



**VISOKA POSLOVNA ŠKOLA
STRUKOVNIH STUDIJA
ČAČAK**

DIPLOMSKI RAD

Igradnja skladišta podataka

Mentor: _____
Profesor: _____

Student: _____
Br.Indeksa: _____

Sadržaj:

UVOD	2
I. DIO: TEORIJSKA RAZMATRANJA	3
1. OSNOVE SKLADIŠTENJA PODATAKA.....	3
1.1. Kratki povijesni pregled razvoja skladištenja podataka.....	3
1.2. Osnovni pojmovi i značajke skladišta podataka.....	5
1.2.1. Osnovni pojmovi.....	5
1.2.2. Značajke skladišta podataka.....	6
1.3. Ciljevi skladištenja podataka.....	7
1.4. Dimenzijski model.....	8
1.4.1. Što je dimenzijski model.....	9
1.4.2. Tablice cinjenica	11
1.4.3. Dimenzijske tablice.....	12
1.4.4. Dimenzija vremena	13
2. IZGRADNJA SKLADIŠTA PODATAKA.....	14
2.1. Proces izgradnje skladišta podataka.....	14
2.2. Neformalna metodologija izgradnje skladišta podataka.....	17
2.3. Sumarne tablice (agregacije).....	18
II. DIO: PRIMJER IZGRADNJE SKLADIŠTA PODATAKA UZ PRIMJENU PROGRAMSKOG PAKETA ORACLE WAREHOUSE BUILDER 3I	20
3. PRINCIP RADA ORACLE WAREHOUSE BUILDERA	20
3.1. Uvod u Oracle Warehouse Builder	20
3.2. Osnovni elementi Oracle Warehouse Buildera	22
3.3. Nacin rada Oracle Warehouse Buildera	22
4. IZRADA LOGICKOG MODELA SKLADIŠTA PODATAKA.....	24
4.1. Prikupljanje pocetnih informacija i definiranje zahtjeva	24
4.2. Logicki model skladišta podataka	26
4.2.1. Tablice cinjenica	26
4.2.2. Dimenzijske tablice.....	29
4.3. Izgradnja logickog modela skladišta u Oracle Warehouse Builderu	30
4.3.1. Stvaranje odredišnog modula.....	30
4.3.2. Stvaranje definicija za dimenzije.....	33
4.3.3. Stvaranje definicija za tablice cinjenica.....	37
4.3.4. Stvaranje izvorišnog modula i učitavanje definicija izvora podataka.....	40
5. MAPIRANJA	42
5.1. Opcenito o mapiranjima.....	42
5.2. Primjer izgradnje mapiranja dimenzije.....	45
5.3. Mapiranje tablice cinjenica	50
6. KONFIGURACIJA FIZICKIH SVOJSTAVA OBJEKATA U ORACLE WAREHOUSE BUILDERU	52
6.1. Konfiguracija fizickih svojstava skladišnog modula.....	52
6.2. Konfiguracija fizickih svojstava dimenzija, tablica, i tablica cinjenica.....	53
6.3. Konfiguracija mapiranja.....	56
6.3.1. Konfiguracija atributa u mapiranjima	56
6.3.2. Konfiguracija svojstava operatora u mapiranjima	58
6.3.3. Konfiguracija fizickih parametara mapiranja	59
7. UCITAVANJE POCETNIH PODATAKA I OSVJEŽAVANJE SKLADIŠTA PODATAKA NOVIM PODACIMA	63
7.1. Generiranje i pokretanje skripti	63
7.2. Periodicko osvježavanje i punjenje skladišta podataka novim podacima.....	65
7.3. Provjera učitanih podataka	67
ZAKLJUCAK.....	69
POPIS LITERATURE.....	71

Uvod

Zadatak ovog diplomskog rada je analizirati postupke izgradnje skladišta podataka s posebnim naglaskom na Oracle-ova rješenja, te nakon izgradnje analizirati dobivene rezultate. Za izgradnju skladišta koristio sam Oracle-ov programski paket Oracle Warehouse Builder 3i, a kao izvor podataka za skladište poslužila mi je baza podataka uspjeha studenata za Zavod za osnove elektrotehnike i električka mjerenja.

Sam proces izgradnje skladišta je složen i odgovoran posao. Zadatak izgradnje skladišta podataka zahtijeva dobro poznavanje principa rada relacijskih baza podataka kao i poznavanje SQL-a i PL/SQL-a. Također zahtijeva dobro razumijevanje poslovnog procesa koji se želi pratiti. Osnovni problem u izgradnji skladišta podataka je pravilno odabrati podatke bitne za proces koji pratimo i raspoznati činjenice (podatke koje ćemo mjeriti kroz neko razdoblje). Model podataka koji je prikladan za dizajn skladišta podataka je dimenzijski model koji će biti detaljno objašnjenu u ovom radu.

Proces izgradnje skladišta podataka se sastoji od nekoliko faza: faze razvoja logickog modela, faze definiranja procesa izvlačenja, transformacije i učitavanja podataka u skladište podataka, te faze provjere učitanih podataka. Ovisno o korištenom programskom paketu pri izradi skladišta podataka može postojati još koja faza kao što je u ovom slučaju faza konfiguracije i faza generiranja skripti. Ovaj rad je organiziran na taj način da se obradi svaka od tih faza u razvoju skladišta podataka.

Ovaj rad sam podijelio u dva dijela. U prvom dijelu koji se sastoji od dva poglavlja definirana su teorijska razmatranja o skladištenju podataka, dane su osnovne definicije i opisan je model podataka koji se koristi za izgradnju skladišta podataka. Također je opisan i proces izgradnje skladišta podataka. Drugi dio ovog rada je rezultat praktičnog rada i u njemu ću opisati kako izgraditi skladište u stvarnom svijetu. Za izgradnju sam koristio, Oracle-ov programski paket Oracle Warehouse Builder 3i, te su prvo opisani principi rada tog programskog paketa (3. poglavlje). U 4. i 5. poglavlju su opisani postupci u izgradnji logickog modela skladišta podataka kao i izrada mapiranja. U 6. poglavlju je opisana konfiguracija fizickih svojstava objekata u OWB-u, a u 7. poglavlju je opisano generiranje i pokretanje skripti, te testiranje učitanih podataka.

I. DIO: TEORIJSKA RAZMATRANJA

1. Osnove skladištenja podataka

Skladištenje podataka je novi koncept koji se pojavio sredinom 90-tih godina 20. stoljeća. Razvio se zbog potrebe dobivanja informacija u kratkom vremenu, te služi kao potpora poslovnim odlučivanju. Skladište podataka sadrži golemu količinu podataka i omogućava da se na osnovu tih podataka dobiju kvalitetna izvješća koja pomažu odgovornim ljudima pri donošenju poslovnih odluka.

U ovom poglavlju ću dati kratki povijesni pregled razvoja skladištenja podataka kao i razloga koji su doveli do njegovog nastanka, definirat ću glavne pojmove vezane uz skladištenje podataka, definirati ću ciljeve te opisati model podataka koji se koristi u skladištima podataka.

1.1. Kratki povijesni pregled razvoja skladištenja podataka

U povijesnom pregledu razvoja skladištenja podataka treba početi sa opisom kako se postupalo s podacima prije nastanka koncepta skladištenja. Kroz povijest sistemskog razvoja glavni naglasak je bio na unapređenju operacijskih sistema. Za takve sisteme nije praktično zadržavati stare podatke neodređeno vrijeme, već su se ti podaci uklanjali i spremali u arhive (većinom su se spremali na magnetske trake, vrpce ...). Takav način rada bio je tipičan za sustave 70-tih godina koji su bili monolitni sustavi sa centraliziranim “mainframe” računalom. Ipak takvi sustavi su glavni izvor podataka za analizu. Te sustave zovemo naslijeđeni sustavi (engl. legacy systems).

80-tih godina dolazi do popularizacije osobnih računala. Snaga tih računala raste, uvode se nove mogućnosti, pojavljuju se grafička sučelja prema korisniku (engl. GUI – graphical user interface), jednostavnije rukovanje te stoga računala postaju lakša za uporabu. Popularizacija osobnih računala dovela je do toga da se počeo smanjivati jaz između programera i krajnjih korisnika. Takvi sustavi su omogućili izvlačenje podataka iz naslijeđenih sustava na osobna računala. Razvili su se alati za izradu izvještaja i za analizu. Ipak ovakav način rada imao je manu koja se ispoljavala kroz fragmentaciju podataka na razna osobna računala i oni su bili usmjereni prema određenim svrhama. Također nije postojao standard za izvlačenje podataka na osobna

racunala. Ovakav nacin rada zahtijevao je od korisnika da poznaje strukturu dijela baze što je mnogim korisnicima bila velika zapreka.

Vrhunac sustava za analizu prije pojave skladištenja podataka bili su sustavi za potporu odlucivanju i izvršni informacijski sustavi. Iako ti sustavi zbog svoje visoke cijene nikad nisu našli široku primjenu, ipak su bili preteca skladištenja podataka.

Kao što smo vidjeli s podacima se kroz povijest postupalo razlicito. Na samom pocetku razvoja informatickih sustava podatke se cak uklanjalo sa sistema na posebne medije za pohranu podataka. Glavni uzrok za to je bila nedovoljno razvijena tehnologija. Tadašnja racunala su bila preslaba, premalog kapaciteta i nisu mogli zadovoljiti potrebe. Medutim napredak na polju elektronicke industrije doveo je do znatnog poboljšanja performansi sustava. Procesorska moc se neprekidno povecava, pojavljuju se napredne arhitekture procesora, ulazno/izlazni procesi (engl. input/output) se ubrzavaju, a što je najvažnije gustoca zapisa postaje veca, a time diskovi sve veceg kapaciteta i manjih dimenzija. Usprkos razvoju tih komponenti njihova cijena pada i mocni strojevi postaju pristupacni širem krugu ljudi, što je omogućilo drugaciji pristup pohrani podataka, kao i obradi tih podataka, a medu ostalim je omogućilo i razvoj koncepta skladištenja podataka.

Takoder se kao posljedica napretka pojavljuju sve snažnija osobna racunala koja omogucavaju razvoj klijent/server arhitekture kao i distribuiranog racunarstva. Programaska podrška se takoder razvija i izgrađuju se sve mocnije aplikacije koje se vrte na osobnim racunalima. Osobna racunala su za skladištenje podataka važna jer korisnici danas pristupaju podacima u skladištima podataka koristeći uglavnom osobna racunala i aplikacije na njima.

Još jedan faktor je utjecao na skladištenje podataka, a to je pojava koncepta Intraneta i korištenja web baziranih aplikacija. Putem Intraneta podaci u skladištu podataka postaju dostupni svima unutar kompanije.

Osim napretka na polju elektronicke industrije na razvoj skladištenja podataka je utjecala i sama poslovna priroda tj. promjene u poslovnoj prirodi.

Tijekom 90-tih su se dogodile velike promjene u svijetu. Komunizam se raspao, nastale su nove države koje su prešle na tržišno orjentiranu ekonomiju te su se tako stvorila nova tržišta. Ritam života se ubrzao, vrijeme je postalo izuzetno važno.

Javio se globalizacijski pokret, kompanije su prerasle granice država i počele su se širiti po svijetu. U tom modernom načinu rada informacija je postala izuzetno bitna i to ona informacija koja je isporučena na vrijeme, te se javila potreba za nečim što se danas zove skladište podataka.

1.2. Osnovni pojmovi i značajke skladišta podataka

1.2.1. Osnovni pojmovi

U ovom poglavlju ću navesti osnovne pojmove vezane uz skladištenje podataka, te ću dati i njihove definicije.

“Skladište podataka je baza podataka koja sadrži povijesne, nepromijenjive podatke koji su logički i fizički izvučeni iz raznih izvora. Ti podaci se u skladu s definiranim modelom učitavaju u skladište i integriraju s postojećim podacima, a sve to u svrhu potpore poslovnom odlučivanju.” [4].

Kao što je vidljivo iz definicije skladište sadrži povijesne podatke i to detaljne i sumarne. Ti podaci dolaze iz raznih izvora, uglavnom operacijskih i transakcijskih baza. Bitno je naglasiti da je skladište podataka fizički odvojeno i logički transformirano od izvora podataka.

“Skladištenje podataka je proces integracije podataka o poslovanju neke organizacije u jednu bazu podataka iz koje krajnji korisnici mogu raditi izvješća, postavljati upite i analizirati podatke.” [4].

Treba reći da je skladištenje podataka proces koji ne završava inicijalnim učitavanjem podataka, već se skladište podataka osvježava novim podacima u nekim, više ili manje pravilnim, vremenskim intervalima (npr. svaki dan, tjedan, mjesec). Iz toga slijedi da je skladištenje podataka kontinuiran i dugotrajan proces.

Uz pojmove skladištenja i skladišta podataka često se još spominju pojmovi iskopavanja podataka (engl. data mining), OLAP (engl. On-Line Analytic Processing) i metapodaci.

“Iskopavanje podataka (engl. data mining) je proces automatskog otkrivanja prethodno nepoznatih obrazaca i odnosa među podacima u bazi podataka.”[4].

OLAP (engl. On-Line Analytic Processing) obuhvaća skupa alata koji krajnjem korisniku pružaju potporu poslovnom odlučivanju, a temelje se na

dimenzijskom (višedimenzijskom) pristupu. Cilj takvog pristupa je omogućavanje korisniku da dobije uvid u značenje podataka na osnovu kojeg onda korisnik donosi odluke. Također taj skup alata sadrži i alate koji korisnicima pomažu u prikazivanju podataka u obliku raznih grafova i tablica.

Metapodaci (podaci o podacima, engl. metadata) je izraz koji označava sekundarne, pomoćne podatke koji sadrže informacije o podacima u skladištu podataka ili sadrže informacije kako te podatke najlakše obraditi. Metapodaci nam pomažu i u izvlačenju podataka i u rješavanju upita nad podacima.

1.2.2. Značajke skladišta podataka

Osnovna ideja skladištenja podataka je da se u njemu pohranjuju podaci namijenjeni za izvođenje poslovne analize, a pristup tim podacima je najefikasniji ako su ti podaci odvojeni od podataka pohranjenih u operacijskim sistemima. Postoje mnogi razlozi za to razdvajanje koji su se tijekom vremena razvijali, ali što je bitno ti razlozi se razmatraju formalno prilikom izgradnje skladišta podataka.

Jedan od tih razloga za razdvajanje je činjenica da podaci u skladište podataka mogu doći i iz više izvora (više operacijskih sistema). Ako podaci dolaze iz više izvora logično je da se kombiniraju i spremaju samostalno i odvojeno od svojih izvora. Podaci se izvlace iz raznih izvora kako bi se mogli uspoređivati. Mogućnost uspostavljanja i razumijevanja odnosa između aktivnosti različitih organizacijskih grupa unutar kompanije se često istice kao najveća snaga skladišta podataka.

Također bitan razlog za odvajanje podataka od operacijskih sistema je činjenica da se procesi obrade transakcije i analize podataka bitno razlikuju odnosno da postoji razlika između transakcijskih (operacijskih) sistema i sistema za analizu. Transakcijski sistem (često se naziva i OLTP – On-Line Transaction Processing) pridaje najveću važnost raspoloživosti i brzini obrade i ne smije se dozvoliti da analiza podataka dovede do degradacije performansi transakcijskog sistema. To je ključni razlog razdvajanja. Transakcijski sistem i skladište podataka se također razlikuju i po podacima. Kod transakcijskog sistema ti podaci sadržavaju trenutne vrijednosti, oni su detaljni i izuzetno promijenjivi (tijekom svake sekunde se može obaviti i nekoliko tisuća transakcija koje mijenjaju vrijednosti tih podataka). Za razliku od transakcijskog sistema skladište podataka sadrži sumarne podatke koji su bitni za analizu, podaci su vremenski nepromijenjivi (jednom kad se učitaju u

skladište više se ne mijenjaju). Sustavi se razlikuju i po namjeni. OLTP je namijenjen za vođenje poslovnog procesa dok je skladište namijenjeno za izvođenje procesa analize i izvještavanja. OLTP najčešće pristupa nekoliko zapisa odjednom dok skladište cita i do nekoliko milijuna zapisa istovremeno. OLTP koriste službenici za obavljanje svog posla dok skladište koriste analiticari i manageri za donošenje poslovnih odluka. OLTP i skladište su sustavi koji se razlikuju u svim bitnim znacajkama te je stoga logično da ta dva sustava budu odvojena i fizički i logički.

	OLTP	SKLADIŠTE PODATAKA
Sadržaj podataka	Trenutne vrijednosti	Povijesni podaci
Vrijednost podataka	Vrlo promijenjivi podaci	Nepromijenjivi podaci
Namjena	Vođenje poslovnih operacija	Analiza i izvješćivanje
Jednica obrade	Transakcija	Upit
Korisnici	Službenici	Analiticari i manageri
Rasploživost	Vrlo bitna	Manje bitna
Izmjena podataka	Polje po polje	Nema izmjene
Radne karakteristike	Citanje/Pisanje	Citanje
Interakcija korisnika	Predodređena	Ad-hoc
Pristup zapisima	Nekoliko zapisa odjednom	Milijunima zapisa istovremeno
Fokus	Spremanje podataka	Dobivanje informacija

Slika 1.1. Razlike između OLTP i skladišta podataka

Da bi se to razdvajanje postiglo potrebno je provesti logičku i fizičku transformaciju podataka s transakcijskog sistema u skladište podataka. Pritom je izuzetno bitno da svi podaci budu transformirani i integrirani u skladište podataka na konzistentan način. To znači da se kroz cijelo skladište podataka moraju zadržati konzistentne konvencije imenovanja, konzistentne mjerne jedinice varijabli, konzistentne strukture šifriranja, itd.

1.3. Ciljevi skladištenja podataka

Skladištenje podataka odnosno izgradnja skladišta podataka imaju svoj razlog i opravdanost. Razlog za pokretanje jednog takvog skupog i složenog projekta leži u činjenici da ako se taj projekt dobro i stručno napravi, on omogućuje svojim korisnicima dobivanje kvalitetne informacije u trenutku što je u današnjim uvjetima poslovanja ne samo poželjno već i neophodno. Svaki projekt, pa tako i projekt izgradnje skladišta podataka, mora zadovoljiti određene zahtjeve (ciljeve). Neki od ciljeva koje skladišta podataka trebaju postići ili omogućiti su:

1. Skladište podataka mora omogućiti pristup podacima bitnim za neku organizaciju ili kompaniju
 - Manageri i analitici moraju imati pristup do podataka koji su bitni za tu organizaciju. Taj pristup treba biti neposredan, brz, na zahtjev korisnika i mora omogućiti visoke performanse. Sve to korisnici moraju moći postići koristeći svoje osobno računalo.
2. Podaci u skladištu podataka moraju biti konzistentni
 - Konzistentnost znači da ako dva korisnika traže isti podatak moraju dobiti isti odgovor iako su oni to tražili u različito vrijeme. Također znači da ako podaci od jučer nisu do kraja učitani korisnik mora biti upozoren.
3. Podaci se u skladištu podataka mogu kombinirati na sve moguće načine (engl. dice and slice requirement)
 - To omogućava dimenzijski model
4. Skladište podataka nisu samo podaci, već ono mora sadržavati i skup alata za postavljanje upita (engl. query tools), alata za analizu i predstavljanje informacije
 - Smatra se da je 60% potrebnog za uspjeh skladišta podataka sadržano u samim podacima, a 40% se odnosi na software za analizu.
5. Skladište podataka je mjesto gdje se objavljuju korišteni podaci
6. Kvaliteta podataka u skladištu je pokretač poslovnog restrukturiranja

1.4. Dimenzijski model


Kao što je već spomenuto u prošlom poglavlju u transakcijskim sistemima se koristi relacijski model podataka koji je normaliziran i optimiziran za postizanje visokih brzina obrade. Takav model podataka se pokazao izvanrednim kada je riječ o transakcijskim obradama u kojima se dohvaca najviše nekoliko desetaka zapisa odjednom. Međutim za potrebe skladišta podataka, u kojima se dohvaca i do nekoliko milijuna zapisa istovremeno, taj model je neprihvatljiv. Problem leži u činjenici da je relacijski model podataka normaliziran i kao takav je neuporabljiv za izvršavanje kompleksnih upita nad milijunima podataka. Zato se u skladištu taj model podataka zamjenjuje s dimenzijskim modelom koji je na višem stupnju apstrakcije od

relacijskog i zato je pogodniji za skladište podataka. Dimenzijski model će biti detaljno obrađen u ovom poglavlju.

1.4.1. Što je dimenzijski model

“Dimenzijski model je tehnika logickog dizajna koja teži prikazivanju podataka na standardiziran, intuitivan način koji omogućava pristup podacima velikom brzinom.”[7].


Dimenzijski model se najčešće prikazuje apstraktno kao kocka čije dimenzije predstavljaju dimenzije posla koji modeliramo, a podatak na presjeku tih dimenzija predstavlja podatak koji tražimo.



Slika 1.2. Prikaz dimenzijskog modela podataka u obliku kocke

Broj dimenzija u praksi može biti i veci od tri pa se onda govori o višedimenzionalnoj kocki. Gotovo u svim dimenzijskim modelima postoji dimenzija vremena. Organiziranje i spremanje podataka prema ovom modelu omogućuje korisnicima bolje razumijevanje podataka i omogućuje da korisnička sučelja budu jednostavnija za korištenje, a izvedba upita na zadovoljavajućoj razini.

Struktura dimenzijskog modela se sastoji od jedne tablice sa složenim ključem koje se naziva tablicom činjenica (engl. fact table) i više tablica dimenzija (engl. dimensional tables) od kojih svaka ima jednostavan ključ koji je dio složenog ključa tablice činjenica. Takva struktura se često zove zvijezda spoj (engl. star-join schema). Na slici 1.3. je prikazan tipičan izgled dimenzijskog modela. O tablicama činjenica i dimenzija bit će malo kasnije više riječi.



Slika 1.3. Prikaz tipicnog dimenzijskog modela

Dimenzijski model i relacijski model se razlikuju u mnogo čemu. Relacijski model je puno složeniji (tj. dijagram relacijskog modela je mnogo složeniji) od dimenzijskog modela. Mnogi dizajneri zato kažu da zbog toga dimenzijski model sadrži manje informacija i da se on koristi za sažetke više razine. Najveći autoritet u području skladištenja podataka i jedan od pionira skladištenja podataka Ralph Kimball smatra da to nije točno: “Osnovni odnos između relacijskog i dimenzijskog modela je da se dijagram relacijskog modela razlaže u nekoliko dijagrama dimenzijskog modela. Dijagram relacijskog modela predstavlja svaki mogući poslovni proces u nekoj kompaniji i odnose između njih i stoga je izuzetno kompleksan. Prvi korak u pretvaranju dijagrama relacijskog modela u dijagram dimenzijskog modela je razdvajanje poslovnih procesa i njihovo modeliranje zasebno. Drugi korak je nalaženje “many-to-many” odnosa i pretvaranje tih odnosa u tablice činjenica. Ostatak se denormalizacijom pretvara u tablice dimenzija. Rezultirajući dijagram dimenzijskog modela za relacijski model za veliko poduzeće može imati 10-25 vrlo sličnih zvijezda spojeva od kojih svaki može imati 4-12 tablica dimenzija.”[7].

Uporaba dimenzijskog modela u skladištu podataka ima mnoge prednosti pred relacijskim modelom. Kao prvo, dimenzijski model je predvidljiv, standardiziran okvir. Korisnici, aplikacije, mogu pretpostaviti mnoge stvari o dimenzijskom modelu koje tada omogućuju razumljivija sučelja ili veću efikasnost obrade. Druga prednost

leži u činjenici da predvidljiv okvir zvijezda spoja odolijeva neočekivanim promjenama u ponašanju korisnika. Dimenzijski model je proširiv u smislu prihvatanja novih, neočekivanih podataka i novog dizajna. Sve tablice se mogu promijeniti dodavanjem novih redova, raspored im se može promijeniti, a pritom se stari podaci ne trebaju ponovno učitati, a i aplikacije se ne trebaju mijenjati da bi podržale promjenu. Također snaga dimenzijskog modela je u tome da postoje standardizirani pristupi za rješavanje uobičajenih situacija u poslovnom svijetu. Svaka od tih situacija ima svoje dobre alternative (neke od tih situacija i modela su npr. sporo mijenjajuće dimenzije gdje se konstantna dimenzija kroz dugi niz vremena mijenja). Zadnja prednost leži u činjenici da dimenzijski model omogućava kreiranje agregacijskih tablica koje ubrzavaju obradu. U zadnje vrijeme se to polje znatno razvilo pojavom odgovarajućih aplikacija i raznih utility-a (aggregation navigator).

1.4.2. Tablice činjenica

Kao što je već spomenuto dimenzijski model se implementira u strukturu znanu kao zvijezda spoj koja se sastoji od tablice činjenica (engl. fact table) i dimenzijskih tablica (engl. dimensional tables). Tablica činjenica je mjesto gdje se spremaju brojčani poslovni pokazatelji. Svaki od tih pokazatelja se nalazi negdje na presjeku svih dimenzija. Ti pokazatelji se nazivaju činjenicama i otuda se tablica zove tablica činjenica. Tipičan primjer za činjenicu je npr. atribut koji sadrži ukupnu vrijednost proizvoda prodanog određenog dana.

Najbolje i najkorisnije činjenice su: brojčane, kontinuirano vrednovane i zbrojive. Činjenice trebaju biti brojčane jer su one pokazatelji nekog poslovnog procesa, a taj proces se iskazuje nekakvim iznosima (koliki je profit, koliko firma duguje, koliki su troškovi...).

Činjenice su obično kontinuirano vrednovane što znači da mogu poprimiti različite vrijednosti svaki put kad se mjere. Činjenice i ne moraju biti kontinuirano vrednovane, već se to pravilo o kontinuiranoj vrijednosti više koristi kao snažna preporuka dizajnerima skladišta podataka kako bi lakše razlučili činjenice od dimenzijskih atributa.

Najbolje činjenice su zbrojive i uvijek se teži k tome da činjenice budu zbrojive. Razlog tomu je činjenica da se pri gotovo svakom upitu prolazi kroz stotine, tisuće, pa čak i milijune zapisa kako bi se izgradio odgovor. Taj veliki broj zapisa se

može sažeti u nekoliko redova ako se cinjenice zbroje. Cinjenice u tablici cinjenica mogu još biti nezbrojive ili poluzbrojive. Poluzbrojive cinjenice se mogu zbrajati samo kroz neke dimenzije, dok se nezbrojive uopće ne mogu zbrajati kroz nijednu dimenziju, a to nije prihvatljivo za skladišta podataka.

Kao i svaka tablica i tablica cinjenica mora imati ključ. Kod nje se ključ sastoji od više atributa. Dakle, tablica cinjenica ima složeni ključ, i što je bitno on se sastoji od svih primarnih ključeva dimenzijskih tablica. Zbog takve strukture u bazi nema složenih odnosa (najsloženiji je odnos jedna prema više tablica) te je stoga omogućena izvedba složenih upita. Tablica cinjenica je, uobčajeno, najveća tablica u skladištu podataka.

1.4.3. Dimenzijske tablice

Dimenzijske tablice spremaju podatke vezane za svaku pojedinu dimenziju. Dimenzije daju cinjenicama kontekst, one su prirodni poslovni parametri koji određuju svaku cinjenicu. Dimenzije se opisuju u dimenzijskim tablicama koristeći iscrpne tekstualne opise. U dobro dizajniranom skladištu podataka dimenzijske tablice imaju vrlo velik broj atributa koji su tekstualnog oblika, a po vrijednosti su diskretni (poprimaju vrijednosti iz određenog skupa vrijednosti), i koji kasnije služe kao izvor ograničenja u upitima (engl. constraints) i naslova stupaca (engl. row header) u izvještajima. Jedna tipična dimenzijska tablica izgleda kao na slici 1.4.

Dimenzijska tablica bi trebala imati što veći broj atributa jer se tako povećava broj ograničenja u upitima, a time se povećava i količina informacija koja je korisniku dostupna. Dimenzijske tablice su denormalizirane radi jednostavnosti dizajna i učinkovitijeg izvođenja upita. One su puno manje od tablica cinjenica pa normalizacija dimenzijskih tablica u svrhu uštede prostora nema nikakvog učinka.

Upiti u skladištu podataka se obrađuju tako da se prvo u dimenzijskim tablicama nađu sve vrijednosti ključa koje zadovoljavaju postavljena ograničenja, a zatim se od njih spoje sve moguće kombinacije složenih ključeva koje će se tražiti u tablici cinjenica. Nadeni podaci se sumiraju i grupiraju prema specifikaciji korisnika.

DIMENZIJA ARTIKLI

kljuc_artikl
opis_artikla
broj_aritkla
velicina_paketa
proizvodac
podkategorija
kategorija
odjel
tip_pakiranja
težina
mjerna_jedinica_težine
jedinica_po_kutiji
kutija_po_paleti
širina_na_polici
visina_na_polici
dubina_na_polici
... i mnogi drugi

Slika 1.4. Jedna tipicna dimenzijska tablica

1.4.4. Dimenzija vremena

DIMENZIJA VRIJEME

kljuc_vrijeme
dan_u_tjednu
broj_dana_u_mjesecu
ukupni_broj_dana
broj_tjedna_u_godini
ukupni_broj_tjedna
mjesec
ukupni_broj_mjeseca
kvartal
fiskalni_period
godina
zastava_praznika
zastava_vikenda
zastava_zadnjeg_dana_u_mjesecu

Dimenzija vremena je dimenzija koja je prisutna u svim skladištima podataka, zato što je svako skladište podataka vremenska serija snimaka stanja neke organizacije. Snimamo stanja transakcijskog sistema i spremamo ta snimljena stanja u skladište podataka kao niz slojeva podataka te je stoga svako skladište podataka vremenski niz. Nakon toga, analizirajući podatke, kopamo kroz slojeve podataka kako bi shvatili kako je naše poduzeće izgledalo u nekoj točki vremena. Tipična dimenzija vremena može izgledati kao na slici 1.5.

Slika 1.5. Dimenzija vremena


2. Izgradnja skladišta podataka

2.1. Proces izgradnje skladišta podataka

Da bi uopće došlo do izgradnje skladišta podataka potrebno je ispuniti neke zahtjeve. Kao prvo, treba postojati želja i potreba za skladištem podataka, te treba postojati netko tko će gurati taj projekt. Sama organizacija mora biti spremna za skladište podataka, pri čemu se spremnost očituje u postojanju poslovnog motiva, raspoloživosti podataka, spremnosti ljudi na promjene itd. Proces izgradnje započinje definiranjem korisničkih zahtjeva. Projektant u razgovoru s korisnicima saznaje njihove želje i potrebe. Nakon toga u razgovorima s administratorom operacijske baze saznaje strukturu baze i s kojim podacima raspolaže. Projektant mora pronaći ravnotežu između želja korisnika i realnosti koju pružaju postojeći podaci.

Kada se analiziraju zahtjevi i postojeći podaci u operacijskoj bazi, prelazi se na izradu logičkog modela skladišta podataka. Kao što sam već spomenuo za skladišta podataka se koristi dimenzijski model podataka. Podaci koje ćemo učitati u skladište moraju se fizički i logički transformirati u odgovarajući oblik. Pritom je izuzetno bitno da svi podaci budu transformirani i integrirani u skladište podataka na konzistentan način. To znači da se kroz cijelo skladište podataka moraju zadržati konzistentne konvencije imenovanja, konzistentne mjerne jedinice varijabli, konzistentne strukture šifriranja, itd.

Podaci se logički transformiraju prilikom izvlačenja iz transakcijske baze i učitavanja u skladište podataka. Podaci su u transakcijskoj bazi bili smješteni u sustavu visokih performansi koji sadrži relacijski model podataka optimiziran za brzo izvođenje. Podaci u skladištu podataka se modeliraju u dimenzijski model podataka koji je pogodan za izvođenje upita nad milijunima zapisa istovremeno. Također ti podaci moraju biti organizirani na način da omogućuju jednostavno proširenje i strukturirani na način da u njega mogu ući podaci iz više izvora. Također je izuzetno bitno da se model podataka slaže sa strukturom posla i da prati razvoj posla (i za to je dimenzijski model izuzetno pogodan). Podaci u skladištu podataka su uglavnom denormalizirani i oni osiguravaju statički odnos u povijesnim podacima. Logička transformacija prikazana je na slici 2.1.




Slika 2.1. Logička transformacija podataka

Fizicka transformacija (prikazana na slici 2.2.) homogenizira i pročišćava podatke i obavlja nekoliko zadataka čiji je cilj osigurati razumijevanje pohranjenih podataka i njihovu konzistentnost u skladištu podataka. U transakcijskom sustavu za pojmove i imena atributa se koriste kriptička i teško razumljiva imena (npr. brkup) koja bi krajnjem korisniku bila teška za uporabu. Također različiti izvori mogu imati i različita imena za isti pojam (npr. brojkup i brkup). Tijekom fizicke transformacije ti pojmovi i imena se transformiraju u jednoznačne, standardne poslovne izraze koji su razumljivi krajnjem korisniku (brkup je broj kupca).

Različiti sustavi mogu imati za iste attribute različite tipove podataka i različite duljine (npr. jedan sustav za šifru artikla ima 12, a drugi 14 numeričkih znakova). Fizickom transformacijom sve različite tipove podataka i duljine treba pretvoriti u jednoznačan, zahtijevani oblik.

Također česti je slučaj da u različitim aplikacijama programeri na različite načine šifriraju isti pojam ili za iste vrijednosti atributa upotrebljavaju različite izraze (tipičan primjer je definiranje spola, jedna aplikacija spol šifrira kao M i F, druga kao X i Y, a treća kao M i Ž) i zato se fizickom transformacijom pretvaranje u zahtijevani oblik. Zadnja, ali ne najmanje važna zadaća fizicke transformacije je kako transformirati podatke koji su nekompletni, pokvareni ili čak nedostaju. Neki se takvi podaci mogu nadomjestiti nekom "default" vrijednošću. Za one koji se ne mogu, to treba riješiti na druge načine (upozoriti korisnika da nema tog podatka i slično).



Slika 2.2. Fizička transformacija podataka

Fizička i logička transformacija su dio procesa poznatijeg kao ETL (engl. extraction, transformation and loading) – izvlacenje, transformacija i učitavanje podataka. Taj proces predstavlja pocetak implementacije skladišta podataka. Znaci prvo se analiziraju zahtjevi i podaci u izvorima, zatim se definira logicki model podataka, te nakon toga se prilazi implementaciji fizicke instance skladišta podataka.

Izvlacenje, transformacija i učitavanje podataka se obavljaju pisanjem skripti u odgovarajucem programskom jeziku (SQL, PL/SQL,...), te izvođenjem tih skripti. Takve skripte se zovu mapiranja (engl. mappings). Danas postoje mnogi alati i programski paketi (kao što je i Oracle Warehouse Builder) koji omogućuju da se takve skripte “pišu” u grafickom okruženju, bez puno pisanja koda kao što cemo vidjeti u prakticnom dijelu. Tijekom ETL-a podaci se izvlace iz izvora, transformiraju se u odgovarajuci oblik, pročišćavaju se, popravljaju se pogreške i zatim se učitavaju i integriraju u skladište podataka.

Inicijalnim učitavanjem podataka proces izgradnje skladišta nije gotov. Nakon što smo učitali pocetne podatke naš posao ipak nije gotov jer treba osigurati učitavanje novih podataka u nekim vremenskim intervalima. Tipican interval je dan tj. svakodnevno učitavanje novih podataka u skladište. Taj proces se zove periodicko punjenje i osvježavanje podataka (engl. periodical loading and refreshing data). Posao projektanta je i da osigura da taj proces prolazi u redu. Proces osvježavanja podataka se u velikim sustavima automatizira. To znaci da ga pokrece i zaustavlja racunalo onako kako smo programirali, a provjeru podataka obavlja administrator skladišta podataka.

Nakon inicijalnog punjenja podataka i osiguravanja periodickog osvježavanja novim podacima, skladište je izgrađeno, ali je skladište potrebno nadgledati i upravljati njime, te ako se javi potreba i restrukturirati. Korisnici će upotrebljavati podatke iz skladišta. Iz toga možemo vidjeti da se proces skladištenja (ne izgradnje skladišta) sastoji od:

1. Izvlacenje, transformacija i učitavanje podataka
2. Spremanje podataka i upravljanje podacima
3. Korištenje podataka kao potpora procesu poslovnog odlucivanja

2.2. Neformalna metodologija izgradnje skladišta podataka

Strucnjaci koji se već neko vrijeme bave skladištima podataka pa tako i njihovom izgradnjom su utvrdili metodologiju koju možemo koristiti prilikom izgradnje skladišta podataka. Ipak, treba naglasiti da ta metodologija nije potpuno formalizirana, već ona više predstavlja niz preporuka, smjernica koje bi trebalo pratiti prilikom izgradnje skladišta. Metodologija se sastoji od devet pitanja o kojima treba odluciti. Ta pitanja se još zovu i točke odluke (engl. decision points). Tih devet tocaka odluke prilikom izgradnje cjelokupnog dimenzijskog skladišta podataka sastoje se od odlucivanja o slijedecem:

1. Koje poslovne procese treba modelirati, odnosno koje su tablice cinjenica
2. Što je srž svake tablice cinjenica
3. Koje su dimenzije svake tablice cinjenica
4. Koje su cinjenice bitne
5. Koji su dimenzijski atributi
6. Kako ćemo pratiti dimenzije koje se sporo mijenjaju
7. Koje agregacije koristiti, koje su heterogene tablice, minidimenzije, načini upita i ostali problemi fizickog spremanja podataka
8. Koliko dugo ćemo čuvati podatke
9. S kojom se učestalošću podaci izvlace i učitavaju u skladište

Ove odluke bi trebalo donijeti u navedenom redoslijedu. Ova metodologija je metodologija od vrha prema dnu (engl. top-down) zato što se počinje identificiranjem

glavnih procesa u kompaniji o kojoj se prikupljaju podaci i onda se kreće prema rješavanju detaljnih problema.

Najvažnija pitanja su na početku i o odgovorima na njih ovisi u najvećem dijelu uspjeh cijelog projekta. Najbitnije je dobro razlučiti poslovne procese koje želimo pratiti i prepoznati prave činjenice, jer o tome ovisi cijeli logički model, a ako je on loš bit će loše i skladište podataka.

Nakon četvrte točke odluke gotovi smo s logičkim dizajnom i tada se počinjemo baviti višom razinom fizičkog dizajna (točke 6 i 7). Nakon toga donosimo odluke koliko dugo ćemo čuvati podatke i s kojom učestalošću ćemo raditi redovito učitavanje novih podataka.

Bitno je naglasiti da ove odluke nisu jednostavne i ne rade se iz ničega. Prije početka same izgradnje potrebno je provesti opsežne razgovore s krajnjim korisnicima i administratorima transakcijske baze kako bi spoznali korisnikove želje i potrebe i kako bi znali donijeti pravu odluku prilikom izgradnje.

Osim o ovim pitanjima treba razmišljati i o potrebnom hardware-u i odgovarajućoj programskoj podršci (kakvo računalo, koje aplikacije za izvješćavanje, itd.).

2.3. Sumarne tablice (agregacije)

Aggregacije su sumarne tablice tj. tablice koje sadrže sumarne podatke. U novije doba se za takve tablice koristi izraz materijalizirani pogled (engl. materialized view). Te tablice sadrže već pripremljene, sumarne podatke koji su rezultat neke obrade (npr. već sumirane podatke, izračunate postotke i sl.). Takve tablice se spremaju u skladište podataka zajedno s ostalim tablicama i koriste se u svrhu poboljšavanja performansi sustava. Pravilnom uporabom tih tablica postižu se znatna unapređenja u performansama.

Razlog zašto se spominju prilikom izgradnje skladišta je jasan. Osim logičkog modela (dimenzijskih tablica i tablica činjenica) projektant mora projektirati i agregacije koje danas predstavljaju značajan dio skladišta. Projektant mora predvidjeti koje će se sumarne tablice najviše koristiti, koji će se upiti najviše postavljati nad bazom i za njih dizajnirati odgovarajuće agregacije.

Sumarne tablice ne moraju stalno postojati u skladištu. Naime one se cesto koriste da bi se riješili određeni problemi, a kad se ti problemi riješe one više ne trebaju. Također se uvijek mogu dodavati nove tablice bez da to smeta radu skladišta. Sumarne tablice se automatski osvježavaju kada se podaci učitaju u skladište i to na način kako ih konfiguriramo. Osvježavanje zna biti dugotrajan proces pa bi trebalo konfigurirati tablice da se osvježe na najbrži mogući način.

Osnovna funkcija takvih sumarnih tablica je da ubrzavaju izvođenje određenih upita. Puno je brže odraditi upit na nekoliko stotina redaka nego na nekoliko stotina tisuća redaka. Za optimalno korištenje tih tablica potreban nam je poseban software - *aggregate navigator* (u Oracle-u se on zove *Summary Advisor*). Njegova uloga je da kad korisnik postavi upit on taj upit transformira kako bi se koristila najpovoljnija agregacija. On postaje važan dio skladišta podataka u današnjim sustavima jer olakšava rad s agregacijama i korisniku i administratoru. Da bi on pravilno radio potrebno je uz njega čuvati i određenu količinu metapodataka. *Summary Advisor* osim što transformira upite, on također analizira koji se upiti najviše i najčešće koriste, te na osnovu te analize predlaže koje bi materijalizirane pogleda trebalo dodati radi ubrzavanja izvođenja tih upita. Također, *Summary Advisor* predlaže i koje bi se materijalizirane pogleda moglo izbrisati jer se više ne koriste. Na taj način *Summary Advisor* predstavlja olakšanje i pomoć pri nadgledanju rada skladišta podataka.

II. DIO: PRIMJER IZGRADNJE SKLADIŠTA PODATAKA UZ PRIMJENU PROGRAMSKOG PAKETA ORACLE WAREHOUSE BUILDER 3i

3. Princip rada Oracle Warehouse Buildera


Da bi izgradili skladište podataka potrebno je, osim dizajna modela podataka, napisati i skripte, procedure, programe u raznim programskim jezicima (SQL, PL/SQL, ...) ovisno o potrebi. Za to nam je potrebno određeno vrijeme kojeg ionako uvijek imamo premalo. Da bi olakšali izgradnju skladišta podataka, mnogi proizvođači su izradili programske pakete u kojima se može jednostavno i lako, koristeći grafičko sučelje, napraviti logički model i definirati skripte. Aplikacija, onda, umjesto nas generira kod po zadanim parametrima. To predstavlja veliku uštedu u vremenu razvoja i implementacije skladišta podataka. Jedan od takvih programskih paketa je i Oracle Warehouse Builder (skraćeno OWB). U ovom poglavlju ću opisati osnovne elemente i filozofiju OWB-a, kao i njegove funkcije i način rada.

3.1. Uvod u Oracle Warehouse Builder

Oracle Warehouse Builder je programski paket koji je napravila Oracle Corporation. Trenutno najnovija inačica je 3i. OWB je programski paket koji služi za definiranje logičkog modela, implementaciju skladišta podataka kao i za nadgledanje i kontrolu rada skladišta podataka. To je integrirani skup programskih rješenja koji nam omogućava lakše dizajniranje i izgradnju skladišta podataka, ali i kasniju kontrolu rada i nadgledanje skladišta podataka.

OWB programski paket sastoji se od OWB repozitorija, OWB klijenta i OWB *Runtime*-a. Osim tih proizvoda za potrebe skladišta podataka potreban nam je i *Oracle Enterprise Manager*, te neki alat za generiranje izvještaja. Da bi instalacija bila uspješna potrebno je instalirati ove proizvode pravilnim redoslijedom. To znači da se prvo treba instalirati baza (ako već ne postoji), zatim se instalira repozitorij u tu odgovarajuću bazu podataka, te se klijent instalira na korisnikovo osobno računalo (može biti i više korisnika koji rade u OWB-u). OWB *Runtime* se instalira zadnji i on služi za poslove nadgledanja.

Korisnik pristupa repozitoriju preko OWB klijenta. OWB klijent predstavlja aplikaciju u kojoj korisnik obavlja sav posao, te sprema taj posao u repozitorij. Prilikom pokretanja OWB klijenta prvi put potrebno je dati informacije o imenu racunala na kojem je repozitorij, broju porta, te Oracle SID. Također je potrebno unijeti svoje korisnicko ime i lozinku. Prilikom pokretanja je također potrebno izabrati projekt na kojem cemo raditi (prilikom prvog pokretanja postoji samo prazan projekt nazvan *My Project* koji se može odabrati), ali se kasnije može prebaciti na drugi projekt. Ako smo dali dobre podatke otvara se glavni prozor OWB klijenta koji izgleda kao na slici 3.1.



Slika 3.1 Glavni prozor Oracle Warehouse Buildera

Sva akcija korisnika se odvija u grafickom sucelju koje je standardno za današnje aplikacije. Korisnikove akcije i promjene koje on unese na ekranu, ne zapisuju se automatski u repozitoriju vec je te promjene i akcije potrebno potvrditi pritiskom na tipku *Commit*. Tek tada napravljene promjene postaju važece i unose se u repozitorij.

3.2. Osnovni elementi Oracle Warehouse Buildera

Osnovni element Oracle Warehouse Buildera je projekt. Projekt se definira kao struktura repozitorija u kojoj se čuvaju formalni opisi koji definiraju skladište podataka i u kojoj OWB sprema generirane skripte korištene pri implementaciji i učitavanju podataka. Projekt je, dakle, osnovna jedinica u Oracle Warehouse Builderu.

Svaki projekt se sastoji od jednog ili više izvorišnih modula (engl. source module) i jednog ili više odredišnih ili skladišnih modula (engl. target module, warehouse module). Odredišni ili skladišni modul je mjesto unutar OWB projekta koje organizira i sprema definicije potrebne za logičku shemu skladišta. On sadrži definicije za dimenzije, tablice činjenica, materijalizirane pogleda, obične pogleda, tablice, te za mapiranja i transformacije. Izvorišni modul je mjesto unutar OWB projekta koje organizira i sprema definicije relacijskih baza ili običnih datoteka (engl. flat files) koje služe kao izvori podataka za skladište podataka. Definicije relacijskih baza se mogu uvesti (engl. import) iz bilo koje baze podataka (ne samo Oracle-ove). OWB koristi takozvane softverske integratore (engl. software integrators) za citanje definicija i izvlačenje podataka iz izvora. Ovisno o izvoru koristit će se odgovarajući integrator.

3.3. Način rada Oracle Warehouse Buildera

Filozofija i način rada Oracle Warehouse Buildera se u početku čini neobičnim, ali s vremenom sam shvatio da je način rada potpuno logičan i u skladu s današnjim trendovima. Osnovni princip rada je da je izgradnja skladišta podataka podijeljena u tri dijela. Prvi dio je potpuna logička definicija koja osim definicije logičkog modela obuhvaća i logičku definiciju mapiranja podataka iz izvora. Drugi dio predstavlja konfiguraciju svih objekata definiranih na logičkoj razini. Završni dio predstavlja generiranje i pokretanje skripti za stvaranje logičkog modela (dimenzija, tablica činjenica,...), te generiranje i pokretanje skripti za izvlačenje, transformaciju i učitavanje podataka iz izvora u skladište podataka.

Logička definicija započinje stvaranjem izvorišnih i odredišnih modula. Nakon definiranja izvorišnog modula, potrebno je uvesti definicije relacijske baze koja nam služi kao izvor podataka. Ako imamo više izvora, potrebno je stvoriti više izvorišnih modula (za svaki izvor podataka, potreban nam je jedan izvorišni modul).

Nakon definiranja odredišnog modula, potrebno je definirati, unutar samog modula, dimenzije, tablice činjenica, materijalizirane poglede,... prema našem logickom modelu podataka. Također unutar odredišnog modula definiramo svoje transformacije i mapiranja. Osim naših transformacija u OWB-u već postoje standardne funkcije i procedure koje možemo koristiti u svojim mapiranjima.

Nakon što smo kreirali definicije objekata potrebnih za logicki model, nakon što smo kreirali vlastite transformacije i mapiranja, i učitali definicije izvora gotovi smo s logickom definicijom. Logicka definicija je zapisana u repozitorij, ali još nije stvoren nijedan objekt, nijedna tablica, niti je stvorena ijedna skripta. Da bi smo stvorili fizicku instancu našeg skladišta prvo je potrebno konfigurirati fizicka svojstva svakog modula, objekta, tablice, svakog mapiranja i operatora unutar mapiranja. Na taj način definiramo kako će se naš logicki model fizicki kreirati, kako će se naše skripte izvoditi itd.

Poslije konfiguracije fizickih parametara potrebno je generirati skripte za kreiranje raznih tablica, te generirati skripte za izvlačenje, transformaciju i učitavanje podataka iz izvora u skladište. Generirane skripte zatim treba fizicki spremati u bazu podataka i nakon toga pokrenuti. Na taj način se stvara fizicka instanca skladišta podataka i učitavaju se podaci u njega. Učitavanjem podataka skladište podataka je izgrađeno.

4. Izrada logickog modela skladišta podataka

Prvi korak u izgradnji skladišta podataka je definicija zahtjeva koje skladište podataka mora ispuniti, te izrada logickog modela koji će omogućiti zahtjevanu funkcionalnost. Model podataka koji se upotrebljava za izradu logickog modela skladišta podataka je dimenzijski model. Zahtjeve koje skladište podataka mora ispuniti definiramo u razgovoru s korisnicima koji će to skladište upotrebljavati, te analizirajući strukturu operacijske baze podataka koja će služiti kao izvor podataka za skladište. Kroz razgovor s korisnicima saznajemo što njima treba i što ih zanima, a analizirajući strukturu operacijske baze saznajemo točno s kojim podacima raspoložemo. Na osnovu tih saznanja trebamo izraditi logicki model skladišta podataka koji će zadovoljavati zahtjevima korisnika, a biti će ga moguće realizirati s postojećim podacima u operacijskoj bazi.

Moj prakticni rad je izgraditi skladište podataka za Zavod za osnove elektrotehnike i elekticka mjerenja koji će pratiti uspjeh studenata na ispitima sa tog zavoda. U daljnjem tekstu ću kroz primjere pokazati kako se jedno skladište podataka razvija i implemetira koristeći OWB.

4.1. Prikupljanje pocetnih informacija i definiranje zahtjeva

Kao što sam već rekao proces izgradnje skladišta zapocinje prikupljanjem informacija od korisnika i definiranjem zahtjeva koje skladište mora zadovoljiti. Da bi se ti zahtjevi pravilno definirali potrebno je i dobro poznavanje poslovnog procesa koji se modelira od strane dizajnera skladišta podataka.

U ovom slučaju poslovni proces je polaganje ispita sa Zavoda za osnove elektrotehnike i elektricka mjerenja i sa Zavoda za telekomunikacije od strane studenata. Studenti upisuju određeni predmet (predmeti koji se prate su: Osnove elektrotehnike 1, Osnove elektrotehnike 2, i Organizacija obrade podataka) koji se predaje u nekom semestru školske godine. Prilikom upisa studenti se razvrstavaju u grupe. Za svaku grupu je određeno koji nastavnik drži predavanja, koji nastavnik drži auditorne vježbe, laboratorijske vježbe, itd. Za pohanjanje nastave, izvršavanje laboratorijskih vježbi, izradu prakticnih zadataka, studenti dobivaju bodove (npr. za pohanjanje nastave od 0 do 4 boda, a za laboratorijske vježbe od 0 do 15 bodova, za

konstrukcijske zadatke od 0 do 15 bodova). Tijekom semestra studenti pristupaju kontrolnim zadacama (iz Osnova elektrotehnike). Studentima koji skupe dovoljan broj bodova (više od 25 za Osnove elektrotehnike 1) iz svih ovih kategorija ponudi se ocjena i oni su oslobođeni pismenog dijela ispita i mogu pristupiti samo usmenom dijelu ispita. Ako nisu zadovoljni ponudenom ocjenom mogu pristupiti pismenom dijelu ispita. Studenti koji nisu zadovoljili moraju izaci na pismeni dio ispita. I na kontrolnim zadacama i na pismenom dijelu ispita, na zadatke se odgovara zaokruživanjem jednog od ponuđenih odgovora. Da bi se prošao pismeni ispit potrebno je skupiti dovoljan broj bodova (za Osnove elektrotehnike više od 14 bodova). Studenti koji prođu pismeni dio izlaze na usmeni dio ispita. Oni koji prođu i usmeni dio ispita prošli su cijeli ispit, a oni koji padnu moraju ponovno i na pismeni ispit. Studenti imaju pravo izaci 8 puta na ispiti iz pojedinog predmeta s tim da ako padnu četvrti put (komisija) moraju ponovno upisati taj predmet, a ako padnu osmi put gube pravo studiranja.

Poznavajući proces možemo pretpostaviti neke zahtjeve, ali ipak najbolji uvid u potrebe dobivamo razgovarajući s budućim korisnicima. Razgovor s korisnicima se obično ponavlja nekoliko puta kako bi se potpuno razumijele potrebe i zahtjevi koje nam oni iskazuju. U ovom konkretnom slučaju “korisnike” je predstavljao mr.sc. Boris Vrdoljak, asistent na Zavodu za osnove elektrotehnike i električka mjerenja. S njim sam razgovarao više puta o potrebama i zahtjevima koje bi buduće skladište podataka trebalo ispuniti. Iz tih razgovora proizašlo je mnogo pitanja na koje bi naše skladište trebalo dati odgovore:

- Koliko je studenata prošlo na kojem roku ovisno o njihovom uspjehu na labosu, u pohađanju nastave...?
- Koliko studenata prođe iz prvog puta, koliko iz drugog, itd.?
- Koliko studenata prođe do određenog vremena (do veljače, do travnja, lipnja,...)?
- Koliko se studenata oslobodi kolokvija?
- Koja je razdioba ocjena na pojedinom roku, ukupno i po grupama?

- Koliko se studenata oslobodi kolokvija, ali ipak izade na pismeni?
- Kako prolaze ponavljači u odnosu na one koji su prvi put upisali taj predmet?
- Koja je razdioba odgovora po zadacima po roku?
- Koji je odgovor na kojem zadatku bio najnetočniji (gdje su studenti najviše griješili)?
- Kako su studenti prolazili na kolokviju (bodovi) u ovisnosti o uspjehu na labosu i nastavi?

Ova pitanja u stvari predstavljaju zahtjeve. Skladište podataka mora moći odgovoriti na sva ova pitanja. Stoga sam morao napraviti logički model skladišta koji je u mogućnosti udovoljiti tim zahtjevima, ali sam isto tako morao analizirati operacijsku bazu kako bih provjerio da li uopće postoji mogućnost odgovoriti na ova pitanja tj. da li postoje svi potrebni podaci u operacijskoj bazi. U ovom slučaju odgovor je bio “da”.


4.2. Logički model skladišta podataka

Kao što je već rečeno za logički model podataka se upotrebljava dimenzijski model. U dimenzijskom modelu središnja tablica je tablica činjenica u koju se spremaju podaci koje pratimo i mjerimo. Pravilan odabir znatosti tablice činjenica je ključan za uspjeh projekta izgradnje skladišta podataka. U poglavlju 2.2. je također opisana metodologija izrade skladišta podataka koju preporučuju stručnjaci. U njoj je također vidljivo da je odabir prave tablice činjenica odnosno znatosti te tablice kritičan (ključan) dio izgradnje. Ako smo sad krivo napravili sve što slijedi će isto biti krivo.

4.2.1. Tablice činjenica


Svaka tablica činjenica treba odgovarati jednom poslovnom procesu kojeg pratimo. Pošto u našem slučaju ima više različitih procesa, imat ćemo i više tablica činjenica. Pismeni ispit se bitno razlikuje od kontrolne zadace, a isto tako se praćenje pismenog ispita i kontrolne zadace bitno razlikuju od praćenja kako su studenti odgovarali na zadatke. Zbog svega navedenog odlučio sam se za četiri tablice činjenica.

Prva tablica cinjenica se zove USPJEH_NA_PISMENOM (slika 4.1). Kao što se vidi po imenu u toj tablici se prati uspjeh studenata na pismenim ispitima. Kratki opis ove tablice cinjenica je: “Broj studenata/ponavljača koji su na određenom roku iz određenog predmeta postigli neki uspjeh (pismeni i usmeni ispit), a imali su ponudenu neku ocjenu, i određeni broj bodova iz pohađanja nastave i laboratorijskih vježbi, te im je to bio n-ti izlazak na ispit.” Ovom tablicom cinjenica se, znaci, prati uspjeh na pismenim ispitima ovisno o svim ostalim mogućim parametrima.




Slika 4.1. Tablica cinjenica USPJEH_NA_PISMENOM

Druga tablica cinjenica se zove KOLOKVIJ (Slika 4.2). Ona prati uspjeh studenata na kontrolnim zadacima, ali bez pokazivanja ovisnosti o postignutim bodovima iz nastave i laboratorijskih vježbi. Razlog tomu je cinjenica da ti bodovi još nisu podijeljeni prilikom pristupanja studenata kontrolnim zadacima. Opis ove tablice cinjenica je: “Broj studenata/ponavljača koji pripadaju nekoj grupi, a na određenom roku su iz određenog predmeta postigli neki uspjeh (broj bodova).” Ova tablica cinjenica se popunjava neposredno nakon obrade rezultata kontrolnih zadata i u nju ulaze samo podaci o studentima koji su pristupili kontrolnoj zadaci.




Slika 4.2. Tablica cinjenica KOLOKVIJ

Treća tablica cinjenica je slična prethodnoj, a zove se **USPJEH_NA_KOLOKVIJU** (Slika 4.3.). Ona prati uspjeh na kontrolnim zadacima svih studenata i to u ovisnosti o postignutim rezultatima iz pohađanja nastave i obavljanja laboratorijskih vježbi. Ova tablica cinjenica se popunjava na kraju semestra kada su poznati postignuti bodovi iz relevantnih kategorija (nastava, laboratorijske vježbe, kontrolne zadace,...). Srž ove tablice cinjenica je: “Broj studenata/ponavljaca koji su na nekoj kontrolnoj zadaci iz nekog predmeta imali određeni broj bodova, a iz nastave i laboratorijskih vježbi imaju n bodova.”



Slika 4.3. Tablica cinjenica **USPJEH_NA_KOLOKVIJU**

Posljednja tablica cinjenica je **RAZDIOBA_ODGOVORI** (Slika 4.4.). Ona prati razdiobu odgovora po zadacima na nekom roku. Srž te tablice cinjenica je: “Broj nekog odgovora po grupi, po zadatku po roku iz nekog predmeta.” Ova tablica cinjenica je zadužena za praćenje kako su studenti odgovarali na zadatke po rokovima.




Slika 4.4. Tablica cinjenica **RAZDIOBA_ODGOVORI**

Zbog razlicitosti procesa koje trebamo pratiti, potreban nam je ovolik broj tablica cinjenica. Svaka tablica cinjenica prati posebne procese i sve zajedno daju cjelovitu sliku cjelokupnog procesa.

4.2.2. Dimenzijske tablice

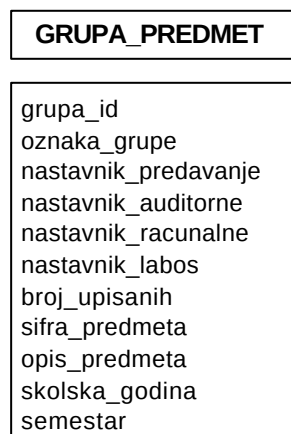
Kao što se vidi imamo deset dimenzijskih tablica: ROK, GRUPA_PREDMET, NASTAVA_LABOS, BODOVI_KOLOKVIJ, PISMENI, USMENI, PONUDJENA_OCJENA, IZLAZAK, ZADATAK i ODGOVOR. Tablice cinjenica imaju neke zajednicke dimenzije, a neke su posebne za svaku tablicu cinjenica. Pošto ima deset dimenzija, necu opisivati detaljno sve vec su opisati samo dvije koje su zajednicke svim tablicama cinjenica.

Zajednicke dimenzije su ROK i GRUPA_PREDMET. Dimenzija ROK opisuje jedan rok iz nekog predmeta. Izgleda kao na slici 4.5. Dimenzija ROK u našem skladištu predstavlja dimenziju vremena iako ona nije u pravom smislu dimenzija vremena. Ona nam omogućuje pracenje uspjeha studenata kroz vrijeme, a vremenski intervali su rokovi.



Slika 4.5. Dimenzija ROK

Dimenzija GRUPA_PREDMET opisuje grupe iz predmeta. Za svaku grupu



su određeni nastavnici koji drže predavanja, auditorne, vode laboratorijske i racunalne vježbe. Svaka grupa ima svoju oznaku i svaka grupa pripada određenom predmetu. Niz grupa se svrstava u predmet. Dimenzija GRUPA_PREDMET prikazana je na slici 4.6.


Slika 4.6. Dimenzija GRUPA_PREDMET

4.3. Izgradnja logickog modela skladišta u Oracle Warehouse Builderu

Definicija logickog modela u Oracle Warehouse Builderu se sprema u odredišni modul (target module, warehouse module), te prije kreiranja te definicije potrebno je napraviti odredišni modul u koji ćemo spremiti naš logički model.


4.3.1. Stvaranje odredišnog modula

Za kreiranje svega, pa tako i odredišnog modula, u OWB-u postoje takozvani *wizardi*. *Wizardi* nas vode korak po korak u procesu stvaranja, od nas zahtijevaju potrebne podatke, te na osnovu tih podataka stvaraju traženi objekt. Da bi kreirali odredišni modul potrebno je pokrenuti *New Module Wizard*. On se pokrece tako da se odabere projekt u koji želimo spremiti taj modul, te pritiskom desne tipke miša dobijemo padajući izbornik, na kojem odaberemo opciju *Create Module* (Slika 4.7.).




Slika 4.7 Pokretanje New Module Wizarda

Pokretanjem *New Module Wizarda* otvori se početni prozor koji sadrži kratki uvod i opis koraka kroz koje treba proći, te koja nas upozori koje ćemo sve podatke trebati dati. (Slika 4.8.).




Slika 4.8. Uvodni prozor New Module Wizarda

U slijedećem koraku moramo imenovati modul, odrediti da li je on odredišni ili izvorišni modul, odrediti mu namjenu (za razvoj, za provjeru kvalitete ili za produkciju), te po želji možemo ukratko opisati modul. (Slika 4.9.). U našem slučaju odredili smo da je odredišni modul i da mu je namjena razvoj.



Slika 4.9. New Module Wizard: Korak 1


Slijedeci korak je odrediti koja ce aplikacija koristi ovaj modul, te koji ce se softverski integrator koristiti za pristupanje podacima. Ovi podaci se unose tako da se izabere jedna od ponudenih opcija sa liste. (Slika 4.10.).



Slika 4.10. New Module Wizard: Korak 2

Treci korak u stvaranju odredišnog modula je davanje informacija o linku prema bazi podataka. Ovaj korak nam treba samo ako cemo importirati definicije iz neke druge baze podataka što u nama u ovom slucaju ne treba jer cemo sami definirati svoj logicki model. Stoga preskacemo ovaj korak.

Završni prozor (slika 4.11.) nam prikazuje sažetak svih informacija koje smo unijeli tako da možemo još jednom provjeriti tocnost i da li je to ono što smo željeli. Zatvaranjem *New Module Wizarda*, OWB kreira odredišni modul u našem projektu te se ime modula pojavljuje u grani *MODULES*.



Slika 4.11. Završni dijalog *New Module Wizarda*.

Važno je napomenuti da iako smo kreirali odredišni modul podaci o tome još nisu unijeti u repozitorij. Da bi potvrdili napravljeni posao potrebno je pritisnuti tipku *Commit* koja se nalazi u gornjem desnom kutu glavnog ekrana OWB-a. Pritiskom na tipku *Commit* spremamo napravljeni posao u repozitorij.

4.3.2. Stvaranje definicija za dimenzije


Kreiranjem odredišnog modula imamo mjesto gdje ćemo spremati definicije našeg logičkog modela. Slijedeći korak je kreiranje definicija za dimenzije. OWB zahtjeva da se prvo definiraju dimenzije, potom tablice činjenica. Razlog je jasan. Tablice činjenica referenciraju primarne ključeve dimenzija pa je prvo potrebno kreirati primarni ključ, a tek onda referencu tog ključa.

Kreiranjem definicije za dimenziju ustvari kreiramo dvije definicije: jednu za dimenzijski objekt, a drugu za dimenzijsku tablicu. Dimenzijski objekt se sastoji od niza razina agregacije (engl. level of aggregation, level) i hijerarhija nad tim razinama agregacije. Razina agregacije predstavlja razinu grupiranja (npr. dan, tjedan, mjesec, godina su razine agregacije). Hijerarhije se definiraju nad razinama i definiraju roditelj-dijete odnose između njih. Hijerarhije opisuju kako se razine agregacije grupiraju jedna u drugu (Primjer hijerarhije je: dan se grupira u tjedan, tjedan se grupira u mjesec, mjesec se grupira u godinu). Unutar jednog dimenzijskog objekta može biti definirano i više od jedne hijerarhije.


Prilikom kreiranja hijerarhije, OWB kreira identifikacijski ključ za svaki nivo u toj hijerarhiji i jedinstveni ključ (engl. unique key) za najniži nivo agregacije. OWB koristi identifikacijske ključeve tijekom faze generiranja kako bi stvorio DDL skripte za kreiranje dimenzijskog objekta. Zbog postojanja tih identifikacijskih ključeva potrebno je jako paziti prilikom kreiranja definicija za tablicu činjenica. Naime kada se određuje koji atributi iz dimenzije će biti strani ključevi u tablici činjenica, OWB ponudi osim jedinstvenog ključa i identifikacijske ključeve kao kandidate za strane ključeve. Međutim samo jedinstveni ključ može biti strani ključ u tablici činjenica.

Da bi kreirali definiciju za dimenziju potrebno je pokrenuti *New Dimension Wizard*. Postoji još i *New Time Dimension Wizard* koji služi za kreiranje definicija za dimenzije vremena. I jedan i drugi *wizard* se pokreću iz *Warehouse Module Editora* (slika 4.12.). Do njega se dolazi dvostrukim pritiskanjem lijeve tipke miša na ime odredišnog modula. Kao što se vidi na slici on ispod imena modula sadrži brojne grane. Svaka od tih grana sadrži definicije posebnih objekata (dimenzija, tablica činjenica, mapiranja, materijaliziranih pogleda, itd.). Da bi pokrenuli *New Dimension Wizard* potrebno je označiti granu DIMENSIONS i pritiskom desne tipke miša otvoriti padajući izbornik. Iz tog izbornika potrebno je odabrati *Create Dimension* i tako pokrenuti *New Dimension Wizard*.

Pokretanjem *New Dimension Wizarda* otvara se uvodni prozor koji nam ukratko opisuje korake u procesu kreiranja definicije za dimenziju, te nas upozorava na podatke koje ćemo trebati unijeti. Prvi korak je unošenje podataka o imenu dimenzije, prefiksu koji će se upotrebljavati prilikom imenovanja ključeva, te opisa dimenzije koji nije obavezan. (slika 4.13.).




Slika 4.12. Warehouse Module Editor




Slika 4.13. New Dimension Wizard: Korak 1

Slijedeći korak je definicija razina agregacije. Za svaku razinu agregacije potrebno je definirati njeno ime, prefiks i eventualno opis. Svaka dimenzija mora imati barem jednu razinu agregacije.




Slika 4.14. New Dimension Wizard: Korak 2

Treći korak traži da se za svaku razinu agregacije definiraju atributi te razine. Potrebno je definirati ime atributa, tip podataka, te opis.




Slika 4.15. New Dimension Wizard: Korak 3

Slijedeci korak je definiranje hijerarhija. Također je potrebno unijeti ime, prefiks i opis za svaku hijerarhiju.



Slika 4.16. New Dimension Wizard: Korak 4

Peti korak je definiranje odnosa razina za svaku hijerarhiju. Razine unutar te hijerarhije se slažu na listu i to tako da je na vrhu liste najviša razina agregacije, a na dnu najniža.




Slika 4.17. New Dimension Wizard: Korak 5

Završni dijalog prikazuje sažetak unesenih informacija, tako da možemo još jednom provjeriti točnost danih informacija. Zatvaranjem *New Dimension Wizarda* OWB kreira definiciju za dimenzijski objekt i dimenzijsku tablicu, umeće te definicije u odredišni modul i ime dimenzije se pojavljuje u navigacijskom stablu *Warehouse Module Editora*. Na taj način smo kreirali definiciju za jednu dimenziju. Postupak ponavljamo za svaku potrebnu dimenziju.


4.3.3. Stvaranje definicija za tablice cinjenica

Kad smo stvorili sve dimenzije, možemo pristupiti kreiranju definicija za tablice cinjenica. Postupak je jako sličan kreiranju dimenzija, samo su podaci koje trebamo pružiti različiti. Dakle, definiciju za tablicu cinjenica kreiramo pomoću *New Fact Wizarda* kojeg pokrenemo iz *Warehouse Module Editora*. Pokretanjem *New Fact Wizarda* otvara se početna stranica na kojoj se nalazi kratki opis koraka koji nas čekaju kao i upozorenje koje podatke trebamo dati. Prvi korak u kreiranju tablice cinjenica je imenovanje tablice cinjenica i davanje kratkog opisa (slika 4.18).




Slika 4.18. New Fact Wizard: Korak 1

Slijedeci korak je definiranje stranih kljuceva koji ce sacinjavati primarni kljuc tablice cinjenica. U ovom koraku treba jako paziti da se za strane kljuceve odaberu samo jedinstveni kljucevi iz dimenzija jer jedino oni odgovaraju svrsi.




Slika 4.19. New Fact Wizard: Korak 2

Treci korak je definiranje cinjenica koje cemo pratiti (engl. facts, measures). U ovom koraku definiramo attribute koji predstavljaju cinjenice, te njihove tipove podataka.




Slika 4.20. New Fact Wizard: Korak 3

Završni korak je definirati setove atributa koji će se upotrebljavati u tablici. Postoje tri vrste setova: predefinirani, korisnicki definirani i tip most. Ja se nisam previše bavio setovima atributa, već sam u svakoj tablici ostavio samo one predefinirane.



Slika 4.21. New Fact Wizard: Korak 4

Završni prozor je kao u svakom *wizardu* sažetak danih informacija kako bi mogli još jednom provjeriti točnost informacija.




Slika 4.22. *New Fact Wizard*: Završni dijalog

Zatvaranjem *New Fact Wizarda*, OWB kreira tablicu cinjenica na osnovu danih informacija. Kreiranjem odgovarajucih tablica cinjenica naš logicki model je gotov. On je unesen u repozitorij (nakon pritiska tipke *Commit*). Kreirali smo definicije za dimenzije i tablice cinjenica i te definicije postoje u repozitoriju, medutim još nijedna tablica nije fizicki implementirana. Taj proces se obavlja u fazi generiranja skripti i pokretanja tih skripti.

4.3.4. Stvaranje izvorišnog modula i učitavanje definicija izvora podataka

Dosad smo kreirali logicki model, ali još uvijek nismo definirali izvore podataka. Da bi spremili definicije za izvore podataka potreban nam je izvorišni modul (slicno kao što nam je potreban odredišni modul za spremanje definicija logickog modela). Proces kreiranja izvorišnog modula je jako slican procesu kreiranja odredišnog modula. Koristi se isti *wizard*. Razlika je samo u informacijama i opcijama koje dajemo *wizardu*. Jedina veka razlika je ta da za izvorišni modul moramo definirati valjani link prema bazi podataka koja ce nam služiti kao izvor podataka (Slika 4.23). Taj link nam omogućuje da iz te baze očitamo definicije tablica, kljuceva, i ostalih relevantnih objekata koji nam trebaju u procesu mapiranja. Kada kreiramo izvorišni modul njegovo ime se pojavljuje u našem projektu pod granom MODULES (isto kao i odredišni modul). Također ako imamo više razlicitih izvora podataka, potrebno je za svaki izvor stvoriti jedan izvorišni modul.



Slika 4.23. New Module Wizard: Kreiranje linka prema bazi podataka

Nakon kreiranja izvorišnog modula potrebno je u njega učitati definicije iz izvorišne baze podataka. Učitavanje se obavlja izborom opcije *Import* iz padajućeg izbornika. Na taj način nam unutar OWB postaje vidljiva struktura izvorišne baze podataka te nam to omogućava izradu mapiranja.

5. Mapiranja

Nakon što smo definirali logicki model skladišta podataka, te ucitali definicije izvorne baze podataka, potrebno je definirati nacin na koji ce se podaci iz izvora prenijeti i ucitati u skladište podataka. Za tu svrhu nam služe mapiranja.

5.1. Opcenito o mapiranjima

Kreiranjem mapiranja definiramo proces izvlacenja, transformacije i učitavanja podataka iz izvora u skladište podataka. Mapiranja se definiraju u skladišnom modulu. Definicija mapiranja formalno opisuje niz operacija koje izvlace podatke iz izvora podataka, transformiraju te podatke ako je to potrebno i zatim ucitavaju te podatke u odredišne tablice.

Mapiranje se u OWB-u sastoji od niza operatora. Operatori definiraju kako se ulaznim nizovima zapisa (engl. row-sets) manipulira radi dobivanja traženog izlaznog niza zapisa, a pri tom kardinalnost ulaznog niza zapisa ne mora biti jednaka kardinalnosti izlaznog niza zapisa. U OWB-u postoji nekoliko tipova operatora koji se po svojoj namjeni mogu rasporediti u: operatore za izvlacenje, operatore za učitavanje, standardne operatore, transformacije i operatore vanjskih procesa. Operatori za izvlacenje i učitavanje su jako slicni, a oni predstavljaju ili izvor podataka u mapiranju ili odredište podataka. Ostali operatori se mogu svrstati u grupu takozvanih *data flow* operatora koji imaju zadacu da manipuliraju podacima koji prolaze kroz njih prema zadanim parametrima. U mapiranju se koriste razliciti tipovi operatora, ali uvijek mora biti barem jedan operator izvlacenja koji ce predstavljati izvor podataka i barem jedan operator učitavanja koji ce predstavljati odredište. Zatim se definira redoslijed tih operatora kao i njihov medusoban odnos te se na taj nacin definira ETL proces za odredenu tablicu, dimenziju ili tablicu cinjenica.


Svaki operator, ovisno o tipu, može imati jednu ili više ulaznih grupa atributa (engl. attribute groups), jednu ili više izlaznih grupa atributa, ili jednu ulazno/izlaznu grupu atributa. Tako npr. operator *Joiner*, koji je obavlja operaciju spajanja jednog ili više ulaza u jedan izlaz, može imati dvije ili više ulaznih grupa atributa i samo jednu izlaznu grupu atributa, dok npr. operator *Splitter*, koji obavlja operaciju razdvajanja jednog ulaza na više izlaza, može imati samo jednu ulaznu grupu atributa i 2 ili više izlaznih grupa atributa.

Operatori imaju tri razine: razinu operatora koja je najviša, razinu grupe atributa i razinu samog atributa koja je najniža razina. Svaka od tih razina, ovisno o tipu operatora, ima neka svojstva koja je potrebno konfigurirati da bi taj operator radio kako mi to želimo. Npr. operator *Joiner* ima na razini operatora svojstvo koje se zove uvjet spajanja (engl. join condition) u koje je potrebno navesti koji će biti uvjet spajanja (to je u biti WHERE clause u SQL upitu) za taj operator. Konfiguracijom tih svojstava postićemo da operatori obavljaju posao koji nam treba.

Za operatore postoji još jedna bitna stvar, a zove se uskladiavanje (engl. reconciliation). Znaci kad definiramo operator izvlačenja ili učitavanja on se veže za određenu tablicu, datoteku (engl. flat file), dimenziju ili tablicu cinjenica. Međutim nakon definiranja mapiranja u kojoj smo koristili taj operator koji je povezan za neku npr. tablicu, ta se tablica može promijeniti (dodaju se novi atributi, mijenja se struktura tablice). Također prilikom definiranja mapiranja možemo ustanoviti da nam neka tablica ne odgovara u potpunosti već je potrebna promjena u strukturi te tablice. Da bi operator i nakon promjene strukture tablice za koju je vezan pratio u potpunosti tu tablicu potrebno ga je uskladiti s tom tablicom. Postoje dvije vrste uskladiavanja: unutarnje i vanjsko uskladiavanje. Unutarnje uskladiavanje (engl. inbound reconciliation) se provodi ako se promijenila struktura tablice pa uskladjemo operator s tablicom, dok se vanjsko uskladiavanje (engl. outbound reconciliation) provodi ako smo promijenili strukturu operatora, a želimo da se ta promjena očituje i na tablici za koju je taj operator vezan.

U mapiranjima posebnu ulogu imaju i transformacije. Transformacije pretvaraju izvorne podatke u podatke koje su nam potrebne u skladištu podataka i one se pišu u PL/SQL-u. Postoje dvije vrste transformacija: funkcije i procedure. Funkcije su one transformacije koje imaju niz ulaznih parametara, a kao rezultat vraćaju samo jedan, dok procedure mogu imati više ulaznih, ali i više izlaznih parametara. U OWB-u nam je na raspolaganju velik broj transformacija iz Oracle-ove knjižnice transformacija (engl. Oracle Transformation Library), ali isto tako možemo pisati svoje transformacije. Transformacije se u mapiranjima koriste preko operatora transformacija. Ti operatori se uskladjuju s transformacijama na isti način koji je opisan za operatore izvlačenja i učitavanja.

Mapiranje se kreira odabirom opcije *Create Mapping* iz izbornika koji se pokrene pritiskom desne tipke miša nad granom MAPPINGS u *Warehouse Module Editoru* (Slika 5.1.).



Slika 5.1 Stvaranje novog mapiranja

Nakon unošenja imena mapiranja i opisa mapiranja otvara se *Mapping Editor* u kojem definiramo naše mapiranja. *Mapping Editor* se sastoji od prazne pozadine (engl. canvas) na koju se nanose operatori, izbornika, toolbara i najvažnije palete objekata (Slika 5.2) sa koje se odabiru operatori koje ćemo koristiti. Operatori koji se mogu koristiti su:

- Operatori izvlačenja i učitavanja: Mapping Table, Mapping View, Mapping Materialized View, Mapping Sequence, Mapping Dimension, Mapping Flat File, Mapping Fact
- Standardni operatori su: Agregator, Pre i Post-Mapping Process, Filter, Splitter, Joiner, Sorter, Deduplicator
- Operatori transformacija: Mapping Transformation, Expressions, Constants
- Operatori vanjskih procesa: Pure Integrate, Pure Extract




Slika 5.2 Paleta objekata

5.2. Primjer izgradnje mapiranja dimenzije

U ovom poglavlju ću prikazati kako se gradi mapiranje i to na primjeru mapiranja dimenzije ROK. Znaci, nakon što smo kreirali novo mapiranje otvori nam se prazan *Mapping Editor*. Naš zadatak je sada kombinacijom operatora i povezivanjem tih operatora stvoriti mapiranje koje će obaviti izvlačenje i učitavanje podataka. Prvi korak u izgradnji mapiranja je definiranje izvora. U ovom mapiranju kao izvore podataka koristim dvije tablice: ROK_STG i PREDAVANI_PREDMETI. ROK_STG je tablica koja je nastala mapiranjem MAP_ROK_STG, a služi kao pripremna tablica za učitavanje podataka u dimenziju ROK.

Dakle, prvo trebamo definirati izvore podataka. Za definiciju izvora koristit ćemo operator za izvlačenje *Mapping Table*. Odaberemo na paleti objekata operator *Mapping Table* te ga držeći lijevu tipku miša prebacimo na prazni dio ekrana, na mjesto gdje želimo da taj operator bude. Tada se otvara dijalog za dodavanje tablice koji nas pita koju tablicu i na koji način želimo tu tablicu dodati (slika 5.3.). Kao što se vidi postoji nekoliko opcija za dodavanje tablice: *Create unbound table with no attributes* – ovaj opcija stvara tablicu bez atributa i operator nije povezan s nijednom stvarnom tablicom, *Create new repository table and bind* – ova opcija poziva *New Table Wizard* koji omogućava stvaranje nove tablice i povezuje operator s tom tablicom, *Import table into repository and bind* – opcija omogućava učitavanje neke tablice u repozitorij i povezivanje operatora s njom, *Select from existing repository table and bind* – ako smo već kreirali tablicu onda ova opcija omogućuje odabir jedne od takvih tablica i povezivanje operatora s njom. Ovakav dijalog se pojavljuje za sve operatore izvlačenja i učitavanja kao i za operatore transformacija (pojavljuje se za sve operatore koji se trebaju povezati s stvarnim fizickim objektom).




Slika 5.3 Dijalog za dodavanje tablice u mapiranje


Nakon što smo dodali operator *Mapping Table*, on se pojavi na ekranu sa svojim grupama atributa i atributima kao na slici 5.4. Isti postupak ponavljamo za dodavanje tablice *PREDAVANI_PREDMETI*, te za dodavanje operatora *Joiner* (samo se za njega ne pojavi dijalog vec se on odmah prikaže na ekranu).

Kao što vidimo na slici operator *Joiner* ima dvije ulazne grupe atributa i jednu izlaznu. U prvu ulaznu grupu atributa se stavljaju željeni atributi iz jedne tablice, a u drugu atributi iz druge tablice. *Joiner* ce nam služiti za spajanje ove dvije tablice preko atributa *S_PREDAVANI_PREDMET*. Kada odredimo koji nam atributi ulaze u operator *Joiner* potrebno je definirati uvjet spajanja. Da bi ga odredili potrebno je pritisnuti desnu tipku miša nad operatorom *Joiner*. Tada se pojavi izbornik s kojeg odaberemo opciju *Operator properties* i kao rezultat dobijemo dijalog s svojstvima operatora (slika 5.5). U ovom slučaju postoji samo jedno svojstvo i to je uvjet spajanja. Pritiskanjem lijeve tipke miša nad praznim dijelom uvjeta spajanja otvara se takozvani *Expression Builder* (slika 5.6.). *Expression Builder* je dijalog u kojem možemo, bez unošenja koda, graditi razne izraze, pa tako i uvjet spajanja. Taj alat nam pomaže da bez ukucavanja koda gradimo kompleksne izraze najčešće kao dio svojstva nekog operatora kao što je i ovdje slučaj. U ovom slučaju definiramo da se ove dvije tablice spajaju po vrijednosti atributa *S_PREDAVANI_PREDMET*. *Expression Builder* ima tipku *Validate* koja omogućava provjeru sintakse izraza kojeg


smo napravili i jako je korisna. Svaki izraz kojeg napravimo trebali bi validirati kako bi rano otkrili eventualne pogreške.



Slika 5.4 Dodani operatori na ekranu *Mapping Editor*a



Slika 5.5 Svojstva operatora *Joiner*a




Slika 5.6 Expression Builder


Nakon spajanja dviju tablica imamo skoro sve attribute koji su nam potrebni za učitavanje u dimenziju ROK. Nedostaju nam podaci o školskoj godini i semestru, te je još potrebno transformirati atribut TIP_ISPITA u odgovarajući oblik. (TIP_ISPITA ima kao moguće vrijednosti KOLOKVIJ i PISMENI, a za potrebe skladišta nam trebaju vrijednosti 1.KZ, 2.KZ, 3.KZ i PISMENI). Tu na scenu stupaju transformacije. Potrebne su nam tri. Da bi koristili transformaciju potrebno je za svaku dodati operator transformacije na ekran i povezati taj operator s odgovarajućom transformacijom. Postupak je identičan dodavanju operatora *Mapping Table*.

Dodavanjem transformacija imamo sve potrebne podatke za učitavanje u dimenziju ROK pa možemo dodati i operator učitavanja *Mapping Dimension* koji ćemo povezati s dimenzijom ROK (slika 5.7.).

Povezivanjem odgovarajućih atributa s atributima dimenzije ROK, privodimo kraju mapiranje. Završna akcija je dodavanje operatora *Sequence* koji je povezan s odgovarajućom sekvencom koja služi za generiranje primarnog ključa. Mapiranje dimenzije ROK je gotovo i izgleda kao na slici 5.8. Da bi provjerili naše mapiranje koristimo opciju *Validate* iz izbornika *Mapping*. Opcija *Validate* provjerava naše mapiranje i traži greške u sintaksi (npr. povezivanje atributa koji imaju različite tipove, i sl.), te nas na te greške i upozorava. Važno je napomenuti da validiranje provjerava samo sintaksu, a ne i da li će naše mapiranje pravilno obavljati posao. Taj dio moramo sami provjeriti.



Slika 5.7 Dodani operatori transformacija i operator dimenzije ROK




Slika 5.8 Mapiranje dimenzije ROK

5.3. Mapiranje tablice cinjenica

Postupak mapiranja tablice cinjenica je isti kao kod mapiranja dimenzija. Jedina razlika je cinjenica da je mapiranje tablice cinjenica uvijek kompleksnije, koristi se više operatora i često se koristi operator *Aggregator* koji može obavljati različite funkcije agregacija (COUNT, SUM, AVG, MAX, MIN, itd.). Ukratko ću objasniti mapiranje tablice cinjenica RAZDIOBA_ODGOVORI (slika 5.9).

Kao izvori podatka koriste se tablice: ISPITI, PREDAVANI_PREDMETI, PRIJAVLJENI_ZA_ISPIT, UPISANI, S_ODGOVORI i ZADATAK_ODGOVOR. Kao što znamo tablica cinjenica prati razdiobu odgovora po rokovima, a da bi to mogli dobiti potrebne su nam navedene tablice. Prvo spajamo tablice ISPITI i PREDAVANI_PREDMETI. Iz tih tablica dobivamo podatke o datumu ispita, tipu ispita, nastavnicima koji su ga sastavili odnosno recenzirali te o šifri predmeta iz kojeg je taj ispit. Nakon spajanja tablica provodimo filtriranje podataka. Podatke filtriramo po datumu i šifri predmeta kako bi u tablicu cinjenica upisivali podatke rok po rok. Zamišljeno je da prilikom pokretanja ove skripte korisnik koji je pokrece unosi kao parametar podatke o datumu ispita i šifri predmeta iz kojeg je taj ispit, kako bi se nakon završenog i obrađenog roka unijeli podaci. Dalje spajamo sve ostale tablice kako bi dobili sve atribute koji nam trebaju. Nakon spajanja brojimo odgovore, ali tako da se brojenje grupira po roku, po grupama iz predmeta, po zadatku ~~e~~ po odgovoru. U tu svrhu koristimo operator *Aggregator* koji koristi funkciju COUNT, uz GROUP BY D_ISPITA, S_GRUPE, S_ZADATKA, ODGOVOR. Zadnje spajanje provodimo kako bi iz dimenzijskih tablica dobili za odgovarajuće vrijednosti atributa vrijednost primarnih ključeva koji će biti strani ključevi u tablici cinjenica. Spajanjem odgovarajućih atributa s atributima u operatoru *Mapping Fact* naše mapiranje je gotovo, ali ga još treba validirati i potražiti skrivene pogreške u sintaksi. Nakon validacije mapiranje je spremno za konfiguraciju i generiranje skripti.



Slika 5.9 Mapiranje tablice cinjenica RAZDIOBA_ODGOVORI

6. Konfiguracija fizickih svojstava objekata u Oracle Warehouse Builderu

Kad smo napravili sva potrebna mapiranja dimenzija i tablica cinjenica, vrijeme je da prijedemo na drugu fazu izgradnje skladišta podataka, a to je konfiguracija fizickih parametara koji su potrebni da bi se objekti fizicki implementirali. Fizicka svojstva je potrebno konfigurirati kako bi OWB na pravilan način generirao potrebne skripte za definiranje objekata (DDL skripte) i izvlačenje i učitavanje podataka (skripte pisane u raznim jezicima: SQL, PL/SQL, ABAP). Potrebno je konfigurirati fizicka svojstva svakog objekta (skladišnog modula, dimenzija, tablica cinjenica, tablica, sekvenci, mapiranja, itd.). Svaki taj objekt ima neka svojstva koja su specifična za njega, a svi objekti imaju i neka zajednička svojstva koja treba konfigurirati.

6.1. Konfiguracija fizickih svojstava skladišnog modula


Da bi konfigurirali skladišni modul potrebno je u *Warehouse Module Editoru* oznaciti ime skladišnog modula kojeg želimo konfigurirati, te na izborniku odabrati opciju *Configure*. To otvara poseban prozor u kojem pristupamo konfiguraciji parametara. (Slika 6.1.)

Kao što se vidi na slici ima dosta parametara koje treba podesiti. Parametri su podijeljeni u kategorije. Prva kategorija parametara obuhvata konfiguraciju veze prema bazi podataka (*Database Links*). U toj skupini potrebno je definirati korisničko ime i lozinku, te računalo na kojem se nalazi baza podataka, te port i SID. Veza prema bazi podataka je važna jer se prilikom svakog izvlačenja podataka upotrebljava.

Runtime Audit kategorija parametara se odnosi na razinu nadgledanja procesa u skladišnom modulu. Postoji nekoliko razina nadgledanja: Bez nadgledanja, nadgledanje na razini statistike, nadgledanje na razini pogrešaka i kompletno nadgledanje. U našem slučaju postavljeno je kompletno nadgledanje.

Generation Preferences je kategorija u kojoj se podešavaju svojstva potrebna za generiranje skripte. Jedini parametar koji se podešava je *End of Line* parametar koji za Windows NT mašinu bi trebao imati vrijednost `\r\n`, a za UNIX `\n`.

OEM Registration kategorija podešava kakav sufiks će dobiti poslovi koji su registrirani u OEM-u (*Oracle Enterprise Manageru*). Postavljena vrijednost je `_job`.



Slika 6.1 Konfiguracija skladišnog modula

Run Time Directories i *Generation Target Directories* kategorije su za podešavanje imena direktorija u koje će se spremati generirane skripte i koji će se koristiti tijekom izvođenja. Također se u tim kategorijama podešavaju ekstenzije za skripte (npr. za PL/SQL skriptu ekstenzija je .pls).

U *Identification* kategoriji se nalaze parametri o samom modulu, kako se zove, tko je vlasnik, na kojem racunalu, itd.


Sve ove parametre je potrebno podesiti prije generiranja skripti. Za naše skladište skladišni modul je konfiguriran kao na slici 6.1.

6.2. Konfiguracija fizickih svojstava dimenzija, tablica, i tablica cinjenica

Da bi konfigurirali dimenziju potrebno je oznaciti ime dimenzije koju želimo konfigurirati i u izborniku odabrati opciju *Configure*. Tada se također otvara novi prozor u kojem se nalaze konfiguracijski parametri. (slika 6.2.)

Kao što vidimo sa slike, konfiguracija dimenzije se znatno razlikuje od konfiguracije skladišnog modula što je i razumljivo. I ovdje imamo parametre

podijeljene po različitim kategorijama. Kategorije *Partitions*, *Partitions Keys*, *Partition Parameters* su vezane uz particije, a zbog relativno male količine podataka, objekti iz našeg skladišta nisu podijeljeni u particije, pa te parametre nisam podešavao.




Slika 6.2 Konfiguracija dimenzije

Od ostalih kategorija najvažnije su kategorije *Performance Parameters*, *Parallel* i *Storage Space*. Podešavanjem parametara iz kategorije *Performance Parameters* i *Parallel* direktno utjecemo na brzinu izvođenja upita i učitavanja podataka, dok podešavanjem parametra *Tablespace* iz kategorije *Storage Space* kazujemo gdje ćemo fizički smjestiti danu dimenziju.

Na slici 6.2. je prikazano kako je konfigurirana dimenzija ROK, a ostale dimenzije imaju sve bitne parametre konfigurirane isto kao i ova dimenzija.


Postupak kod konfiguracija tablica je isti kao i kod konfiguracija dimenzija – odabirom opcije *Configure* s izbornika, dobivamo prozor s konfiguracijskim parametrima (slika 6.3). Konfiguracijski parametri su slični onima kod dimenzije i

cak su isto i konfigurirani kao što se vidi na slici. Također su i ostale tablice slično konfigurirane kao i ova.



Slika 6.3 Konfiguracija tablice GRUPE_STG

Konfiguracija tablica cinjenica je također jako slična konfiguraciji dimenzija i tablica. Konfiguracijski parametri su prikazani na slici 6.4. Kao što se vidi na slici u konfiguraciji parametara nema bitne razlike jer su i dimenzije i tablice i tablice cinjenica po svojoj namjeni slične, i sve se spremaju na isto računalo istu bazu. Jedine razlike su u konfiguraciji kategorije *Index* u kojoj se konfiguriraju indeksi za zadani objekt, a opet ovisno o tipu i namjeni objekta.



Slika 6.4 Konfiguracija tablice cinjenica RAZDIOBA_ODGOVORI

Više o svim ovim parametrima se može naći u Oracle-ovim priručnicima, posebno u *OWB User's Guide* i *Designing and Tuning Performance*.

6.3. Konfiguracija mapiranja

Konfiguracija mapiranja se jako razlikuje od konfiguracije ostalih objekata u OWB-u i ima mnogo više parametara koje treba konfigurirati. Konfiguracija mapiranja je također jako važna jer ona definira kako će se podaci izvlačiti (koje će se operacije izvoditi). Prije konfiguracije samog mapiranja potrebno je konfigurirati attribute koje ulaze u određeni operator te određeni operator kako bi definirali način na koji će se ti atributi učitavati u određeno mjesto.

6.3.1. Konfiguracija atributa u mapiranjima

Znači, prije same konfiguracije mapiranja potrebno je definirati kako će se ponašati atributi dok se učitavaju u određeno mjesto. Slijedeci operatori sadržavaju attribute koje bi trebalo konfigurirati prije učitavanja: Tablice, Tablice cinjenica, Dimenzije, Pogledi, Materijalizirani Pogledi.

Svaki atribut ima svoja svojstva. Pritiskanjem desne tipke miša nad određenim atributom pojavljuje se izbornik na kojem je i opcija *Attribute properties*. Odabirom te opcije otvara se prozor sa svojstvima atributa kao na slici 6.5. Za učitavanje podataka bitni su parametri u kategoriji *Attribute Properties*. Podešavanjem tih parametara definira se ponašanje atributa u procesu učitavanja.

Parametar *Insert: Use for Loading* definira da li će se atribut koristiti za učitavanje u odredište koristeći operaciju *Insert*. Ako je postavljen na *Yes* onda će biti učitani u odredište u operaciji *Insert*, a ako je postavljen na *No* onda neće biti učitani u odredište iako je u mapiranju definirano da bi se trebao učitati u odredište.


Parametar *Update: Use for Loading* je sličan prethodnom parametru, ali on definira da li će se atribut koristiti u operaciji *Update*.

Parametri *Update: Use for matching* i *Delete: Use for matching* definiraju da li će se za taj atribut provjeravati da li njegova vrijednost već postoji u odredištu, te ako postoji nad tim zapisom će se onda provesti operacija *Update* odnosno *Delete*. Znači, prilikom učitavanja u odredište provjerava se da li vrijednost atributa, za koji su ta dva parametra postavljena na *Yes*, već postoji u odredištu. Ako postoji onda će se samo nad tim zapisom u odredištu provesti definirana operacija.

Parametar *Update: Operation* definira kako će se računati nova vrijednost atributa, ako se tijekom provjere pronade ista vrijednost atributa i provede se operacija *Update*. Moguće operacije su:

- = odredište := izvor
- += odredište := izvor + odredište
- = odredište := odredište – izvor
- =- odredište := izvor – odredište
- ||= odredište := odredište||izvor

Nakon postavljanja ovih parametara može se prići na konfiguraciju operatora i onda na konfiguraciju samog mapiranja.



Slika 6.5 Svojstva atributa

6.3.2. Konfiguracija svojstava operatora u mapiranjima

Za svaki odredišni operator u mapiranju potrebno je podesiti njegova svojstva koja se odnose na metode učitavanja podataka. Da bi se podesila svojstva treba otvoriti prozor sa svojstvima operatora (slika 6.6), odabirom *opcije Operator properties*. Za proces učitavanja su bitni parametri u kategoriji *Data Entity parameters*, a posebno parametar *Loading Types* koji definira kako će se provoditi operacija učitavanja podataka.

Parametar *Loading Types* može imati nekoliko različitih vrijednosti:

INSERT – ova vrijednost definira da će podaci biti dodani u tablicu korištenjem operacije *Insert*.

UPDATE – ova vrijednost definira da će se podaci koji dolaze u odredište koristiti kako bi se provela operacija *Update* nad već postojećim zapisima u odredištu.

INSERT/UPDATE – ova vrijednost definira da će se za svaki dolazeci redak podataka, prvo obaviti operacija *Insert*. Ako se Insert zbog nekog razloga ne obavi onda će se provesti operacija *Update*.

UPDATE/INSERT – ova vrijednost definira da će se za svaki novi redak prvo pokušati obaviti operacija *Update*, a ako ona ne uspije onda će se probati provesti operacija *Insert*.


DELETE – ova vrijednost definira da će se dolazeci podaci koristiti kako bi se odredilo koji će zapisi iz odredišta biti brisani.

TRUNCATE/INSERT – ova vrijednost definira da će podaci u odredištu prvo srezati, a zatim će se novi podaci unijeti u odredište operacijom *Insert*.

DELETE/INSERT – ova vrijednost definira da će se svi zapisi iz odredišta prvo obrisati, a zatim će se novi podaci unijeti operacijom *Insert*.

CHECK/INSERT – ova vrijednost definira da će se odredište provjeriti da li sadrži ijedan zapis. Ako ne sadrži onda će se novi podaci unijeti operacijom *Insert*.

NONE – ova vrijednost definira da se nijedna operacija neće obaviti nad odredištem, ali podešavanje parametra *Loading Types* na ovu vrijednost može biti jako korisno tijekom ispitivanja jer će se izvlačenje podataka i transformacije podataka provesti, ali podaci neće biti uneseni u odredište.




Slika 6.6 Svojstva operatora

Podešavanjem svojstava operatora, posebno parametra *Loading Types*, definiramo kako će se podaci učitavati u odredište. Na taj način, u kombinaciji s konfiguracijom parametara pojedinih atributa, određujemo kako će se provoditi proces izvlačenja i učitavanja podataka u odredište.

6.3.3. Konfiguracija fizickih parametara mapiranja

Nakon što smo podesili parametre atributa i operatora u mapiranju, možemo prijeci i na konfiguraciju fizickih svojstava samog mapiranja. Da bi konfigurirali mapiranje potrebno je sa izbornika odabrati opciju *Configure*. Tada se otvara prozor koji sadrži fizicka svojstva mapiranja. Svojstva su podijeljena u dvije kategorije: *Operators* i *Steps*. Kategorija *Operators* sadrži parametre za sve operatore u mapiranju, dok kategorija *Steps* sadrži parametre koji su bitni za generiranje koda.

Na slici 6.7. su prikazani parametri iz kategorije *Operators* za jedan operator iz mapiranja MAP_DIM_ROK_INIT. Kao što vidimo za svaki operator postoji nekoliko podkategorija fizickih parametara. Od definiranja sheme u kojoj se nalazi operator do definiranja *SQL*Loader* parametara koji služe za izvlačenje podataka iz običnih datoteka (flat files). *Partition Exchange Loading* je poseban način učitavanja podataka, ali za njega je potrebno da je odredite podijeljeno po particijama, te ga nisam koristio. Podkategorija *Hints* definira sugestije koje će koristiti optimizator za optimizaciju izvlačenja i učitavanja podataka, a *Constraint management* podkategorija definira da li će se koristiti ograničenja.



Slika 6.7 Fizicki parametri operatora u mapiranju

Na slici 6.8. su prikazani parametri koji utjecu na generiranje koda, odnosno pomoću kojih definiramo strategiju generiranja koda. Postoji samo jedna kategorija ovih parametara, ali zato sadrži mnogo parametara koji su jako bitni pa ću ih i opisati:

Default audit level – ovaj parametar definira razinu nadgledanja mapiranja tijekom izvođenja. Postoje četiri razine nadgledanja koje su iste kao i kod skladišnog

modula: bez nadgledanja, nadgledanje na razini statističke informacije, nadgledanje na razini pogrešaka i kompletno nadgledanje.

Setting Maximum Number of Errors – ovaj parametar definira maksimalni broj pogrešaka koji će biti dozvoljen tijekom generiranja i izvođenja ovog mapiranja. Ako se taj broj prijede, generiranje ili izvođenje se prekida.

Commit Frequency – definira učestalost s kojom će se potvrđivati promjene u bazi podataka. Ovdje je definirano da se nakon svakih 1000 redaka potvrđuju promjene.


Default Operating Mode – ovaj parametar definira kako će se generirati kod iz mapiranja. Ovdje je definirani način *Row based* što znači da će kao implementacijski jezik koristiti PL/SQL i da će se obrada provoditi na razini retka.

Generate Bulk Processing Code – ovaj parametar uključuje ili isključuje *bulk* procesiranje. Naime, PL/SQL za izvlačenje podataka iz neke tablice koristi SQL upit. *Bulk* procesiranje znači da će PL/SQL koristiti jedan SQL upit za dobivanje više redaka. Ako je *bulk* procesiranje isključeno to znači da će PL/SQL za svaki redak podataka koristiti jedan SQL upit, što može jako usporiti izvođenje mapiranja.

Bulk size – definira koliko se redaka podataka dohvaca odjednom, ako je *bulk* procesiranje uključeno

Analyze Statistics Percentage – definira se postotak redaka koji će se koristiti za procjenu statistike odredišnih tablica

Kada smo zadovoljni s konfiguracijom svih objekata možemo prijeći na sljedeći korak u implementaciji skladišta podataka, a to je generiranje i izvođenje skripti za definiranje objekata kao i za izvlačenje, transformaciju i učitavanje podataka u skladište podataka.




Slika 6.8 Fizicki parametri mapiranja koji utjecu na generiranje koda

7. Ucitavanje pocetnih podataka i osvježavanje skladišta podataka novim podacima

Generiranjem i pokretanjem skripti implementiramo fizicku instancu našeg skladišta podataka i pokrecemo ETL proces. Nakon pocetnog ucitavanja podataka u skladište moramo i osigurati mehanizme za periodicki punjenje i osvježavanje podataka u skladištu. Takoder moramo nakon svakog punjenja provjeriti tocnost ucitanih podataka, te ako je sve u redu objaviti te podatke kao pouzdane i točne.

7.1. Generiranje i pokretanje skripti

Nakon definiranja logickog modela, definiranja mapiranja te konfiguriranja svih tih objekata potrebno je za svaki objekt generirati skripte. Da bi generirali skripte potrebno je pritisnuti desnu tipku miša iznad odabranog objekta, te iz izbornika odabrati opciju *Generate*. Tada nam se otvara novi prozor koji izgleda kao na slici 7.1., a sadrži informacije o generiranim skriptama. Na slici je prikazan primjer za generirane skipte za dimenziju ROK.




Slika 7.1 Prozor s informacijama o generiranim skriptama za dimenziju ROK

Kao što vidimo u donjem dijelu ekrana se pojavljuje informacija o imenu objekta, tipu objekta, imenu skripte, ulogu koja ima ta skripta i jeziku u kojem je napisana. Za objekte poput dimenzija, tablica cinjenica, tablica, i sl., OWB generira

takozvane DDL skripte (DDL – Data Definition Language) koje služe za kreiranje objekata. Na desnoj, donjoj strani ekrana nalaze se tri tipke od kojih su nam bitne prve dvije: *View Code* i *Deploy*. Tipka *View Code* nam omogućuje da vidimo generirani kod za odabranu skriptu, dok nam tipka *Deploy* omogućuje da tu skriptu i implementiramo na željeno računalo gdje nam je i skladište podataka. Implementacijom DDL skripti ujedno i stvaramo fizicku instancu objekta za koji je ta skripta napisana. Oznacavanjem svih objekata na ekranu i pritiskom na tipku *Deploy* smo u stvari fizicki instancirali dimenziju ROK prema definiciji i konfiguraciji koju smo proveli ranije.

Postupak generiranja skripti za mapiranja je sličan postupku generiranja skripti za ostale objekte. Ekran s informacijama o generiranim skriptama je vrlo sličan onome na slici 7.1., ali ipak ima nekih razlika. Na slici 7.2. je prikazan ekran s generiranim skriptama za mapiranje MAP_DIM_ROK_UPDATE.



Slika 7.2 Ekran s informacijama o generiranim skriptama za mapiranje MAP_DIM_ROK_UPDATE

Kao što vidimo za svako mapiranje se generiraju dvije skripte: PL/SQL skripta namjenjena za izvođenje ETL procesa i TCL skripta koja služi za registraciju skripte kao posla (engl. job) u *Oracle Enterprise Manageru* ili sličnim programima.

Za PL/SQL skriptu se također može vidjeti generirani kod pritiskom na tipku *View Code*. Pritiskom na tipku *Deploy* ta skripta se integrira u skladište podataka, ali

da bi napravili svoj posao potrebno ju je i pokrenuti s tipkom *Run*. Pokretanjem skripte ona obavlja posao za koji je napravljena. U posebnom prozoru možemo vidjeti rezultate tog obavljenog posla, eventualne pogreške i status posla. Pokretanjem skripte se obavlja izvlacenje podataka iz definiranih izvora i punjenje odredišta tim podacima.

TCL je kontrolna skripta koja služi za registriranje posla u OEM. Kada se neka skripta registrira kao posao u OEM, tada se može pokretanje te skripte automatizirati tj. odrediti kada će se pokrenuti. Također se za sve poslove mogu pomoću *Oracle Workflowa* odrediti njihove međusobne ovisnosti i na taj način možemo definirati kompletan proces kojeg opet možemo automatizirati pomoću OEM. Međutim za naše potrebe bio je dovoljan i samo OWB.

Ovdje također treba napomenuti da je redoslijed implementacije objekata bitan jer je potrebno implementirati dimenzije, prije implementacije tablice činjenica. Generiranjem i pokretanjem svih skripti, za sve objekte i mapiranja, implementirali smo fizicku instancu našeg skladišta i napunili smo je početnim podacima. Međutim ostaje nam još riješiti problem periodičkog osvježavanja i punjenja skladišta podataka novim podacima kao i provjere točnosti učitanih podataka.

7.2. Periodičko osvježavanje i punjenje skladišta podataka novim podacima

Kad smo napunili skladište podataka početnim podacima, potrebno je također osigurati mogućnost da se skladište podataka nadopunjava novim podacima. Taj proces nadopunjavanja novim podacima je možda i najosjetljiviji dio ETL procesa. To je zato što je potrebno raspoznati koje podatke već imamo u skladištu, a koje bi trebalo učitati u skladište što ovisno o situaciji zna biti vrlo kompliciran problem.

Međutim u našem slučaju ipak nije tako kompliciran. Pošto nemamo pravu dimenziju vremena, već imamo dimenziju ROK koja ju zamjenjuje, moguće je da se novi podaci u tablice činjenica unose po završetku obrade roka. Nakon unosa podataka potrebno je podatke provjeriti i objaviti do kojeg roka je tablica činjenica valjana, tako da se zna koji je iduci rok kojeg trebamo unijeti. Na taj način se može osigurati nadopunjavanje skladišta podataka bez velikih problema.

Što se tiče nadopunjavanja i osvježavanja dimenzijskih tablica, situacija je malo kompliciranija. Dimenzijske tablice ne možemo nadopunjavati po nekom ključu


vec moramo uvijek odabirati sve moguće podatke iz izvora i onda od tih podataka odabrati one koji su nam novi i njih unijeti u dimenzijske tablice. Kako se to može napraviti pokazat ću na primjeru dimenzije ROK koja će se ujedno i najviše nadopunjavati.

Za dimenziju ROK napravio sam dva mapiranja: MAP_DIM_ROK_INIT i MAP_DIM_ROK_UPDATE. Prvo mapiranje puni dimenziju početnim podacima, a drugo služi za nadopunu. Ovaj problem se mogao riješiti i samo s jednim mapiranjem, ali sam htio pokazati razliku pa sam napravio dva mapiranja. Razlika u ova dva mapiranja je u konfiguraciji atributa i odredišnog operatora. Na slici 7.3. je prikazana konfiguracija operatora dimenzije ROK, kao i konfiguracija atributa DATUM_DATUM i DATUM_TIP_ROKA u mapiranju MAP_DIM_ROK_INIT. Na slici 7.4. je su prikazane konfiguracije za isti operator i iste attribute, ali u mapiranju MAP_DIM_ROK_UPDATE.


Kao što se vidi sa slika, konfiguracije operatora i atributa DATUM_TIP_ROKA su različite, dok je konfiguracija za atribut DATUM_DATUM ista. Prilikom konfiguriranja operatora i atributa u mapiranju MAP_DIM_ROK_INIT bilo je zamišljeno da to mapiranje puni dimenziju ROK početnim podacima. To znači da prije pokretanja tog mapiranja nije bilo nikakvih podataka u dimenziji ROK. Stoga su svi podaci mogli biti umetnuti u dimenziju ROK operacijom *Insert* bez provjere da li ti podaci već postoje, pa je i mapiranje tako konfigurirano (u konfiguraciji operatora je postavljeno da će se izvoditi operacija INSERT).

Međutim, ako želimo nadopunjavati dimenziju, mapiranje MAP_DIM_ROK_INIT nije prikladno jer ono samo umeće podatke u tablicu bez obzira da li neki podaci već postoje ili ne. Nadopunjavanje se vrši pokretanjem mapiranja MAP_DIM_ROK_UPDATE koje je i konfigurirano u tu svrhu. Naime, u konfiguraciji operatora dimenzije ROK u tom mapiranju je u parametru *Loading Types* postavljena vrijednost UPDATE/INSERT i u parametru *Match by constraint* je postavljena vrijednost *No*. Takav postav nalaže da se za svaki redak koji ulazi u dimenziju ROK prvo pokuša provesti operacija UPDATE, a ako ona ne uspije obavlja se operacija INSERT. Za odluku koji će redak biti podvrgnut operaciji UPDATE ne gleda se ključ već se ispituju atributi koji imaju uključenu opciju *Update: Use for matching*. U našem slučaju to je atribut DATUM_DATUM jer su rokovi poslagani po datumu pa je logično ispitivati da li već postoji taj datum u dimenziji. Za ostale

atribute koji ne sudjeluju u provjeri vrijednosti isključene su sve opcije osim *Insert: Use for Loading* tako da se oni ne ispituju, ali se umecu u dimenziju. Mapiranje radi tako da se prilikom punjenja dimenzije provjerava da li već postoji u dimenziji redak koji ima istu vrijednost atributa DATUM_DATUM kao i nadolazeci. Ako ima onda se taj redak ne umeće u dimenziju ROK, a ako nema istu vrijednost onda se umeće na kraj dimenzije ROK. Ovakav postupak se može koristiti za nadopunjavanje bilo koje dimenzije.



Slika 7.3 Konfiguracija operatora i atributa u mapiranju MAP_DIM_ROK_INIT



Slika 7.4 Konfiguracija operatora i atributa u mapiranju MAP_DIM_ROK_UPDATE

7.3. Provjera učitanih podataka

Nakon učitavanja početnih podataka u skladište podataka potrebno je provjeriti točnost učitanih podataka. Provjera točnosti zapravo znači da li učitani podaci odgovaraju stvarnim podacima koji su u operacijskoj bazi. Provjera podataka je jako bitna jer ako su učitani podaci krivi skladište podataka ne prikazuje pravu sliku stanja.

U našem slučaju provjera učitanih podataka je bila relativno jednostavna. Što se dimenzijskih tablica tice jednostavno sam usporedio učitane podatke s onima u operacijskoj bazi i ustanovio da su učitani podaci točni. Jednostavna provjera dimenzijskih tablica je bila moguća zbog relativno malo podatka prisutnih u operacijskoj bazi pa se jednostavnim pregledavanjem moglo provjeriti da li su podaci učitani u skladište podataka točni.

Što se tice tablice činjenica situacija je bila ipak malo problematичnija. Podatke u tablici činjenica sam provjeravao u dva dijela. Prvi dio provjere je obuhvatao nadzor nad učitavanjem u tablice činjenica i kontrola broja redaka koji se učitavaju u tablice činjenica jer sam znao koliko bi se redaka trebalo učitati za neki rok (npr. znao sam da je na prvi kolokvij izašlo 739 studenata pa sam očekivao 739 redaka koji bi tijekom obrade morali izvuci iz operacijske baze i kasnije sažeti u manji broj i učitati u skladište podataka). Drugi dio provjere je obavljen nakon učitavanja, a obuhvatao je postavljanje upita za koje sam već imao rezultate iz operacijske baze i usporedba dobivenih rezultata iz skladišta podataka s onim koje sam već imao. Na taj način sam obavio provjeru učitanih podataka u tablicama činjenica. Zaključak je da su podaci u skladištu dobro učitani.

Zaključak

U ovom diplomskom radu sam obradio kompletan postupak izgradnje skladišta podataka – od teorijskih osnova do implementacije korištenjem programskog paketa Oracle Warehouse Builder. Skladištenje podataka je koncept koji se pojavio u zadnjih nekoliko godina, a u prvom redu služi kao potpora procesa poslovnog izvješćivanja. Skladištenje podataka omogućava lakše i brže izvještavanje i efikasnije korištenje raspoloživih resursa. U ovom radu sam izradio skladište podataka koje bi trebalo služiti profesorima i asistentima sa Zavoda za osnove elektrotehnike i električka mjerenja u lakšem dobivanju povratnih informacija o uspjehu studenata na ispitima iz njihovih kolegija.

Sam proces izgradnje skladišta podataka je vrlo složen i zahtjevan proces, te nadasve odgovoran posao. Tijekom izgradnje skladišta potrebno je definirati od kuda će se izvlaciti podaci (izvori), potrebno je definirati logički model skladišta u kojeg će se spremati izvučeni podaci. Također je potrebno definirati proces izvlačenja, transformacije i učitavanja podataka iz izvora u skladište podataka (poznatiji kao ETL proces) što se radi pisanjem skripti u raznim programskim jezicima (SQL, PL/SQL,...). Nakon definiranja logičkog dijela, potrebno je implementirati stvarno skladište, učitati u njega podatke te najvažnije provjeriti da li su ti podaci točni i da li su dobro učitani. Proces izgradnje skladišta podataka obuhvaća najveći dio skladištenja podataka.

Za izradu skladište koristio sam Oracle-ov programski paket Oracle Warehouse Builder. Kako je OWB relativno nov programski paket s kojim nitko još nije imao previše iskustva, mnogo sam vremena potrošio proučavajući razne priručnike i eksperimentirajući po ekranima OWB, ali kad sam shvatio kako radi nije više bilo problema. OWB je programski paket koji je jednostavan za korištenje, te znatno ubrzava izgradnju skladišta podataka. OWB, uz ostalo, ipak posebno olakšava definiciju ETL procesa. Naime u OWB nije potrebno pisati skripte ručno, već OWB generira kod prema definicijama i konfiguracijama koje smo sami napravili. To omogućuje veliku uštedu u vremenu razvoja i implementacije skladišta podataka, te na taj način se i povećava efikasnost tima koji izrađuje skladište podataka.

Što se tice ovog konkretnog rada i izgradnje skladišta za Zavod za osnove elektrotehnike i električka mjerenja, smatram da je projekt bio uspješan. U tome je

OWB bio od velike pomoci. Uspio sam napraviti skladište podataka i u njega učitati točne podatke. Ono što bi još trebalo napraviti da bi skladište bilo kompletno, je izgraditi sustav izvještavanja. Znači, potrebno je postojeće skladište nadograditi s nekim alatom za izradu izvještaja, i možda izraditi portal preko kojeg će svi zaposlenici zavoda moći pristupiti skladištu korištenjem lokalne mreže. Bez mogućnosti dobivanja izvještaja samo skladište nema smisla ni koristiti.

Na kraju mogu reći da sam zadovoljan s napravljenim. Mislim da je projekt uspio iako će na potpunu ocjenu rada trebati pričekati neko vrijeme. Također sam zadovoljan i sa samom temom diplomskog rada i mogu reći da sam puno naučio i da će mi to kasnije puno pomoći. Spoznao sam neke probleme koji se javljaju samo u stvarnom svijetu i ovaj projekt mi je bio veliko iskustvo i poticaj za daljnji rad i usavršavanje.

Popis literature

Knjige:

- [1] R. Kimball, *The Data Warehouse Toolkit*, Wiley Computer Publishing, 1996.
- [2] Oracle Corporation, *Oracle Warehouse Builder User's Guide*, Oracle Corporation, 2001.
- [3] Oracle Corporation, *Data Warehousing Guide*, Oracle Corporation, 1999.
- [4] Z. Skocir, I. Matasic, Vrdoljak, *Organizacija obrade podataka*, interna skripta, Zavod za telekomunikacije, 2001.
- [5] Oracle Corporation, *PL/SQL User's Guide and Reference*, Oracle Corporation, 1997.

Clanci:

- [6] V. R. Gupta, *An Introduction to Data Warehousing*, www.system-services.com
- [7] R. Kimball, *A Dimensional Modeling Manifesto*, www.dbmsmag.com
- [8] IBM Corporation, *Data Warehousing Concepts for AS/400*, IBM Corporation, 1996.

Gotovi seminarski, maturski, maturalni i diplomski radovi iz raznih oblasti, lektire , puškice, tutorijali, referati - specijalizovan tim za usluge visokokvalitetnog pisanja, istraživanja i obradu teksta za kompletan region Balkana.

Posetite nas na sajtovima ispod:

WWW.MATURSKIRADOVI.NET

WWW.SEMINARSKIRAD.ORG

WWW.MATURSKI.NET

WWW.MATURSKI.ORG

WWW.SEMINARSKIRAD.INFO

Dostupni smo Vam 24h 365 dana u godini.

Za gotove verzije rada obratiti se na mail:

maturskiradovi.net@gmail.com

061/ 11-00-105

Seminarski, diplomski, maturski radovi, prevodi na engleski i eseji...