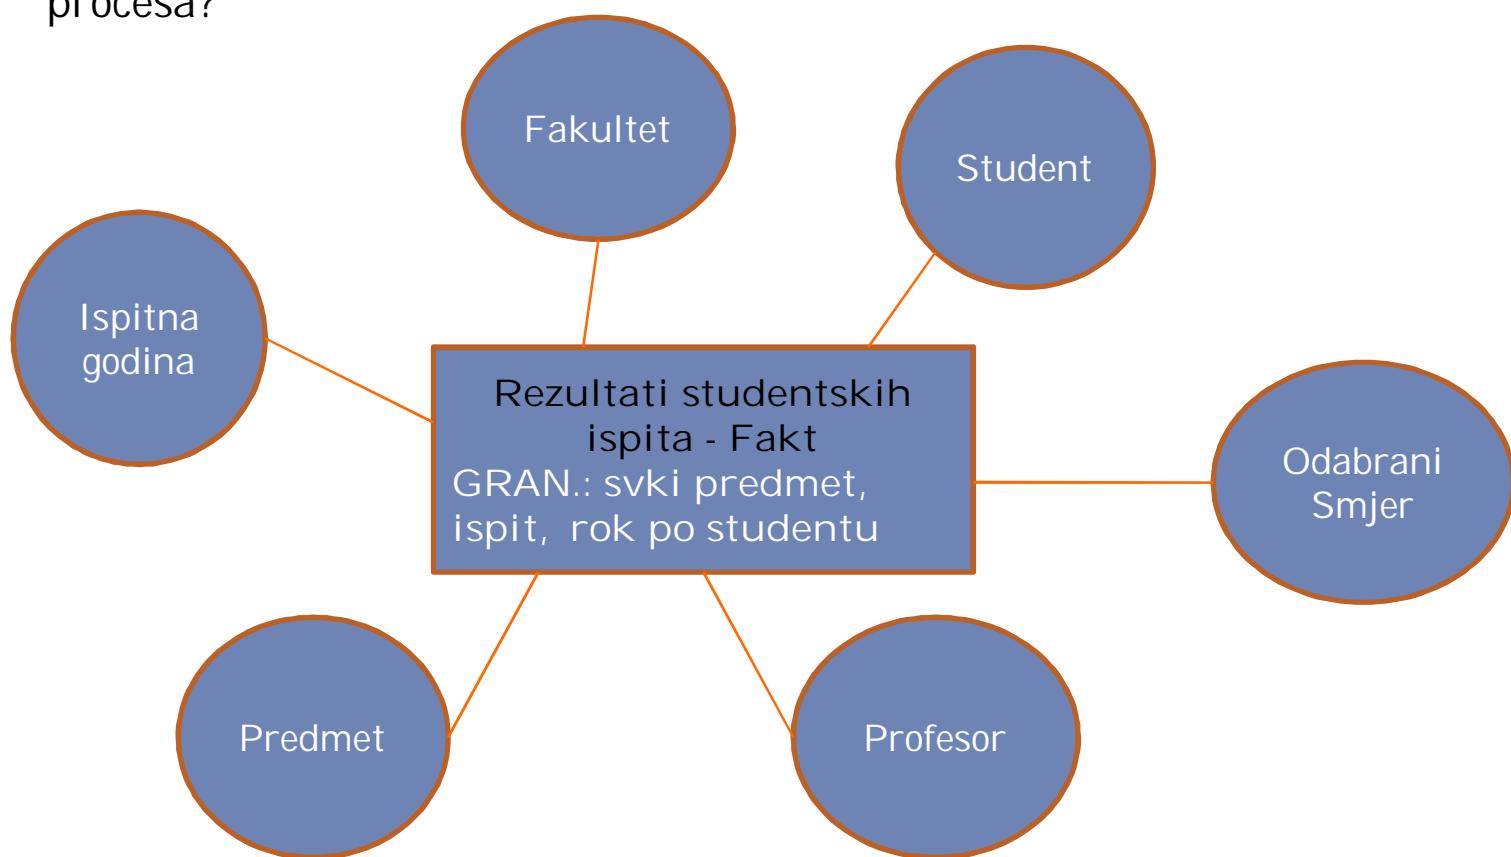
KORAK 3 – IDENTIFICIRANJE DIMENZIJA

- Popis svih diskretnih, tekstualnih atributa koji proizlaze iz fakt tablice.
- Koristi se riječ "po" za opis zahtjeva.
- Svaka dimenzija se može promatrati kao analitička "ulazna točka" za vrijednosti (činjenice/fakte).
- "Kako poslovni ljudi opisuju podatke koji rezultiraju iz poslovnih procesa?"



KORAK 3 – IDENTIFICIRANJE DIMENZIJA

- Popis svih diskretnih, tekstualnih atributa koji proizlaze iz fakt tablice.
- Koristi se riječ "po" za opis zahtjeva.
- Svaka dimenzija se može promatrati kao analitička "ulazna točka" za vrijednosti (činjenice/fakte).
- "Kako poslovni ljudi opisuju podatke koji rezultiraju iz poslovnih procesa?"



KORAK 3 – IDENTIFICIRANJE DIMENZIJA

PREDMET dimenzija

- Predmet ključ (PK)
- Predmet naziv
- ECTS
- Predavanja sati
- Vježbe sati
- Sadržaj
- Kompetencije

ROKOVI GODINE dimenzija

- Rok ključ (PK)
- Rok opis
- Akademska godina
- Rok/Sezona
- Rok tip *

* R – redoviti rok
I – izvanredni rok



KORAK 3 – IDENTIFICIRANJE DIMENZIJA

FAKULTET dimenzija

- Fakultet ključ (PK)
- Facultet naziv
- Facultet adresa
- Facultet telefon
- Facultet e-mail
- Facultet web

ODABRANI SMJER dimenzija

- Odabrani smjer ključ (PK)
- Odabrani smjer opis



KORAK 3 – IDENTIFICIRANJE DIMENZIJA

STUDENT dimenzija

- Student ključ (PK)
- Student ime
- Student prezime
- Student indeks
- Student datum rođenja
- Student status*
- Study ciklus
- Student semestar
- Student adresa
- Student telefon
- Student e-mail

PROFESOR dimenzija

- Profesor ključ (PK)
- Profesor ime
- Profesor prezime
- Profesor titula
- Zvanje
- Profesor JMBG
- Profesor datum rođenja
- Profesor adresa
- Profesor telefon
- Profesor e-mail

* R – redoviti bez plaćanja

P – redoviti uz plaćanje

I – izvanredni uz plaćanje



KORAK 4 – IDENTIFICIRANJE VRIJEDNOSTI

- Mora odgovarati usitnjenosti definiranoj u koraku 2.
- Tipične činjenice su numerički zbrojive.
- Činjenice koje pripadaju različitoj granularnosti pripadaju i odvojenim fakt tablicama.
- Činjenice su određene odgovorom na pitanje: "Što mi mjerimo?"
- Postotci i stope, kao što su postotak dobiti su nezbrojivi. Brojitelj i nazivnik bi trebali biti pohranjeni u fakt tablici.

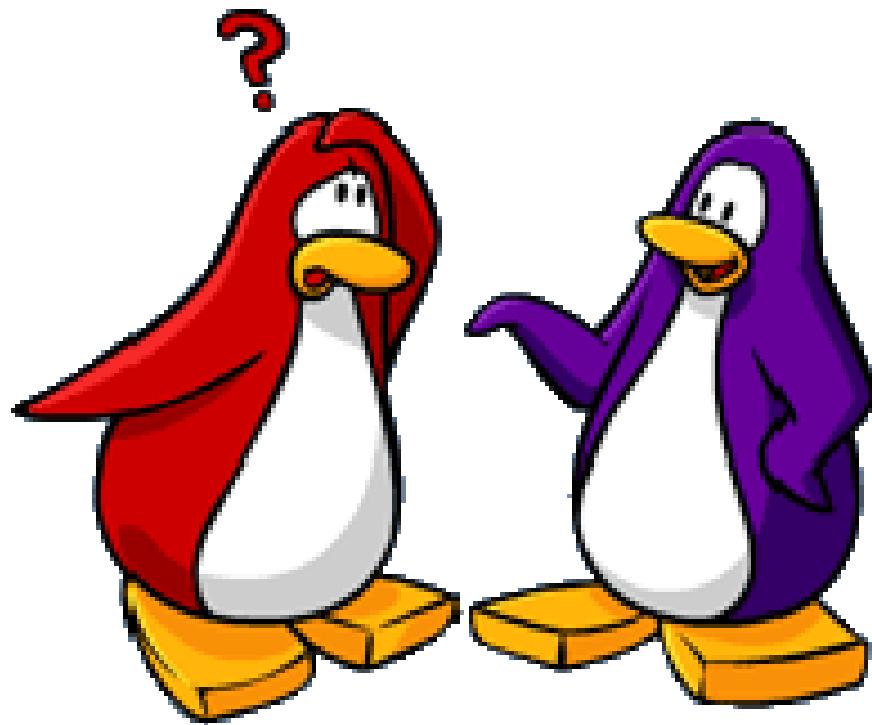


KORAK 4 – IDENTIFICIRANJE VRIJEDNOSTI

REZULTATI STUDENTSKIH ISPITA – FAKT

- Predmet ključ (FK)
- Rok ključ (FK)
- Fakultet ključ (FK)
- Odabrani smjer ključ (FK)
- Student ključ (FK)
- Profesor ključ (FK)
- Ocjena





Pitanja...