Sustavi poslovne inteligencije hotela

Juračić, Oliver

Undergraduate thesis / Završni rad

2015

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Pula / Sveučilište Jurja Dobrile u Puli**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:137:550784

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Image not found or type unknown

Repository / Repozitorij:

Digital Repository Juraj Dobrila University of Pula

zir.nsk.hr

Image not found or type unknown

Sveučilište Jurja Dobrile u Puli
Fakultet za ekonomiju i turizam „Dr.Mijo Mirkovic“

OLIVER JURAČIĆ

Sustavi poslovne inteligencije hotela
(*Business Intelligence Systems for The Hotel Organizations)*

Završni rad

Pula, 2015.

Sveučilište Jurja Dobrile u Puli
Fakultet za ekonomiju i turizam „Dr.Mijo Mirkovic“

OLIVER JURAČIĆ

Sustavi poslovne inteligencije hotela
(*Business Intelligence Systems for The Hotel Organizations)*

Završni rad

MBS: 2337-E, izvanredni student 3. godina
Studijski smjer: Informatika

Predmet: Upravljački IS
Mentor: Dr.sc. Vanja Bevanda

Pula, rujan 2015.

IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisani Oliver Juračić, kandidat za prvostupnika informatike ovime izjavljujem da je ovaj Završni rad rezultat isključivo mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio Završnog rada nije napisan na nedozvoljen način, odnosno da je prepisan iz kojega necitiranog rada, te da ikoji dio rada krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

Student:

U Puli, 22.09. 2015. _____

SADRŽAJ

UVOD ... 1
1 POSLOVNA INTELIGENCIJA ... 3
1.1 O poslovnoj inteligenciji ... 3
1.2 Područja primjene ... 4
1.2.1 Poslovna inteligencija za menadžment i kontrolu ... 5
1.2.2 Poslovna inteligencija za povećanje učinkovitosti ... 5
1.2.3 Poslovna inteligencija u operativi ... 6
1.2.4 Poslovna inteligencija za unapređenje poslovnih procesa ... 7
1.2.5 Poslovna inteligencija za unapređenje podrške kupcima ... 7
1.2.6 Poslovna inteligencija koja čini svijet boljim ... 8
1.2.7 Ostala područja primjene poslovne inteligencije ... 8
1.3 Budućnost sustava poslovne inteligencije ... 8
2 TEHNOLOGIJE I ALATI POSLOVNE INTELIGENCIJE ... 11
2.2 Skladištenje podataka ... 12
2.2.1 Skladišta podataka ... 12
2.2.2 „Data Mart“ ... 14
2.3 Rudarenje podataka ... 15
2.4 OLAP alati ... 18
3 IZRADA APLIKACIJE ... 25
3.1 O aplikaciji ... 25
3.2 O razvojnim alatima ... 26
3.3 Relacijski model i opis tablica ... 26
3.4 Izrada aplikacije ... 30
3.4.1 Izrada „view“ objekata ... 30
3.4.2 Izrada pivot tablice ... 37
3.4.3 Izrada stranica aplikacije ... 39
4 ZAKLJUČAK ... 42
LITERATURA ... 43
POPIS SLIKA ... 44
POPIS TABLICA ... 44

UVOD

U ovom radu govori se o poslovnoj inteligenciji i njenoj primjeni prikazanoj kroz praktičan primjer u analizi podataka poslovanja hotelskog kompleksa.

Pojam poslovne inteligencije vrlo je atraktivan rukovodstvima poduzeća zbog svog utjecaja na povećanje poslovnih performansi, a time i povećanje prihoda, što je u današnje vrijeme jedan od glavnih mjerila uspješnosti. Čest je slučaj da poduzeća svoj informacijski sustav godinama koriste na uobičajen način, praktički bez ideje što sa starim arhivskim podacima. Poslovna inteligencija takav propust može ispraviti. Ona je koncept kojim se sakupljeni podaci pretvaraju u informaciju kojom se potkrjepljuje proces donošenja poslovnih odluka, jer ako se ne iskoristi u tom smjeru, sami postupci njene primjene malo vrijede.

Spor tempo razvoja posljednje ekonomske krize, kao posljedicu imao je i isti takav tempo prilagodbe gospodarstva. Kriza sama po sebi sprječava organizacije da djeluju sukladno svojim željama, jer su ograničenja budžeta sve veća, tržišta sve izazovnija, sredstva predviđena za investicije se smanjuju, a s druge strane menadžment očekuje ostvarenje zadanih ciljeva.

Kako je opće poznato da su u IT industriji proizvodi i usluge relativno skuplji nego u drugim industrijama, što je i normalno s obzirom na razinu stručnosti i tehnološka znanja koja se zahtijevaju, u duhu ekonomske krize, projekt je realiziran pomoću besplatnog alata.

Cilj ovog rada je analizom implementacije poslovne inteligencije na modelu hotelskog kompleksa dokazati da je moguće unaprijediti poslovanje upotrebom besplatnih alata i tehnologija te da je implementacija ozbiljnijeg modela poslovne inteligencije isplativ potez i u ovim ekonomski vrlo teškim vremenima.

Cilj je ostvaren na sljedeći način:

1. Kroz uvod smo upoznati sa osnovnim pojmovima poslovne inteligencije u informatičkom poslovanju.
2. U drugom smo se poglavlju upoznali s osnovama i područjem primjene poslovne inteligencije
3. Dalje se govori o tehnologijama i alatima kojima se poslovna inteligencijama služi
4. Četvrto je poglavlje posvećeno opisivanju rada i tehnologija korištenih u izradi aplikacije jednostavne poslovne inteligencije hotelskog poduzeća

5. Na kraju su provedeni zaključci vezani za ovaj rad

U izradi ovog rada korištena je deskriptivna metoda, te metode modeliranja i eksperimenta.

1 POSLOVNA INTELIGENCIJA

1.1 O poslovnoj inteligenciji

Poslovna inteligencija je proces kojim se prikupljaju podaci i informacije iz unutarnje i vanjske poslovne okoline s ciljem njihove pretvorbe u poslovna znanja kojima bi se olakšalo donošenje poslovnih odluka. Menadžerima to postaje presudan strateški resurs kojim se rukovode pri donošenju kvalitetnih poslovnih strategija. U velikom postotku u cijelom svijetu poslovna inteligencija zasebna je poslovna funkcija. U Evropskoj uniji zastupljena je od 73% do 96%, dok je na svjetskoj razini oko 87%. U Hrvatskoj je situacija nešto drugačija. U istraživanju u razdoblju listopad 2010. - travanj 2011., provedenom metodom online ankete na uzorku od 1.000 najvećih (prema prihodu) hrvatskih tvrtki, 19% tvrtki u Hrvatskoj ima zasebne PI organizacijske odjele, dok se 57% tvrtki povremeno unutar ostalih poslovnih aktivnosti bavi PI područjem[1].

Pojam poslovne inteligencije prvi puta se pojavljuje 1986. godine, a upotrijebio ga je Howard Dresner, koji je u to vrijeme bio glavni analitičar u američkoj konzultantskoj kući GartnerGroup Inc. , danas CRO (Chief Research Officer) u Dresner Advisory Services.[2]



Slika 1. Howard Dresner

Izvor: http://microstrategyexamprep.com/category/wisdom-of-crowds/ , kolovoz 2015.

Od svog je nastanka pojam poslovna inteligencija postao snažno utisnut u svjetska gospodarstva, čak u toj mjeri da je preuzeo ulogu instrumenta bez kojeg je suvremeno poslovanje nezamislivo. Razlog toga je jednostavan. Ispravna, kvalitetna i pravovremena

[1] „Business intelligence u hrvatskom gospodarstvu“ - Mirko Bilandžić, Benjamin Čulig, Danijela Lucić, Martina Putar-Novoselec & Jelena Jakšić
[2] http://www.dresneradvisory.com/our-approach-to-research , kolovoz 2015.

poslovna informacija, prenesena u znanje iz kojeg se rađa poslovna odluka temelj je poslovnog uspjeha.[3]

„Kao što su oči ogledalo duše, poslovna inteligencija je prozor u dinamiku poslovanja“[4] riječi su Cindy Howson, potpredsjednice „Research in BI and Analytics at Gartner“. Ona otkriva sposobnosti, poslovne učinkovitosti i neotkrivene mogućnosti. Ona je skup tehnologija i procesa koja omogućuju ljudima, na svim nivoima organizacije, da pristupe podacima i da ih prouče. Bez ljudi koji će shvatiti informacije i djelovati sukladno njima poslovna inteligencija ne može postići ništa. Tehnologija nam omogućuje poslovnu inteligenciju i analitiku, ali ljudi su taj faktor koji će uvođenje poslovne inteligencije napraviti velikim uspjehom ili propalim pokušajem.

Česte su zablude, kojima se pojam poslovne inteligencije poistovjećuje s pojmom skladištenja podataka. Trebalo bi napomenuti da iako skladište podataka može biti djelom poslovne inteligencije, bez upotrebe alata koji u rukama korisnika transformiraju podatke u korisne informacije samo skladište podataka ne donosi ništa

1.2 Područja primjene

Poslovna inteligencija prožima se kroz sve funkcije i sve industrije, dodiruje sve osobe unutar tvrtki i više od toga, šireći se prema kupcima, dobavljačima, a preko javnih podataka i do građana. Kako je prije spomenuto, poslovna inteligencija može dati vrijednost samo kada je učinkovito korištena od strane ljudi. Postoji veza između učinkovitog korištenja poslovne inteligencije i učinka poduzeća.[5] Dakako, imanje boljeg pristupa podacima ne donosi automatski i bolju poslovnu učinkovitost. Donosi je ono što tvrtke rade s podacima koje posjeduju.

[3] Javorović, B., Bilandžić, M., (2007): Poslovne informacije i business intelligence. Zagreb: Golden marketing-Tehnička knjiga
[4] Successful Business Intelligence: Unlock the Value of BI & Big Data – Cindy Howson, Cpt.1, BI and Big Data from the Business side, McGraw-Hill Education; 2 edition (November 8, 2013)
[5] Ibidem.

1.2.1 Poslovna inteligencija za menadžment i kontrolu

Poslovna inteligencija, u svojoj osnovi, pribavlja menadžerima informacije o poslovanju, kako bi znali što se događa u njihovu poslu. Bez toga, njihova strategija bila bi let na slijepo, bez uvida u poslovanje, bar dok se ne objave tromjesečni izvještaji. Uz poslovnu inteligenciju informacije su dostupne na vrijeme i na puno fleksibilnijoj osnovi koja omogućuje uvid u:

- Prodaju po regijama i produktima
- Troškove usporedive sa predviđenim budžetima
- Pregled roba i materijala u skladištima
- Usporedbu predviđene i ostvarene prodaje

Kada neki parametar iskoči iz predviđenih okvira, poslovna inteligencija dozvoljava korisniku da detaljnije istraži podatke koji leže ispod prikazanog parametra, kako bi mogao poduzeti odgovarajuće akcije. Nekada menadžeri, dok bi proučavali financijske izvještaje, ili pratili prikaz podataka iz transakcijskih sistema, nisu bili u mogućnost dublje istražiti zašto se posao kreće u nekom smjeru. Na primjer, mnoge kompanije koriste poslovnu inteligenciju kako bi pratili troškove proizvodnje i spriječili da ne premaše budžet. Umjesto da čekaju kraj tromjesečja, kako bi otkrili da su troškovi pretjerano umanjili ili u potpunosti anulirali dobit, sada mogu u svakom trenutku pristupiti podacima o troškovima, istražiti ih i utvrditi koje je mjere potrebno poduzeti kako bi se na vrijeme reagiralo i smanjilo troškove dok oni u potpunosti ne ponište dobit.

1.2.2 Poslovna inteligencija za povećanje učinkovitosti

Učinkovito korištena poslovna inteligencija omogućuje organizacija da povećaju svoju učinkovitost. Poslovna učinkovitost mjeri se brojkama ili financijskim indikatorima, kao što su prihodi, marže, troškovi. U marketingu, učinkovitost se može povećati tako da se otkriju karakteristike proizvoda i kupaca koji na njih dobro reagiraju. Proizvodi na koje kupci dobro ne reagiraju, trebaju se prilagoditi ili potpuno ukinuti. Takve odluke donesene na vrijeme mogu uštedjeti kompanijama velike gubitke. Poslovna inteligencija omogućava kompanijama da povećaju zaradu prodajući proizvode sličnih karakteristika ciljanim skupinama koje dobro reagiraju na takve karakteristike. Računovodstva mogu brzo i lako pronaći loše platiše. U proizvodnji, poslovna inteligencija može olakšati analizu zašto neke tvornice rade učinkovitije od drugih.

U svim tim slučajevima pristup podacima neophodan je prvi korak. Dakako, povećanje učinkovitosti također zahtjeva ljudski uplit u analizu podataka kako bi se utvrdila najbolja akcija koja će to poboljšanje i donijeti. Poduzimanje te akcije ne treba biti podrazumijevano. Ljudi ponekad imaju političke, vjerske ili financijske razloge da takav korak ne poduzmu. Da se postigne pravi učinak, pri donošenju odluke, sve te razloge treba uzeti u obzir. Tvrtka može uvesti poslovnu inteligenciju kako bi dobila dublji uvid u stanje poslovanja, ali ako taj uvid nije iskorišten za donošenje odluke i provođenje akcije onda poslovna inteligencija nije napravila ništa za povećanje učinkovitosti poslovanja. Također, i krivo prosuđivanje u donošenju odluke negira učinke povećanja učinkovitosti. Ključno mjerilo uspješnosti poslovne inteligencije je stupanj kojim utječe na povećanje učinkovitosti poslovanja, povezujući dubinski uvid u podatke i djelovanje.6

Mjerenje utjecaja poslovne inteligencije na povećanje uspješnosti poslovanja nije jednostavno, jer na to povećanje utječu faktori koje sama poslovna inteligencija ne može mjeriti. Metode kojima se ono mjeri postoje, ali one nisu dio ovog rada.

1.2.3 Poslovna inteligencija u operativi

Dok je „rana“ poslovna inteligencija uglavnom bila fokusirana na pomoć pri strateškim odlukama i povećanju učinkovitosti, u novije vrijeme postaje sve važnija u dnevnom operativnom poslovanju. Sukladno tome, pristup detaljnim podacima i informacijama može biti ključan za uspješno obavljane takvog posla. Na primjer, kao dio zaprimanja nove narudžbe, zastupnik prodaje može prvo provjeriti zalihu. Takav izvještaj o stanji zalihe može biti dio standardnog sustava izvještavanja, ali može biti i dio sustava poslovne inteligencije, bilo neovisnog, bilo ugrađenog u sustav izvještavanja. Još neki primjeri poslovne inteligencije u operativi bili bi:

- Putničke agencije i aerodromi koriste poslovnu inteligenciju pri praćenju odgode letova, pa na osnovu toga proaktivno ponudili alternative putnicima koji presjedaju.
- Bolnice koriste poslovnu inteligenciju da predvide optimalan broj pojedinih djelatnika za vrijeme najvećih gužvi
- Restorani je koriste da predvide vrijeme čekanja na stol u ovisnosti o predviđenom broju gostiju i prosječnoj dužini trajanja obroka

[6] https://www.gartner.com/doc/2715117/business-intelligence-performance-management-key, kolovoz 2015.

- Centrima za korisničku podršku koristi da utvrde optimalni broj djelatnika i linija u ovisnosti o količini poziva i prosječnom trajanju
- Dostavljači i prijevoznici robe nalaze korist pri planiranju optimalnih ruta i metoda dostave.

Poslovna inteligencija u operativi najviše se razlikuje od one za menadžment i to u nivou promatranih detalja kao i u promatranom vremenskom uzorku. Kada se koristi u operativi najčešće traži pristup transakcijsko bazi ili skladištu podataka koje se ažurira relativno često, pa i po nekoliko puta dnevno. Dio koji koristi menadžmentu i kontroli može se također koristiti iz transakcijske baze ili često ažuriranog skladišta podataka, ali najčešće se promatraju uzorci u dužem vremenskom periodu kao što su tjedni, mjeseci ili čak godine.

1.2.4 Poslovna inteligencija za unapređenje poslovnih procesa

Poslovni je tok sastavljen od desetina pojedinačnih poslovnih procesa. Poslovna inteligencija može podržavati odluke koje pojedinci donose u svakom koraku tih procesa. Može se koristiti kako bi ubrzati proces mjereći koliko pojedini pod proces traje i pronalazeći područja koja se mogu poboljšati. Na primjer, proizvodnja je jedan proces. U odsutnosti poslovne inteligencije tvrtka može shvatiti da ima problem u trenutku kada se kupac požali da mu kasni roba. Ili da isti produkt od konkurencije brže dolazi. Analizirajući ulaze, vrijeme i izlaze za svaki korak procesa, poslovna inteligencija pomaže u pronalaženju uskog grla koje koči normalan tijek proizvodnje.

- Tvrtke za online prodaju prate broj paketa spremljenih za slanje po satu i danu. Svaka promjena u tim podacima kože dovesti do revizije procesa kojima bi se daljnje optimizirao proces.

1.2.5 Poslovna inteligencija za unapređenje podrške kupcima

Kvalitetna podrška kupcima, na kraju se uvijek manifestira kroz profit. Poslovna inteligencija kože pomoću tvrtkama podići kvalitetu korisničke podrške pružajući vremenski uvid u procesuiranje narudžbi, odobravanje popusta, rješavanje jamstvenih pritužbi itd.

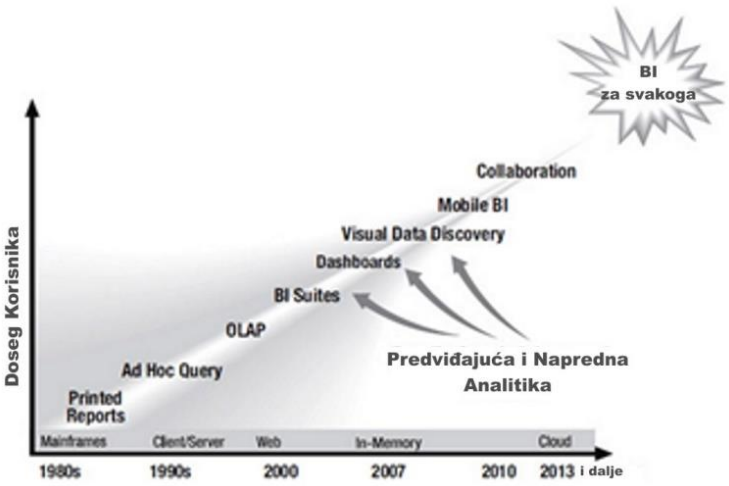
1.2.6 Poslovna inteligencija koja čini svijet boljim

Poslovna inteligencija za menadžment, kontrolu i povećanje učinkovitosti okupira većinu medijske pažnje. S druge strane, davanje mogućnosti ljudima da mijenjaju svijet dio je čija važnost sve više raste. Školski sistemi koriste poslovnu inteligenciju da bi probali razumjeti trendove u rezultatima ispita baziranima na spolu, postocima pristupanja, metodama učenja itd. Mnoge bolnice koriste se njime kako bi smanjile vrijeme čekanje, poboljšale uslugu i smanjile troškove liječenja. Proizvođači medicinskih pomagala, koriste se metodama poslovne inteligencije, prateći i mjereći na koji način njihovi uređaji olakšavaju živote njihovih korisnika.

1.2.7 Ostala područja primjene poslovne inteligencije

Osim sve gore navedenog poslovna se inteligencija intenzivno koristi u sportu, politici, otkrivanju novih poslovnih prilika te u svakodnevnom životu.

Kako je vidljivo na slici područja primjene poslovne inteligencije širila su se godinama i danas su po svojoj važnosti u poslovanju kao i u svakodnevnom životu dovela do prepoznavanja poslovne inteligencije od mnogih svjetskih korporacija kao jednog od najvažnijih prioriteta u IT-u.



Slika 2. Evolucija poslovne inteligencije

Izvor: www.gartner.com, august, 2015

1.3 Budućnost sustava poslovne inteligencije

Kako smo to već ranije spomenuli u prvo vrijeme od svoga nastanka poslovna je inteligencija bila uglavnom orijentirana na udovoljavanje potreba menadžmenta i kontrole, pritom koristeći metode analize povijesnih podataka i tražeći odgovor na pitanje: „Što se

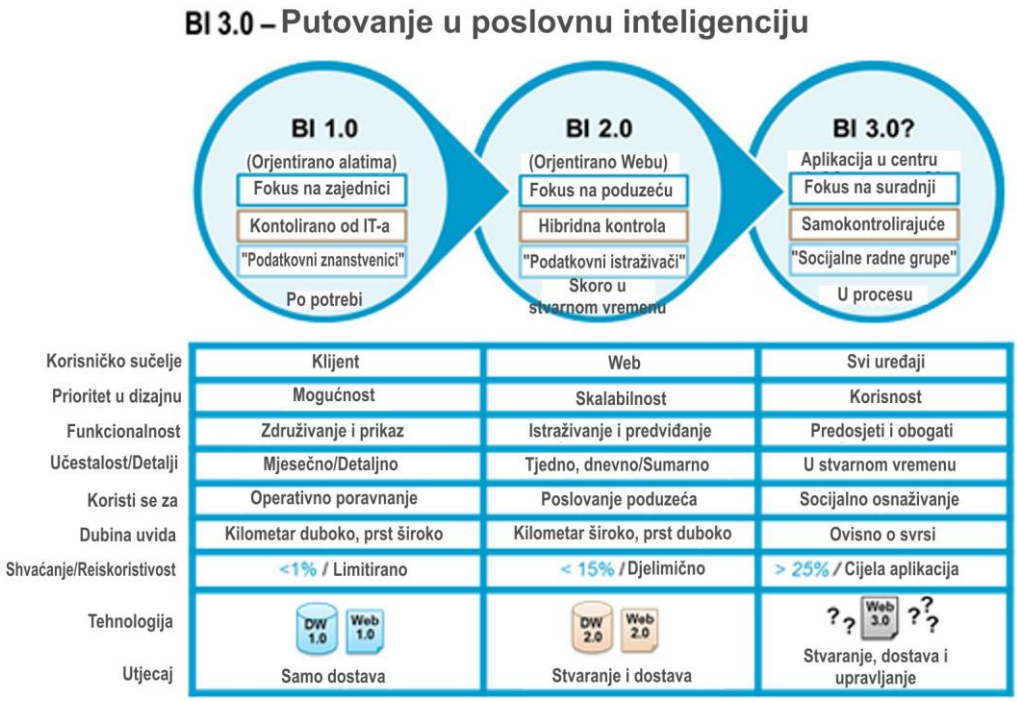
događalo?„ Tražile su se pravilnosti i zakonitosti u događajima iz nekog prošlog vremena s ciljem prenošenja otkrivenih konkretnih znanja menadžerima, a preko njih i izvršiteljima ili poslovnim partnerima kako svi skupa ne bi ponavljali greške ili propuštali prilike koje ranije nisu uočavali. Količine podataka koje su se u te svrhe prikupljale bile su ogromne, stoga se brzo uvidjelo da treba uvesti novi sustav pohranjivanja koji je nazvan skladištenjem podataka (eng. Data Warehousing).

Vremenom se skladištenje podataka počelo mijenjati, prilagođavajući se potrebama tržišta. Iako su sustavi poslovne inteligencije koji su se primjenjivali nad skladištima podataka imali odlične uspjehe u nalaženju pravilnosti i odgovora iz povijesnih podataka to nije bilo dovoljno da zadovolji potrebe planiranja i analize koja zahtjeva pogled unaprijed. Poslovna je inteligencija trebala izaći iz područja povijesnih analiza i usmjeriti se budućnosti.7 U budućnosti, da bi mogle ostati konkurentne na tržištu, tvrtke će se morati sve više oslanjati na sustave poslovne inteligencije. Korisnici su iz tog razloga počeli zahtijevati poslovnu inteligenciju i analizu podataka u realnom vremenu. Informacije trebaju biti dostupne u svakom trenutku. Poslovni procesi poslovnih organizacija morati će se prilagoditi tokovima podataka. Taj novi pristup ponekad se naziva „Poslovna inteligencija 2.0“[8] Novi pojam odnosi se na skupljanje, dostavu i analizu podataka u realnom vremenu, što raniji alati nisu mogli. To je pristup fokusiran na web koji uključuje procesuiranje podataka u stvarnom vremenu, upravljan je IT osobljem ali i korisnicima samim i nadahnjuje korisnika da se upusti u istraživanje podataka kroz dostavu sadržaja preko poznatog sučelja. Rana rješenja rasla su sa razvojem tržišta i na početku je sve bilo bajno. Novi izazovi pojavili su se s vremenom, kako je rastao broj korisnika, kao i broj načina gledanja na podatke. S veličinom, rasla je kompleksnost i raznovrsnost pogleda na informaciju, što donosi potrebu za novim rješenjem. Nova informacijska struktura postaje ključni izazov kojem će pokušati odgovoriti „Poslovna inteligencija 3.0“

Poslovna inteligencija 3.0 treba omogućiti onima koji donose odluke u poslovanju da brzo i neovisno istraže, stvore i analiziraju sadržaj dok u isto vrijeme:

- Štite poslovne korisnike od kompleksnosti alata kojim se koriste.
- Omogućuju korisnicima da podijele saznanja s osobama unutar i izvan organizacije, bilo gdje i bilo kada, putem bilo kojeg uređaja ili platforme.
- Dozvoljavaju korisnicima da kombiniraju ljudska znanja i podatke unutar konteksta poslovne inteligencije kako bi zajednički donijeli daljnje odluke.

[7] Panian, Ž. et al.: Poslovna inteligencija – Studije slučajeva iz hrvatske prakse, Ekonomska biblioteka, Zagreb, 2007., str. 36.
[8] http://www.yellowfinbi.com/YFCommunityNews-Defining-Business-Intelligence-3-0-159445, kolovoz 2015.



Slika 3. Tijek razvoja poslovne inteligencije

Izvor:https://www.capgemini.com/blog/capping-it-off/2012/07/bi-30-the-journey-to-business-intelligence-what-does-it-mean

Ukratko, poslovna inteligencija 3.0 trebala bi osloboditi „radnika znanja“ iz okova nedostupnosti i kompleksnosti podataka.[9] Poslovna inteligencija napokon postaje ono što bi trebala biti: „Jezgrena komponenta u neprekidnim pokušajima da se unaprijedi poslovanje i kojom vladaju sami korisnici.“[10]

[9] https://www.capgemini.com/blog/capping-it-off/2012/07/bi-30-the-journey-to-business-intelligence-what-does-it-mean, kolovoz 2015.
[10] http://www.ittechnewsdaily.com/203-business-intelligence-tools.html, kolovoz 2015.

2 TEHNOLOGIJE I ALATI POSLOVNE INTELIGENCIJE

2.1 Uvod

Nakon smještanja poslovne inteligencije u poslovni kontekst, možemo navesti tehnike i alate kojima se ona implementira. Velike količine podataka potrebno je sakupiti i obraditi pa su u tu svrhu razvijeni mnogi alati. Poslovna inteligencija može sadržavati povijesne podatke, kao i nove podatke dobivene iz raznih izvora u trenutku nastajanja. Alati poslovne inteligencije nekad su primarno bili korišteni od analitičara podataka ili drugih IT profesionalaca koji su radili analize i stvarali izvještaje. Kasnije se zahvaljujući razvoju „self-service" poslovne inteligencije u to uključuju prvo menadžeri, a zatim i svi drugi djelatnici. Razni proizvođači alata za poslovnu inteligenciju nude svoja rješenja, međusobno drugačija i najčešće razvijen prema potrebama jednog određenog sektora npr. proizvodnje ili bankarstva. Kombiniraju se razne tehnologije za analizu podataka, uključujući „ad hoc" analizu[11] i upite, online analitičko procesiranje (OLAP[12]) , mobilnu PI, PI u realnom vremenu, operativnu BI, cloud i SaaS (software as a service) PI, kolaborativnu PI i lokacijsku PI[13]. Tehnologije poslovne inteligencije također uključuju vizualizaciju podataka, alate za dizajniranje infografike, kao i alate za izgradnju nadzornih ploča i „performance scorecard-a" koji vizualiziraju podatke u poslovnoj metrici i ključne indikatore učinka poslovanja na način koji je lako razumijeti.

Aplikacije poslovne inteligencije mogu se nabaviti zasebno od raznih proizvođača ili kao dio objedinjenih platformi od jednog velikog. Danas se na tržištu nude cjeloviti sustavi od renomiranih tvrtki kao što su Microsoft, Oracle ili SAP. Programi poslovne inteligencije u sebi obično sadržavaju formu napredne analitike kao što je rudarenje po podacima[14], predviđajuća analitika (predictive analytics)[15], rudarenje teksta, statistička analiza i analiza velike količine podataka (big data analitics[16]).

[11] „Ad hoc" analiza je proces poslovne inteligencije dizajniran da odgovori na jedno specifično poslovno pitanje. Produkt takve analize je, obično statistički model, analitički izvještaj ili neki drugi tip sumiranog podatka.
[12] OLAP je računalna obrada koja omogućuje korisniku da jednostavno i selektivno izdvoji i vidi podatke iz raznih točki gledišta.
[13] http://searchdatamanagement.techtarget.com/definition/business-intelligence, kolovoz 2015.
[14] Rudarenje po podacima je preslagivanje podataka u svrhu pronalaska obrazaca i veza među njima
[15] „Predictive analytics" je grana rudarenja po podacima usmjerena ka predviđanju budućih vjerojatnosti i trendova
[16] Big data analitics je proces pretraživanja velikih količina podataka koji sadrže mnoštvo raznih tipova podataka u svrhu nalaženja skrivenih obrazaca, nepoznatih veza, tržišnih trendova, korisničkih želja i drugih korisnih poslovnih informacija

Podaci koje koristi poslovna inteligencija obično su spremljeni u skladištima podataka ili manjim „dana mart-ovima“ koji sadrže podskupove informacija. Dodatno, Hadoop[17] sistemi se sve više koriste unutar arhitekture poslovne inteligencije kao spremišta podataka, posebno za nestrukturirane podatke, logove, senzorne podatke i druge oblike „big data“ podataka. Skladištenje podataka osnovni je preduvjet poslovne inteligencije i potrebno ga je detaljnije pojasniti.

2.2 Skladištenje podataka

2.2.1 Skladišta podataka

Podaci koji se obrađuju u poslovnoj inteligenciji obično su spremljeni u skladištu podataka (eng. Data Warehouse“) ili manjim „Data Mart-ovima“ koji u sebi sadrže pod skupove informacija. Termin skladištenje podataka skovao je William H. Inmon, poznat i kao otac skladištenja podataka.



Slika 4. William H. Inmon

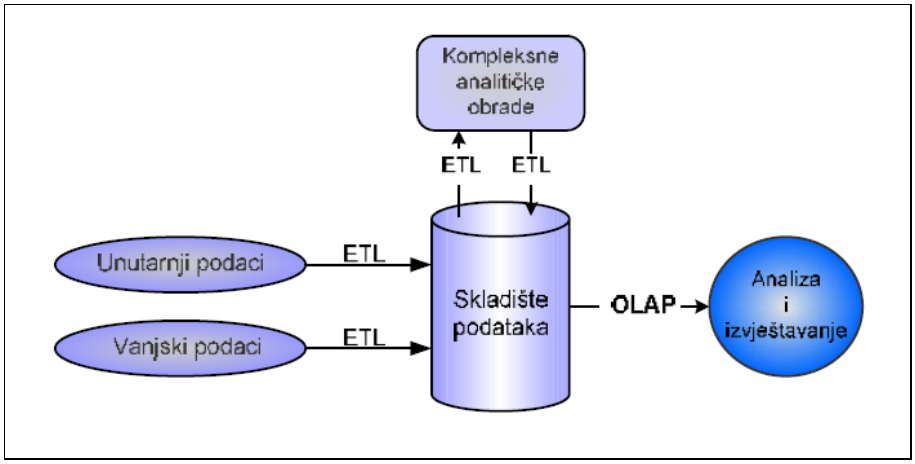
Izvor: http://damaottawa.wildapricot.org/event-548592, August 2015.

Inmon je opisao skladištenje podataka kao subjektno orijentiranu, vremensku i postojanu kolekciju podataka koji podržavaju proces donošenja odluka.[18] Skladište podataka osnovni je repozitorij za sve podatke koji razni poslovni programi sakupljaju. Taj repozitorij može biti fizički ili logički. Prije nego li se mogu koristiti u programima poslovne inteligencije, „sirove podatke“ iz različitih izvora potrebno je objediniti, presložiti i pročistiti

[17] Hadoop (trenutno u verziji 2) je besplatan „framework“ baziran na Javi koji podržava obradu velikih setova podataka u distribuiranom računalnom okruženju.
[18] http://searchsqlserver.techtarget.com/definition/data-warehouse, kolovoz, 2015.

koristeći alate za integraciju i kvalitetu podataka, kako bi se osigurala preciznost i dosljednost informacija. Proces kojim se to provodi prikazan je na slici 5., a zove se ETL (eng. Extract, Transform, Load).

Podaci iz raznih OLTP[19] (eng. Online Transaction Processing) sistema i drugih izvora se selektivno „izvlače“ za korištenje u naknadnim analitičkim procesima. U skladište mogu biti spremljeni u relacijskom ili dimenzijskom obliku. Menadžerima raznih poduzeća jako se sviđa dimenzijska struktura podataka jer omogućuje visok stupanj vizualizacije, što je uz integrirani i pravovremeno dobiven podatak koji sustavi poslovne inteligencije omogućuju, preduvjet za donošenje kvalitetnih odluka. Dimenzijska struktura s druge strane omogućuje pregled podataka kombiniranjem više relevantnih faktora u nekom vremenskom roku, kojima se mogu dobiti izvještaji kao što su pregledi proizvodnje ili prodaje po regijama u nekom vremenu i periodici. Skladišta podataka obično se čuvaju na „mainframe“ serverima, ili sve više u oblaku.



Slika 5. Shema sustava poslovne inteligencije

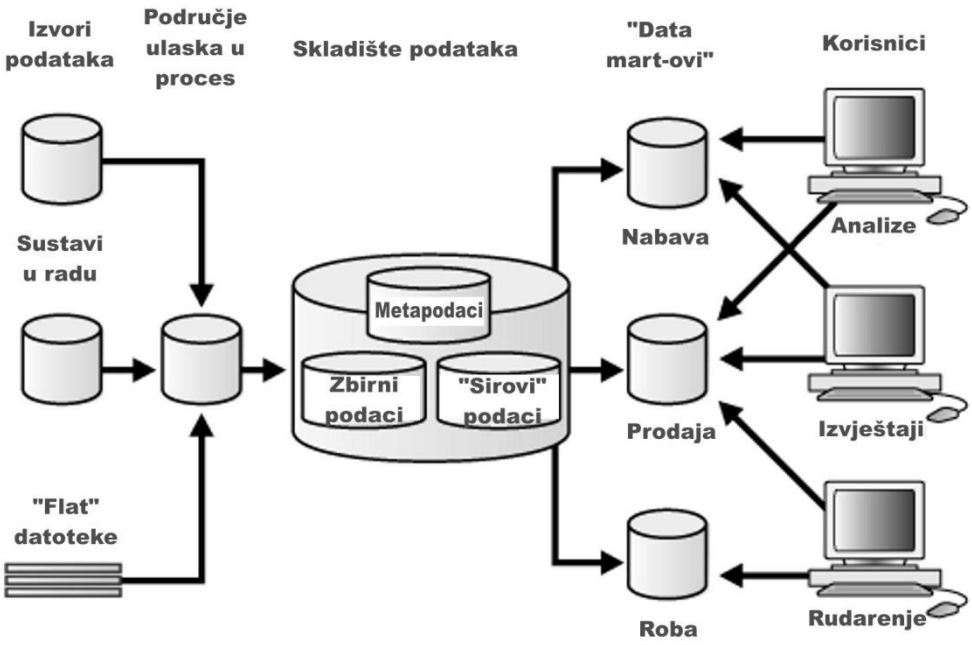
Izvor: Panian, Ž., Klepac, G.: ***Poslovna inteligencija****, Masmedia, Zagreb, 2003., str. 61.*

Za korisne analize i upite, skladišta podataka potiču preuzimanje podataka iz raznih izvora, što s točke gledišta krajnjeg korisnika može biti prenatrpano i zbunjujuće. Njemu najčešće treba specijalizirani, često lokalni prikaz podatka. Stoga se, kasnije razvila ideja „Data Mart-ova“.

[19] OLTP je klasa softvera koja podržava transakcijski orijentirane aplikacije, kao sistemi unosa narudžbi, financijske transakcije, CRM i sl. Imaju jednostavne upite i brze odgovore iz baza podataka. Primjer je IBM-ov CISC (Customer Information Control System).

2.2.2 „Data Mart“

„Data mart“, u nekim literaturama piše se spojeno „Datamart“, je repozitorij podataka dizajniran da služi određenoj grupaciji ili vrsti korisnika poslovne inteligencije. Razlika između skladišta podataka i „Data mart-a“ ponekad može biti zbunjujuća jer se dva termina često koriste kao sinonimi. Skladište podataka je centralni repozitorij za sve podatke neke organizacije, dok je cilj „Data mart-a“ da odgovori na specijalizirane zahtjeve neke grupacije korisnika unutar organizacije, kao na primjer ljudskih resursa ili korisničke podrške. To generalno znači da je skladište podataka jedno, dok „Data mart-ova“, unutar jedne organizacije, ima ili bi trebalo biti više. „Data mart“ je u osnovi podskup organizacijskog skladišta podataka.



Slika 6. Arhitektura skladišta podataka

Izvor: https://docs.oracle.com/database/121/DWHSG/concept.htm#DWHSG8075

Budući da su „Data mart-ovi“ optimizirani da gledaju na podatke na svoj jedinstven način, prilikom njihova stvaranja treba krenuti od sagledavanja potreba korisnika. Skladišta podataka, s druge strane, nastaju na način da se sagledavaju postojeći podaci i načini na koji bi se ti podaci mogli sakupiti i složiti kako bi kasnije postali korisni. Skladišta podataka su strateški, ali na neki način nezavršen proces, dok je „Data mart“ taktički proces koji odgovara na trenutne potrebe.

Postoje dva pristupa izgradnji skladišta podataka i „Data mart-ova“. Jedan je odozgo prema dole (eng. top down), a drugi odozdo prema gore (eng. bottom up). Prvi stvara „Data mart-ove“ za specifične grupacije korisnika nakon što je skladište podataka oformljeno. Drugi pristup prvo stvara „Data mart-ove“, a onda ih kombinira u jedinstveno sveobuhvatno skladište podataka.

U današnje vrijeme, virtualizacijski softveri omogućili su kreiranje virtualnih „Data mart-ova“ koji vuku podatke iz raznih izvora, kombiniraju ih po potrebi s drugim podacima da zadovolje specifične potrebe korisnika. Virtualni „Data mart-ovi“ omogućuju korisnicima pristup podacima koji su im potrebni, dok u isto vrijeme ne zauzimaj prostor za pohranu, što omogućuje lakše održavanje i veći nivo kontrole podataka.

2.3 Rudarenje podataka

Pojam rudarenje podataka (eng. Data mininig), ponegdje se spominje i kao otkrivanje znanja (eng. Knowledge Discovery) u svojoj je biti pretraživanje podataka u svojstvu pronalaska veza ili odnosa među njima. Svrha rudarenja je pronaći smisao u podacima. U tom svjetlu dobro je prisjetiti se dvije izjave. „Svrha računarstva je uvid, a ne brojke“[20] i „Imati mišljenje je umjetnost, a u zrncima leže činjenice“[21]. Obje mogu služiti kao lajtmotiv svega čemu rudarenje nad podacima stremi.

Rudarenje nad podacima i otkrivanje znanja, nasljedno je povezano s bazama podataka. U tom smislu, rudarenje nad podacima značajno unaprjeđuje baze podataka, praveći ih pristupačnijima za upotrebu i na taj način omogućava ljudima da se osjećaju opuštenije radeći s velikim količinama podataka i izvlačeći korist iz njih.[22] To je prirodna evolucija tehnologije koja datira još iz 18. (Bayesov teorem) i 19. (regresijska analiza) stoljeća[23], a upotrebljava interdisciplinarne koncepte, metodologije i tehnike od baza podataka i statistike do umjetne inteligencije. Baze podataka godinama su se razvijale, od primitivnih do moćnih i sofisticiranih kakve su danas. Sposobne su sakupljati ogromne količine podataka, pa je jasno da se morala pojaviti potreba za obradom i analizom istih, a sve u svrhu stjecanja novih znanja i drugih korisnih informacija.

[20]Richard Hamming, Više na: https://en.wikipedia.org/wiki/Richard_Hamming
[21] Herb Caen, Više na: http://www.nndb.com/people/498/000022432/
[22] Krzysztof J. Cios , Witold Pedrycz, Roman W. Swiniarski: Data Mining and Knowledge Discovery, Poglavlje 1.1 Defending knowledge dicovery
[23] https://en.wikipedia.org/wiki/Data_mining, kolovoz 2015.

Tehnologije rudarenja nad podacima rezultat su dugotrajnog procesa istraživanja i razvoja statističkih algoritama koja je počela kada su poslovni podaci prvi puta uneseni u računala, a nastavlja se i danas razvojem novih tehnologija, koje korisnicima omogućuju prikaz podataka u više dimenzija i to u realnom vremenu. Osnovne tehnologije čiji je razvoj omogućio rudarenje nad podacima su:

- Tehnologija za masovno prikupljanje podataka
- Snažna višeprocesorska računalna podrška
- Algoritmi za rudarenje podataka

Ključni parametri rudarenja nad podacima su:

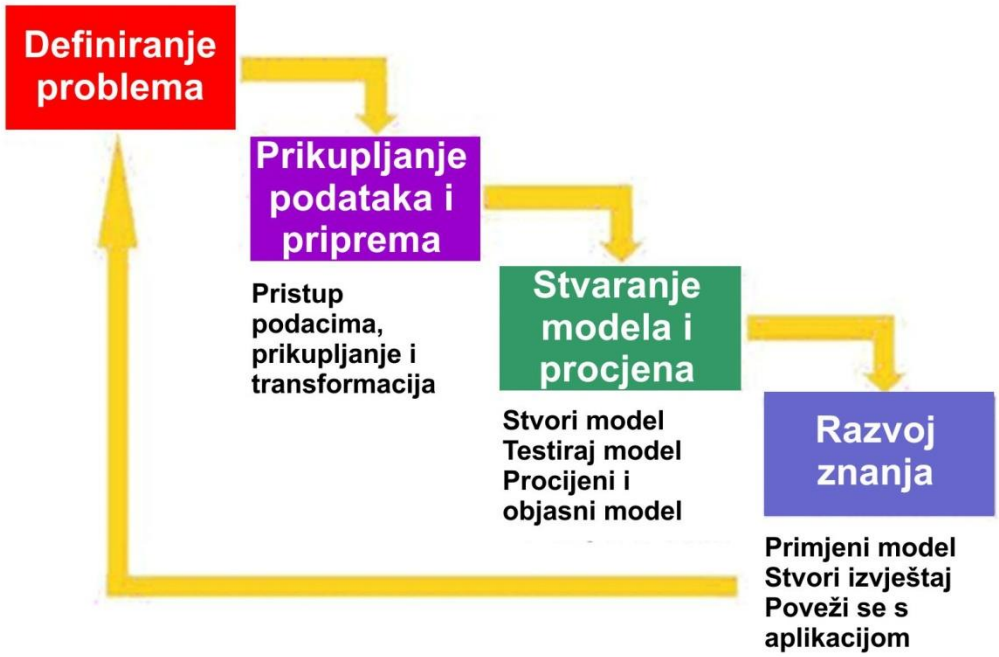
- Asocijacija ili traženje uzorka u kome je jedan događaj vezan za drugi
- Analiza puta ili traženje uzorka gdje jedan događaj slijedi u drugi kasniji
- Klasifikacija ili traženje novih uzoraka
- Klasteriranje ili traženje međusobno zavisne grupe činjenica
- Prognoziranje ili traženje uzoraka među podacima koji mogu dovesti do razumnog predviđanja budućih događaja.

Rudarenje nad podacima odgovara na pitanja koja ne mogu biti odgovorena običnim upitima i tehnikama izvještavanja.24 Podaci mogu biti rudareni neovisno o tome da li su smješteni u „flat“ datotekama, proračunskim tablicama, tabelama baze podataka ili nekom drugom formatu spremanja. Kriterij za podatke nije njihov način spremanja, već njihova primjenjivost na problem koji se rješava. Dobro pročišćavanje podataka i priprema jako su važni za rudarenje, a skladište podataka može obaviti te aktivnosti, Naravno, niti ono nam neće biti od koristi ukoliko ne sadrži podatke potrebne za rješavanje problema koji imamo.
Proces rudarenja podataka iterativan je po prirodi, što znači da stalno prolazi kroz iste faze i ne zaustavlja se kada je neko rješenje pronađeno. Rezultat rudarenja podataka pokreće novo pitanje koje može biti iskorišteno za razvijanje novog još fokusiranijeg modela. Drugim riječima naknadne iteracije rudarenja profitiraju od prijašnjih.
Faze[24] procesa rudarenja podataka su:

- Definiranje problema – inicijalna je faza procesa rudarenja podataka fokusirana na razumijevanje ciljeva i zahtjeva projekta. Kada se odredi projekt s poslovne perspektive, treba ga formulirati kao problem rudarenja podataka i razviti početni provedbeni plan.

[24] http://docs.oracle.com/cd/B28359_01/datamine.111/b28129/process.htm, kolovoz 2015

- Prikupljanje podataka i priprema – je faza razumijevanja podataka koja uključuje sakupljanje podataka i istraživanje. Podatke treba dobro pregledati da bi se utvrdilo koliko dobro pokrivaju problem koji rješavamo. U toj fazi uklanjamo suvišne podatke ili dodajemo potrebne. To je također trenutak da se utvrde problemi s kvalitetom podataka, kao i pronađu obrasci u podacima. Temeljita priprema podataka može značajno poboljšati informacije dobivene rudarenjem.
- Stvaranje i procjena modela – faza je u kojoj se odabiru i primjenjuju razne tehnike modeliranja i postavljaju parametri na optimalne vrijednosti. Ako algoritam zahtijeva transformaciju podataka, potrebno se vratiti na prethodnu fazu da bi se promjena implementirala.
- Razvijanje znanja – je upotreba rudarenja nad podacima unutar ciljane okoline. U fazi razvoja iz podataka se uočavaju informacije koje se mogu prihvatiti ili se mogu dalje obrađivati.



Slika 7. Proces rudarenja podataka

Izvor: http://www.rosebt.com/blog/category/business%20process/2

Rudarenje podataka sastoji se od 5 glavnih elemenata:

- Izdvajanje, transformacija i učitavanje (ETL) transakcijskih podataka u skladište podataka
- Spremanje podataka u višedimenzionalni sistem baze podataka

- Omogućavanje pristupa podacima poslovnim analitičarima i IT profesionalcima
- Analiziranje podataka od strane aplikacijskog softvera
- Prezentiranje podataka u jasnoj formi, npr. grafu ili tabeli

Osnovne tehnike za rudarenje nad podacima su umjetne neuronske mreže, genski algoritmi, stabla odlučivanja, metode najbližeg susjeda, indukcijska pravila, asocijacijska pravila, statističke metode i vizualizacija podataka. Primjena rudarenja nad podacima moguća je svugdje gdje se raspolaže s velikom količinom podataka, a gdje je potrebno otkriti pravilnosti, veze i zakonitosti.

2.4 OLAP alati

OLAP je kratica za „Online Analitical Processing“. To je računalna obrada koja omogućava korisniku da iz raznih kutova lagano i selektivno izdvoji i promatra podatke. OLAP se može koristiti za rudarenje nad podacima ili otkrivanje prije neotkrivenih veza među njima. Baza kojoj OLAP aplikacija pristupa ne mora biti velika kao skladište podataka ili „Data mart“, budući da ne moraju svi transakcijski podaci biti bitni za analizu koja se radi. Korištenjem ODBC (Open Database Conectivity) konekcije podaci se mogu uvesti iz postojeće relacijske baze, skladišta ili „Data mart-a“ u višedimenzionalnu bazu koju OLAP aplikacija koristi.

OLAP često znači više različitih stvari različitim ljudima, ali termin uvijek uz sebe veže izraze kao što su višedimenzionalnost, kocke, „slicing & dicing“, brzi odgovor, svrdlanje itd. OLAP je sve to, ali i više od toga. OLAP aplikacije prikazuju korisnicima informacije, a ne samo podatke. To olakšava korisnicima brzo pronalaženje obrazaca i trendova u podacima, bez potrebe da tragaju kroz velike količine „sirovih“ podataka. Tipično, analiza je vođena potrebom da se odgovori na poslovna pitanja kao što je: „Kako nam ovaj mjesec ide prodaja u Istarskoj županiji?“ Od takvih temelja OLAP aplikacije prelaze na područja predviđanja i rudarenja po podacima, dajući korisnicima odgovore na pitanja kao:“Koji su naši predviđeni troškovi za slijedeću godinu?“ ili „Prikaži mi listu naših najuspješnijih trgovaca“.

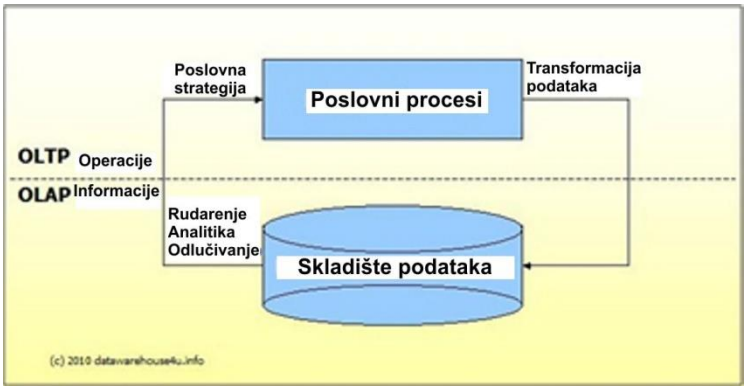
OLAP aplikacije razlikuju se od klasičnih OLTP[19] aplikacija na način na koji spremaju, analiziraju i prezentiraju podatke svojim korisnicima. To su osnovne razlike koje omogućavaju OLAP aplikacijama da odgovore na sofisticiranija poslovna pitanja. Postoje

značajne prednosti OLAP aplikacija nad OLTP aplikacijama, a to je vidljivo u nekoliko područja[25]:

- Povećanje količine podataka – Nije izgledno da će se uskoro smiriti trendovi povećanja podataka koje tvrtke spremaju u svoje baze. Preuzimanje više tisuća zapisa za trenutnu obradu je vremenski i procesorski zahtjevan posao, pogotovu kada puno korisnika koristi aplikaciju istovremeno. Baze podataka koje mogu brzo prikazati nekoliko tisuća zapisa nekolicini korisnika imaju velike probleme kada su primorane vratiti rezultate kompleksnih upita tisućama korisnika istovremeno. „Keširanje“ često traženih podataka u privremene tabele može ublažiti simptome, ali samo djelomično rješava problem, pogotovu ako korisnici zahtijevaju „samo malo“ drugačije podatke. U modernim skladištima podataka gdje zahtijevani podaci mogu biti rasprostranjeni u nekoliko tabela, kompleksnost upita može također uzrokovati vremensku odgodu i zahtijevati ogromne hardverske resurse, što znači veća ulaganja u opremu kako bi se zadovoljile potrebe korisnika.
- Podaci vs. Informacije – Poslovni korisnici trebaju oboje. Korisniku koji donosi poslovnu odluku o baziranu na nekom događaju potrebne su informacije sadržane u poslovnim podacima. Da bi odgovorila na pitanje: „Koliko smo proizvoda jedne vrste danas prodali?“, OLTP aplikacija mora prikupiti cijene svih proizvoda te vrste za današnji dan i zbrojiti ih, te prikazati sumarnu informaciju korisniku. Da napravi istu usporedbu za sve dane unutar 3 mjeseca ista se procedura mora ponoviti za svaki dan. Multipliciramo li problem na nekoliko stotina trgovina kako bi menadžer mogao vidjeti stanje prodaje u cijeloj tvrtci, lako je uočiti da cijeli proces zahtjeva enormnu količinu resursa i procesorske snage kako bi odgovor mogao stići u par sekundi koliko je korisnik spreman čekati. Baze podataka nisu dizajnirane da dohvaćaju grupe zapisa i onda ih matematički sumiraju, stoga kada su primorane to učiniti ne odrađuju to brzo. OLTP aplikacija dati će traženi odgovor, samo to neće uvijek biti onoliko brzo koliko je korisnik spreman čekati.
- Raspored podataka – Relacijski model baze podataka dizajniran je za transakcijsko procesiranje, što nije uvijek najbolji način da se spreme podaci ako se očekuju poslovna pitanja poput „Kolika je prodaja računala po regijama?“ ili „Kolika je mjesečna zarada na onom artiklu za gotovinska plaćanja u nekom periodu?“ Takve vrste upita zahtijevaju prikupljanje ogromne količine podataka koje onda treba na

[25] Introduction to OLAP, Seagate Info Technical Roadmap Series, 2002, Crystal Decisions, str.2-4

zahtjev sumirati ili prebrojati. To je nešto što zahtjeva vrijem i resurse, ili što je još značajnije takvi zahtjevi često znače da se različiti upiti (najčešće ugniježđeni jedan u drugi) izvršavaju na istom setu podataka.



Slika 8. OLTP „vs“ OLAP

Izvor: http://datawarehouse4u.info/OLTP-vs-OLAP.html

Odgovor na takva ograničenja OLTP aplikacija nije trošenje novca na veće i jače baze podataka ili jači hardver, nego potpuno novi pristup problemu, a taj pristup je OLAP. OLAP aplikacije spremaju podatke na različiti način od tradicionalnih relacijskih baza, što im dozvoljava da rade sa setovima podataka dizajniranim da rade s velikim brojem korisnika paralelno. Za razliku od baza podataka OLAP-ova spremišta podataka dizajnirana su da rade s agregiranim podacima, što im dozvoljava da brzo odgovore na kompleksne upite o poslovnim podacima, a u isto vrijeme omogućavajući korisniku i originalne transakcijske podatke kada su mu potrebni.

Iako različiti OLAP alati koriste različite tehnologije, svima je zajedničko da pokušavaju prikazati podatke koristeći isti napredni koncept višedimenzionalne kocke. Kocke je lako razumjeti, ali postoje temeljne razlike između kocki i baza podataka zbog kojih se može činiti da su kompliciranije nego što uistinu jesu. Kocka je koncept koji predstavlja spremište podataka u centru svih OLAP aplikacija. Iako sami podaci mogu biti spremljeni brojnim različitim metodama, kocka je logički dizajn putem kojeg se pristupa podacima. Možda je najlakše objasniti kocku ako usporedimo spremanje podataka u kocku sa spremanjem podataka u tablicu baze podataka.

Tablica 1. Relacijska tablica koja sadrži podatke o prodaji

Produkt	Trgovina	Količina
Žarulja	Gornji grad	40
Žarulja	Donji grad	52
Žarulja	Srednji grad	36
Baterija	Gornji grad	104
Baterija	Donji grad	22
Baterija	Srednji grad	78
Osigurač	Gornji grad	56
Osigurač	Donji grad	31
Osigurač	Srednji grad	58

Izvor: Samostalna izrada autora

Na slici 8. Prikazana je tablica transakcijske baze podataka s podacima o prodaji u tri trgovine. Postoje dvije tekstualne kolone „Produkt“ i „Trgovina“ te jedna kolona sa vrijednostima imenovana „Količina“. Takva se tablica često naziva „činjenična tablica“. Slika 9. Prikazuje istu tablicu preuređenu u kocku. Termin kocka treba shvatiti „labavo“ jer je ponovno prikazana dvodimenzionalna tablica.

Tablica 2. Tablica 1. prikazana u obliku kocke

		Dimenzija produkta		
		Produkti		
	Trgovine	Žarulja	Baterija	Osigurač
Dimenzija trgovina	Gornji grad	40	104	56
	Donji grad	52	22	31
	Srednji grad	36	78	58

Izvor: Samostalna izrada autora

Svaka stranica kocke sadrži stavke iz kolona tablice i nazivamo ih dimenzijama kocke. U ovoj kocki horizontalna dimenzija sadrži imena produkata i nazivamo je „dimenzija produkta“. Vertikalna dimenzija sadrži imena trgovina i zovemo je „dimenzija trgovina“. U tabeli baze podataka svaki red predstavlja podatak. U kocki, presjek između polja predstavlja podatak. U ovoj kocki ćelija na presjeku između „Donjeg grada“ i „baterija“ sadrži broj baterija prodanih u Doljem gradu, u našem slučaju 22. Nema potrebe spominjati riječ

„količina“ jer cijela kocka sadrži volumen „količina“.Ovaj koordinatni koncept nalaženja podatka razlog je zašto možemo „ignorirati“ jednu dimenziju kocke.

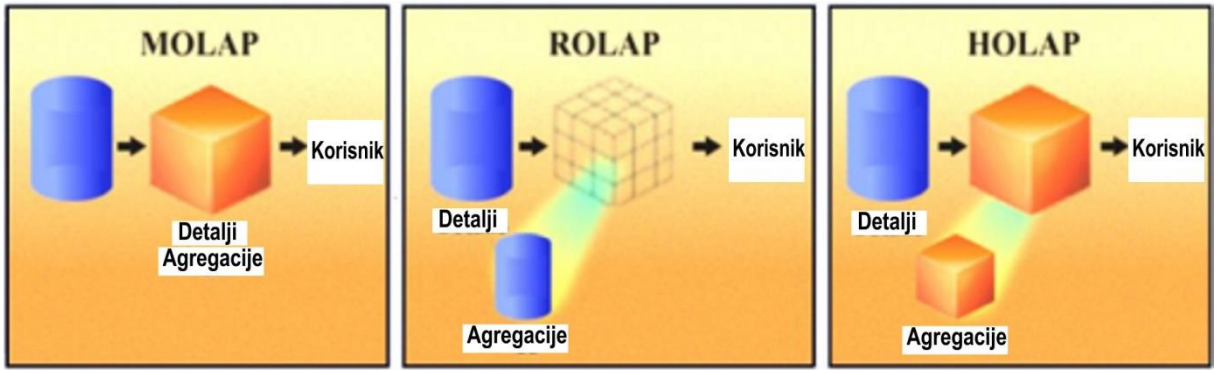
Iako korisna, ovakva kocka samo je mrvicu sofisticiranija od obične tablice. Sposobnosti kocke postaju očitije ako njen dizajn proširimo na više dimenzija. Ta višedimenzionalnost je možda element dizajna kocke kojeg se najviše „bojimo“ iz razloga što ga je teško vizualizirati. Kada bi u prvotnu tabelu dodali još kolone Prihod i Cijena u kocku bi trebalo dodati još jednu dimenziju. Kocka bi sada imala tri identične tablice, ali bi svaka držala drugi volumen. U prvoj bi bila količina, u drugoj prihod, a u trećoj cijena. Dobili smo trodimenzionalnu kocku. Sada možemo zamisliti da imamo 72 takve trodimenzionalne kocke, sve iste, osim što sadrže podatke svaka za drugi dan. Kombiniranje takvih kocki postaje problematično. Posebno se to očituje ako nam zatrebaju tjedni ili mjesečni podaci. Jednostavan način da se riješi taj problem je da se vratimo na našu trodimenzionalnu kocku i dodamo joj četvrtu dimenziju, u našem slučaju dimenziju „Dan“. Takav koncept ne možemo jednostavno nacrtati, niti vizualizirati, ali u kockama on funkcionira. Kao i ranije, podatak je smješten u jedinstvenoj ćeliji, koju možemo pronaći koristeći 4 jedinstvene dimenzije. Trebamo li prihod žarulja iz Gornjeg grada u ponedjeljak potrebit ćemo te 4 dimenzije i pronaći ćeliju.

Iako je to teško vizualizirati, zapravo su dimenzije i polja u tim dimenzijama ono što definira kocku, a ne podaci spremljeni u kocki. Tablica se često opisuje kao broj redaka i kolona, dok je broj dimenzija i broj polja u njima ono što definira kocku.

Fraza „slicing & dicing“ koristi se da opiše dio procesa koji se koristi pri pribavljanju podataka iz OLAP kocke. Zbog veličina i kompleksnosti do koje kocke mogu narasti, proces lociranju pravih podataka ponekad se naziva „navigacija“. Kako podaci mogu biti vizualizirani jedino u dvije dimenzije, višedimenzionalna kocka svesti na kriške podataka. Dok bira neku određenu orijentaciju u kocki korisnik je doslovno reže na kriške kako bi je mogao prikazati.

Dimenzije se mogu i ugnježđivati jedne u drugu kako bi se moglo istovremeni prikazivati više podataka. Moguće ih je grupirati i hijerarhijski nizati. Može ih se „bušiti“ za gore, dole i poprijeko (eng. drill-up, drill-down, drill-across), što je proces kojim se iz nadređenog polja premještamo u podređeno i obrnuto, ili se premještamo u polje jednake važnosti.

Spremanje podataka u kocke generalno se može obaviti na 3 različita načina. Sva tri načina prikazuju podatke u obliku kocke , ali se tehnologija iza njih razlikuje.



Slika 9. Verzije OLAP-a

Izvor: http://datawarehouse4u.info/OLTP-vs-OLAP.html

To su:

- ROLAP – što znači „Relacijski OLAP“. Termin opisuje OLAP aplikaciju koja sprema sve podatke o kocki u relacijske tablice. Aplikacija skriva postojanje tablica prikazujući podatke u obliku kocke. Višedimenzionalni pogled generira se kombiniranjem osnovnih i agregiranih tablica s podacima skupa s kompliciranim i često višestrukim SQL upitima. Rezultat takvog pristupa su spore performanse, kao i problematično održavanje agregiranih tablica.
- MOLAP – je naziv za „Višedimenzionalni OLAP“. On predstavlja OLAP aplikacije koje spremaju sve podatke kocke, one iz baze i one višeg nivoa koje stvara, u svoju vlasničku višedimenzionalnu podatkovnu datoteku. Aplikacija kopira osnovne podatke iz tablica u višedimenzionalni podatkovni format (obično binarnu podatkovnu datoteku), a onda procjenjuje i ujedinjene vrijednosti. Višedimenzionalni pogledi na podatke su automatikom prisutni u ovoj metodi te su stoga performanse odlične, posebno ako je kocka dovoljno mala da stane u radnu memoriju. Ipak češće se događa da je kocka spremljena u veliku datoteku na disku. Najveća je mana ove metode potreba za dupliciranjem podataka iz baze koje se događa pri kopiranju u kocku, što zahtjeva dodatan diskovni prostor i troši vrijeme.
- HOLAP – znači „Hibridni OLAP“ što je OLAP aplikacija koja sprema podatke višeg nivoa u svoju vlasničku višedimenzionalnu podatkovnu datoteku, ali ostavlja podatke iz baze u svojim originalnim tabelama. Velika prednost ove metode je da ne zahtijeva dupliciranje podataka iz baze, što štedi vrijeme i prostor. Kocka pruža

višedimenzionalni pogled , stoga aplikacija zahtijeva robusnu vezu između višedimenzionalne podatkovne datoteke i relacijski tablica baze u kojoj su podaci.

OLAP kocka je struktura podataka koja nadilazi limite relacijske baze podataka pružajući brzu analizu podataka. Kocke mogu prikazati bilo koju veliku količinu podataka dok u isto vrijeme omogućavaju korisnicima pretragu i pristup do bilo kojeg dijela baze. Na taj način podaci mogu biti pretraživani kako bi odgovorili na širok spektar pitanja relevantnih korisniku[26].

Poznati OLAP produkti su Oracle Essbase[27], ranije poznat kao Hyperion Solution's Essbase , IBM Cognos[28] i Microstrategy[29]. OLAP produkti su obično dizajnirani za višekorisničko radno okruženje, i najčešće se naplaćuju po broju korisnika.

[26] https://technet.microsoft.com/en-us/library/hh916543.aspx, kolovoz 2015.
[27] Više na: http://www.oracle.com/technetwork/middleware/essbase/overview/index.html
[28] Više na: http://www-01.ibm.com/software/analytics/cognos/
[29] Više na: http://www.microstrategy.com/us

3 IZRADA APLIKACIJE

3.1 O aplikaciji

Aplikacija pod nazivom „Sierra“ nastala je kao praktični rad u sklopu kolegija Informatičkog praktikum I u suradnji s tvrtkom Istra informatički inženjering[30] iz Pule, koja je u međuvremenu promijenila naziv u Istra Tech. Aplikacija je razvijena na već postojećoj bazi podataka Oracle XE[31] uz pomoć alata JDeveloper[32] i SQL Developer[33]. U aplikaciji se naravno, ne radi OLAP analiza, već se vizualiziraju izvještaji koji su rezultat SQL upita nad bazom koja nije optimizirana za analitiku. Studenti su polazili tečaj JDeveloper-a organiziran od strane Istra informatičkog inženjeringa, te su na kraju odradili samostalne zadatke tj. izradili web aplikaciju za tabelarni i grafički prikaz te analizu pokazatelja poslovanja s područja statistike. Podijeljeni su u nekoliko timova i ova aplikacija je rezultat rada tima br.2 pod nazivom „Sierra“. Tim su sačinjavali slijedeći studenti: Oliver Juračić, Dragana Božić – Bađun, Tatjana Berc, Sandro Butković i Ana Mirić. Ova je aplikacija dio završnog rada voditelja tima, dok su ostali članovi za to dali svoj pristanak, na čemu im posebno zahvaljujem.

Kao rezultat praktikuma izrađena je aplikacija iz koje menadžeri hotelskog poduzeća čija je baza podataka u pozadini mogu vizualizirati podatke i iz njih doći do informacija koje im mogu pomoći u planiranju i reviziji poslovanja, što i jeste svrha poslovne inteligencije.



Slika 10. "Sierra", Početni zaslon

Izvor: Samostalna izrada autora

[30] Više na: http://www.mish-iii.inet.hr/
[31] Više na: http://www.oracle.com/technetwork/database/database-technologies/express-edition/overview/index.html
[32] Više na: http://www.oracle.com/technetwork/developer-tools/jdev/overview/index-094652.html
[33] Više na: http://www.oracle.com/technetwork/developer-tools/sql-developer/overview/index-097090.html

3.2 O razvojnim alatima

Pri izradi aplikacije korišteni su Oracle-ovi alati JDeveloper i SQL Developer. Rad u njima, zbog izvrsno osmišljene i jasne radne okoline pokazao se iznimno jednostavan, a budući da dolaze od istog proizvođača od kojeg je i baza kojoj su pristupali nije bilo nikakvih problema u konfiguraciji i radu. Alati su u potpunosti besplatni, te je na Internetu moguće pronaći pregršt uputstava i primjera rada s njima.

JDeveloper je besplatan Oracle-ov IDE[34] koji razvojnim programerima pruža mogućnost razvijanja aplikacija u Javi, XML-u, SQL i PL/SQL-u, JavaScript-u, BPEL-u i PHP-u. Pokriva cijeli razvojni ciklus od dizajna, preko kodiranja, debagiranja, optimiziranja i profiliranja do puštanja u pogon.

S JDeveloper-om Oracle je pokušao pojednostaviti razvoj fokusirajući se na omogućavanje vizualnog i deklarativnog pristupa razvoju aplikacija kao dodatku na već postojeće napredno okruženje za kodiranje koje je preuzeto od Borland-ovog JBuilder-a i kasnije dodatno unaprjeđivano. Integrira se sa Oracle Application Development Framework-om ili Oracle ADF-om, Java EE baziranom framework-u koji dodatno pojednostavljuje razvoj aplikacija. Ista IDE platforma, također služi kao baza za dugi korišteni Oracle-ov produkt SQL Developer, koji Oracle promovira kao specijalizirani alat za rad u PL/SQL-u i razvoju baza podataka.

SQL Developer je također Oracle-ov besplatan IDE koji pojednostavljuje razvoj i održavanje Oracle-ovih baza podataka u tradicionalnom , kao i u „Cloud“ obliku. Nudi okolinu za razvoj PL/SQL aplikacija, kao i testiranje SQL upita i skripta, konzolu za administriranje baze, sučelje za izradu izvještaja, kompletno rješenje za modeliranje podataka i platformu za migraciju drugih baza u Oracle-ovu.

3.3 Relacijski model i opis tablica

Relacijski model baze na osnovu kojeg je napravljena aplikacija pripada tzv. star shemi. Star shema je dimenzijski dizajn implementiran na relacijskoj bazi. Sastoji se od dvije vrste tablica: činjenične tablice (ili transakcijske) i pripadajuće dimenzijske tablice (ili

[34] Integrated Development Environment ili Integrirano Razvojno Okruženje je softverska aplikacija koja pruža cjelovito rješenje za izradu aplikacija.

šifranti). U činjeničnoj tablici zapisane su svi prihodi u periodu od nekoliko godina ostvareni u sklopu hotelskog kompleksa turističkog poduzeća. Vanjskim ključevima iz dimenzijskih tablica da se iščitati po kojoj je osnovi prihod nastao.



Slika 11. "Sierra", Relacijski model korištenog dijela baze podataka

Izvor: Samostalna izrada autora

U ovom slučaju činjenična tablica se naziva Žurnal odnosno IREC_ZURDW_SZURU i postavljena je u središte te su na nju povezane ostale dimenzijske tablice: S_VSJ, M_SO, MREC_VPROGRAMA, MREC_GDGOSTIJU, SZMP_GSZURNALA, S_ZURNALA, S_ZEMLJE, M_AGENCIJE, S_USLUGE. Direktno jedna na drugu povezane su tablice S_ZEMLJE i M_AGENCIJE te SZMP_GSZURNALA i S_ZURNALA.

Opis tablica:

- IREC_ZURDW_SZURU je činjenična ili transakcijska tablica koja evidentira zapise ili transakcije o događaju.
- S_VSJ je tablica koja evidentira vrste smještajnih jedinica.
- M_SO se odnosi na mjesto smještajnog objekta.
- MREC_VPROGRAMA je tablica koja prikazuje vrste turističkih programa.
- MREC_GDGOSTIJU prikazuje dobne grupe gostiju.
- SZMP_GSZURNALA je tablica grupe stavaka (hrana, piće, smještaj i BP) u kojoj se grupiraju pojedine stavke iz tablice S_ZURNALA.
- S_ZEMLJE i M_AGENCIJE prikazuju popis zemalja, odnosno agencija te iz njihove povezanosti možemo očitati koja agencija potječe iz koje zemlje i obratno.
- S_USLUGE evidentira pojedine usluge hotelskog poduzeća.

3.4 Izrada aplikacije

Tim je dobio zaduženje izraditi 4 obavezna zadatka te mogućnost da proširi aplikaciju s dodatnim sadržajima. Prva tri zadatka je tabelarno i grafički prikazati NETO prihod po uslugama, zemljama i grupama stavaka za odabrani period i periodiku (dnevnu, tjednu, mjesečnu i godišnju). Četvrti zadatak je izrada pivot[35] tablice žurnala koja omogućava prikaz što više podataka. Budući da se sve vizualizacije osim pivot tablice izrađeni su na isti način, te je razlika samo u tablicama iz kojih se uzimaju podaci prikazat će se izrada samo prvog zadatka i pivota.

3.4.1 Izrada „view“ objekata

Na početku svakog zadatka potrebno je kreirati „view“ objekte, tj. SQL upite kojima se izrađuju pogledi (en. view) čiji se rezultat koristi za prikaz u pivot tablici, odnosno grafikonu. „View“ objektima (kasnije u tekstu VO) je dan sufiks VO radi lakšeg snalaženja u modelu. Kreirane VO je zatim bilo potrebno prebaciti u aplikacijski modul pri čijem se pokretanju može kontrolirati prikaz podataka.

Svaki izrađeni SQL upit, odnosno VO, sadrži slijedeće dvije varijable koje se odnose na početak i kraj promatranog vremenskog razdoblja. Prva je varijabla `:vPoc` (tip: date) i u nju se upisuje početni datum promatranog razdoblja. Druga se zove `:vKraj` (tip: date) i označava kraj promatranog razdoblja.



Slika 12. "Sierra", prikaz odabira datuma

Izvor: Samostalna izrada autora

SQL upiti koriste funkciju `trunc ( date, [ format ] )` pomoću koje je dobivena dnevna, tjedna, mjesečna, kvartalna i godišnja periodika.

Tablica 3. Argumenti format parametra

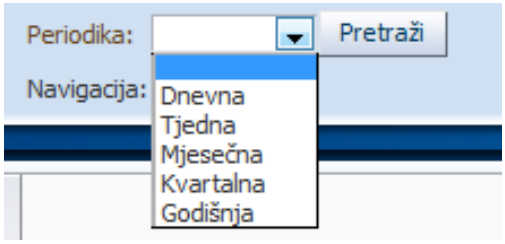
Periodika	Parametri
Year	SYYYY, YYYY, YEAR, SYEAR, YYY, YY, Y
ISO Year	IYYY, IY, I
Ouarter	O

[35] Pivot tablica je alat za sumarni prikaz podataka koji se koristi u programima za vizualizaciju podataka kao što su tablični kalkulatori i programi poslovne inteligencije.

Month	MONTH, MON, MM, RM
Week	WW
IW	IW
W	W
Day	DDD, DD, J
Start day of the week	DAY, DY, D
Hour	HH, HH12, HH24
Minute	MI

Izvor: http://www.techonthenet.com/oracle/functions/trunc_date.php

U aplikaciji Sierra, odnosno u SQL upitima unutar aplikacije, format datuma (dd, ww, mm, q, yy) zamijenjen je varijablom :vPeriodika (tip:string) koju korisnik odabire u padajućem izborniku periodike te poziva SQL upit s parametrom odabrane periodike.



Slika 13. "Sierra", odabir periodike

Izvor: Samostalna izrada autora

Da bi se u padajućem izborniku prikazivali nazivi periodike, a ne dd, ww, mm, q i yy napravljen je slijedeći SQL upit:

```
select 'dd' sif, 'Dnevna' naz,1 from dual
union select 'ww' sif,  'Tjedna' naz,2 from dual
union select 'mm' sif , 'Mjesečna' naz,3 from dual
union select 'q' sif, 'Kvartalna' naz,4 from dual
union select 'yy' sif, 'Godišnja' naz,5 from dual
order by 3
```

Ovim je upitom dobiven VO koji nam služi kao izvor podataka za periodiku. Brojevi u trećem stupcu dodani su isključivo iz razloga da se u aplikaciji periodika prikazuje u redoslijedu koji je logičniji (Dnevna, Tjedna, Mjesečna, Kvartalna i Godišnja), a ne po abecedi, te je taj stupac iskorišten za slaganje.

Ukoliko korisnik odabere jedno vremensko razdoblje i želi pogledati npr. NETO prihod po uslugama, a zatim i NETO prihod po zemljama ili neki drugi prihod vrijednosti

koje su upisane za vremensko razdoblje prvi puta prenose se na ostale. Periodika se ne prenosi, već se bira iz padajućeg izbornika.



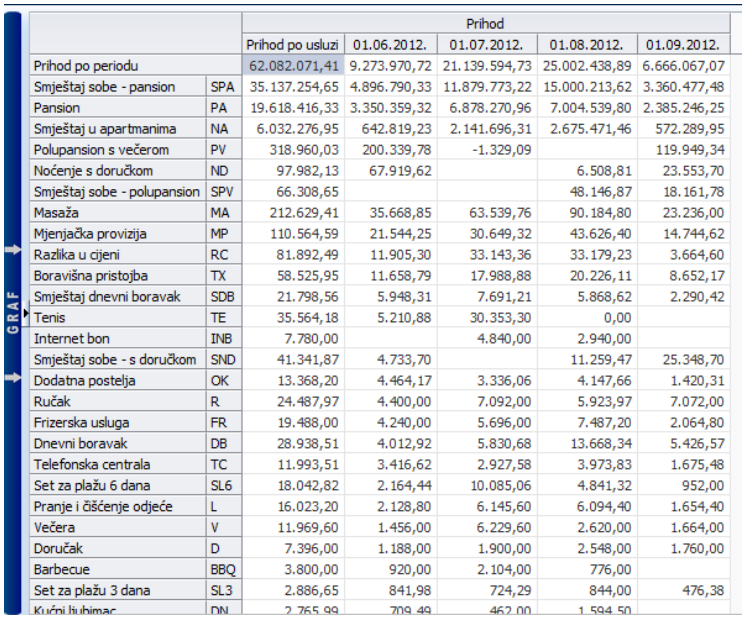
Slika 14. "Sierra", Prijenos datuma iz jednog u drugi pregled

Izvor: Samostalna izrada autora

Prijenos varijabli datuma dobiven je korištenjem „setPropertyListener“ svojstva objekta koji je postavljen na dugme 'Pretraži' za svaku od varijabli datuma te se prilikom otvaranja stranice, ukoliko postoje, varijable pune u datumska polja. Za tablicu koja prikazuje NETO prihod po uslugama načinjen je VO koji povezuje tablice IREC_ZURDW_SZURU i S_USLUGE. SQL upit je slijedeći:

```
SELECT trunc(datum,:vPeriodika)AS periodi, t2.sifra, t2.naziv AS usluga,
            SUM(t1.izn_prihoda_knj) AS prihod
FROM    irec_zurdw_szuru t1, s_usluge t2
WHERE t1.usl_id = t2.id
AND      t1.datum BETWEEN :vPoc AND :vKraj
GROUP BY t2.sifra, t2.naziv, trunc(datum,:vPeriodika)
ORDER BY periodi
```

Za zadano vremensko razdoblje i mjesečnu periodiku tablica koja sumira prihode izgleda ovako:



		Prihod				
		Prihod po usluzi	01.06.2012.	01.07.2012.	01.08.2012.	01.09.2012.
Prihod po periodu		62.082.071,41	9.273.970,72	21.139.594,73	25.002.438,89	6.666.067,07
Smještaj sobe - pansion	SPA	35.137.254,65	4.896.790,33	11.879.773,22	15.000.213,62	3.360.477,48
Pansion	PA	19.618.416,33	3.350.359,32	6.878.270,96	7.004.539,80	2.385.246,25
Smještaj u apartmanima	NA	6.032.276,95	642.819,23	2.141.696,31	2.675.471,46	572.289,95
Polupansion s večerom	PV	318.960,03	200.339,78	-1.329,09		119.949,34
Noćenje s doručkom	ND	97.982,13	67.919,62		6.508,81	23.553,70
Smještaj sobe - polupansion	SPV	66.308,65			48.146,87	18.161,78
Masaža	MA	212.629,41	35.668,85	63.539,76	90.184,80	23.236,00
Mjenjačka provizija	MP	110.564,59	21.544,25	30.649,32	43.626,40	14.744,62
Razlika u cijeni	RC	81.892,49	11.905,30	33.143,36	33.179,23	3.664,60
Boravišna pristojba	TX	58.525,95	11.658,79	17.988,88	20.226,11	8.652,17
Smještaj dnevni boravak	SDB	21.798,56	5.948,31	7.691,21	5.868,62	2.290,42
Tenis	TE	35.564,18	5.210,88	30.353,30	0,00	
Internet bon	INB	7.780,00		4.840,00	2.940,00	
Smještaj sobe - s doručkom	SND	41.341,87	4.733,70		11.259,47	25.348,70
Dodatna postelja	OK	13.368,20	4.464,17	3.336,06	4.147,66	1.420,31
Ručak	R	24.487,97	4.400,00	7.092,00	5.923,97	7.072,00
Frizerska usluga	FR	19.488,00	4.240,00	5.696,00	7.487,20	2.064,80
Dnevni boravak	DB	28.938,51	4.012,92	5.830,68	13.668,34	5.426,57
Telefonska centrala	TC	11.993,51	3.416,62	2.927,58	3.973,83	1.675,48
Set za plažu 6 dana	SL6	18.042,82	2.164,44	10.085,06	4.841,32	952,00
Pranje i čišćenje odjeće	L	16.023,20	2.128,80	6.145,60	6.094,40	1.654,40
Večera	V	11.969,60	1.456,00	6.229,60	2.620,00	1.664,00
Doručak	D	7.396,00	1.188,00	1.900,00	2.548,00	1.760,00
Barbecue	BBQ	3.800,00	920,00	2.104,00	776,00	
Set za plažu 3 dana	SL3	2.886,65	841,98	724,29	844,00	476,38
Kućni ljubimac	DN	2.765,99	709,49	462,00	1.594,50	

Slika 15. "Sierra", Tablični prikaz prihoda po uslugama

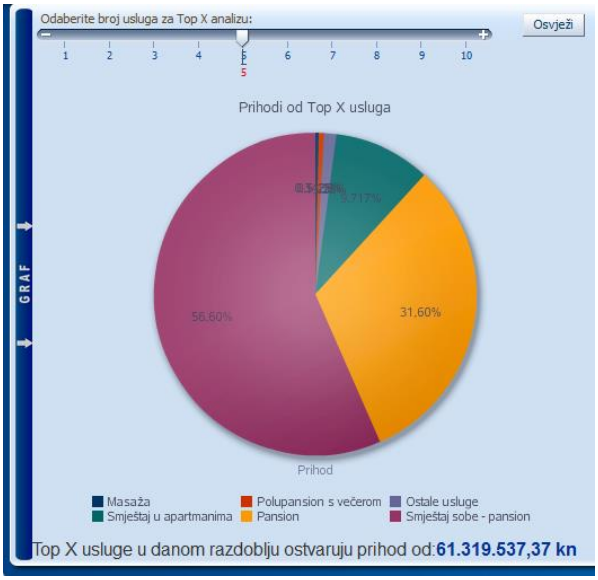
Izvor: Samostalna izrada autora

U grafikonu koji se nalazi lijevo od tablice prikazuju se identični podaci, no ograničeni na 10 najprofitabilnijih prihoda. Budući da usluge sadrže velik broj stavaka što je prikazano u PIVOT tablici podaci u grafikonu bez ograničenja prikaza ne bi bili korisni ni čitljivi. Kada se pokrene grafikon prikazuje se top 5 usluga, no moguće je smanjiti ili povećati opseg prikaza od 1 do 10. Ostale usluge koje ne ulaze u top X se sumiraju i prikazuju na grafikonu pod „Ostale usluge“. SQL upit za grafikon izgleda ovako:

```
SELECT  MIN (CASE WHEN  r_num <= :vBroj THEN  usluga
                ELSE  'Ostale usluge'
                END) AS usluge,
            SUM (prihod) AS prihod
FROM    (SELECT usluga, SUM (pr) AS prihod,
                        LEAST (ROW_NUMBER () OVER (ORDER BY SUM (pr) DESC),
                        :vBroj+1) AS r_num
            FROM (SELECT SUM(t1.izn_prihoda_knj) AS pr, t2.naziv AS usluga
                    FROM irec_zurdw_szuru t1, s_usluge t2
                   WHERE t1.usl_id = t2.id
                   AND t1.datum BETWEEN :vPoc AND :vKraj
                   GROUP BY t2.naziv
                   ORDER BY pr DESC)
             GROUP BY usluga)
GROUP BY r_num
ORDER BY prihod
```

U upitu se prvo sumiraju svi prihodi po usluzi u periodu i slažu od najvećeg prema najmanjem. Zatim vanjskim upitom izvlačimo uslugu, sumu prihoda i redni broj onih usluga koje su unutar odabranog zahtjeva, dok ostalima dajemo isti redni broj koji je za jedan veći od

zahtjeva i to grupiramo po usluzi. Potom još jednim upitom odabiremo redom od najmanjeg rednog broja uslugu i spremamo je tako dok ne dostignemo zahtjev, a ostale usluge sumiramo kao 'Ostale usluge', grupirano po rednom broju i posložimo po prihodu. Grafikon za odabrano vremensko razdoblje izgleda ovako:



Slika 16. "Sierra", grafički prikaz najboljih 5 prihoda

Izvor: Samostalna izrada autora

Ispod grafikona prikazan je zbroj top prihoda od usluga izražen u kunama dobiven pomoću slijedećeg SQL upita:

```
SELECT TO_CHAR (SUM(prihod),'999G999G990D99','NLS_NUMERIC_CHARACTERS
= ",."')||' kn' AS prihod
FROM (SELECT SUM(t1.izn_prihoda_knj) AS prihod, t2.sifra, t2.naziv AS usluga
        FROM irec_zurdw_szuru t1, s_usluge t2
        WHERE t1.usl_id = t2.id
        AND t1.datum BETWEEN :vPoc AND :vKraj
        GROUP BY t2.sifra, t2.naziv
        ORDER BY prihod DESC)
WHERE ROWNUM <= :vBroj
```

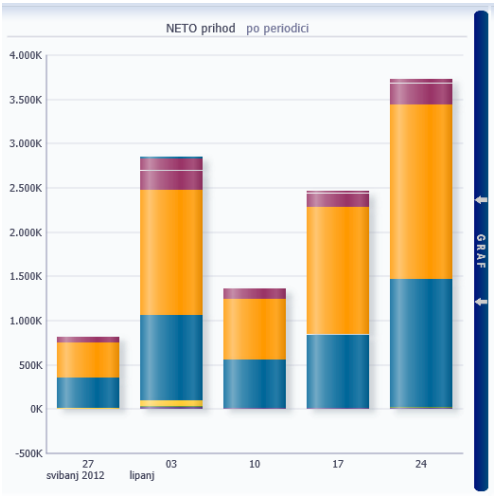


Slika 17. "Sierra", sumirani prihod od najboljih x usluga

Izvor: Samostalna izrada autora

Gornjim unutarnjim SQL upitom prvo se sumiraju prihodi po usluzi za neko razdoblje, a onda se vanjskim upitom ti prihodi po usluzi sumiraju u jedinstveni prihod, ali samo dok ne dođemo do ograničenja koje postavljamo varijablom :vBroj, te se usput formatira za ispis.

Desno od tablice smješten je stupčasti grafikon koji prikazuje sumu prihoda za odabrano razdoblje po periodici. U priloženom ekranskom prikazu prikazana je suma prihoda svih usluga prikazanih, po mjesecima (budući da je u ovom slučaju odabrana mjesečna periodika), unutar odabranog razdoblja.



Slika 18. "Sierra", Suma prihoda u stupčastom grafikonu

Izvor: Samostalna izrada autora

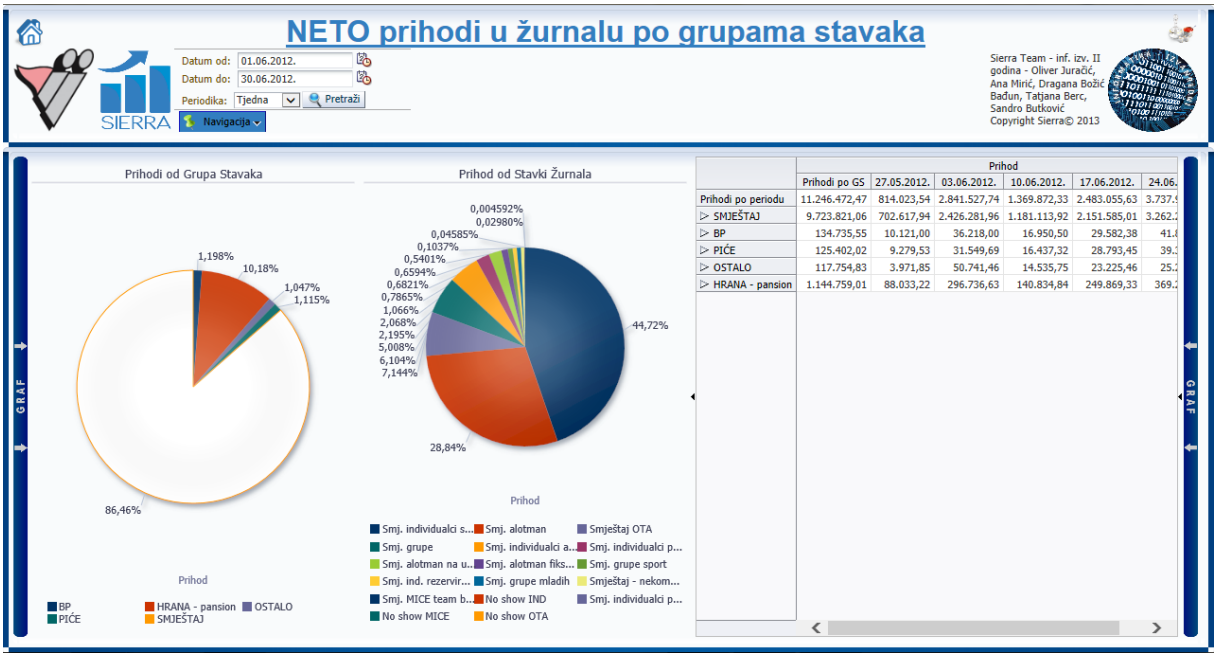
SQL upit za ovu vrstu grafikona je slijedeći:

```
SELECT TRUNC(datum,:vPeriodika) AS periodi,
            SUM(t1.izn_prihoda_knj) AS prihod
FROM     irec_zurdw_szuru t1,
            s_usluge t2
WHERE t1.usl_id = t2.id
AND      t1.datum BETWEEN :vPoc AND :vKraj
GROUP BY trunc(datum,:vPeriodika)
ORDER BY periodi
```

Ovaj upit je u osnovi identičan upitu kojim je dobivena tablica osim što je izostavljena šifra, a jedini razlog zašto se nije koristio već postojeći VO leži u načinu na koji je dijagram prikazivao podatke kada su u upit bile uključene šifre. Ovako je dobiven čišći izgled grafikona.

Sve stranice osim stranice NETO prihoda po grupama stavaka imaju grafikone izrađene na isti način pomoću upita u kojima su mijenjani samo nazivi tablica na koje se odnose. Stranica koja prikazuje NETO prihod po grupama stavaka ima grafikon s mogućnosti

„master-detail“ pregleda. Zato je kreiran „view link“ koji povezuje 2 SQL upita. U ovom slučaju na lijevom grafikonu smo označili SMJEŠTAJ, a na desno se prikazuje grafikon koji detaljno prikazuje vrste smještajnih jedinica te postotak prihoda po svakoj smještajnoj jedinici. Također je omogućeno 'drillanje' u pivot tablici po grupama stavaka prema stavkama žurnala.



Slika 19. "Sierra", master-detail prikaz grafa

Izvor: Samostalna izrada autora

SQL upit za lijevi grafikon glasi:

```
SELECT SUM(t1.izn_prihoda_knj) AS prihod,
            t3.naziv AS grupe_stavaka,
            t3.id
FROM     irec_zurdw_szuru t1,
            s_szurnala t2,
            szmp_gszurnala t3
WHERE t1.szur_id = t2.id
AND      t2.zmpgszur_id = t3.id
AND      t1.datum BETWEEN :vPoc AND :vKraj
GROUP BY t3.naziv,t3.id
ORDER BY grupe_stavaka
```

Za desni grafikon SQL upit glasi:

```
SELECT SUM(t1.izn_prihoda_knj) AS prihod, t2.naziv AS stavka_zurnala,
                    t2.zmpgszur_id AS idgs
FROM     irec_zurdw_szuru t1, s_szurnala t2
WHERE  t1.szur_id = t2.id
AND       t1.datum BETWEEN :vPoc AND :vKraj
GROUP BY t2.naziv,t2.zmpgszur_id
ORDER BY prihod DESC
```

Ostali zadaci napravljeni su na potpuno isti način, samo su se u upitima koristile druge tablice, stoga će se daljnji opis odnositi na posljednji zadatak, tj. pivot tablicu.

3.4.2 Izrada pivot tablice

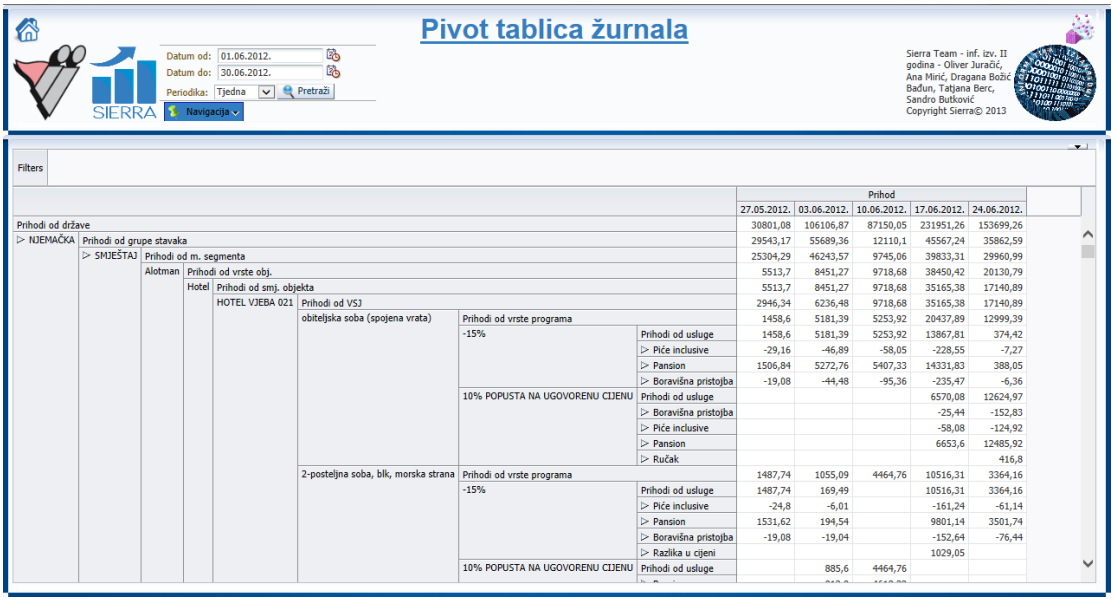
U pivot tablici su vidljivi svi NETO prihodi ostvareni u zadanom vremenskom razdoblju.

SQL upit za pivot tablicu glasi:

```
SELECT trunc(datum,:vPeriodika) AS periodi,
      SUM(t1.izn_prihoda_knj) AS prihod,
      t2.naziv AS marketinski_segment,
      t3.naziv AS drzava,
      t4.naziv AS agencija,
      t5.naziv AS usluga,
      t6.naziv AS stavka_zurnala,
      t7.naziv AS grupe_stavaka,
      t8.naziv AS dobne_grupe_gostiju,
      t9.naziv AS vrste_programa,
      t10.naziv AS smještajni_objekt,
      t11.naziv AS vrsta_objekta,
      t12.naziv AS vrsta_smjestajne_jedinice
FROM irec_zurdw_szuru t1,
    m_msegmenti t2,
    s_zemlje t3,
    m_agencije t4,
    s_usluge t5,
    s_szurnala t6,
    szmp_gszurnala t7,
    mrec_gdgostiju t8,
    mrec_vprograma t9,
    m_so t10,
    s_vuo t11,
    s_vsj t12
WHERE t1.ms_id = t2.id
```

```
    AND t1.ms_id = t2.id
    AND t1.zem_id = t3.id
    AND t1.age_id = t4.id
    AND t1.usl_id = t5.id
    AND t1.szur_id = t6.id
    AND t6.zmpgszur_id = t7.id
    AND t1.recgdgost_id = t8.id
    AND t1.recvpro_id = t9.id
    AND t1.so_id  = t10.id
    AND t10.vuo_id = t11.id
    AND t1.vsj_id =t12.id
    AND t1.datum BETWEEN :vPoc AND :vKraj
GROUP BY trunc(datum,:vPeriodika),
      t2.naziv,
      t3.naziv,
      t4.naziv,
      t5.naziv,
      t6.naziv,
      t7.naziv,
      t8.naziv,
      t9.naziv,
      t10.naziv,
      t11.naziv,
      t12.naziv
ORDER BY periodi
```

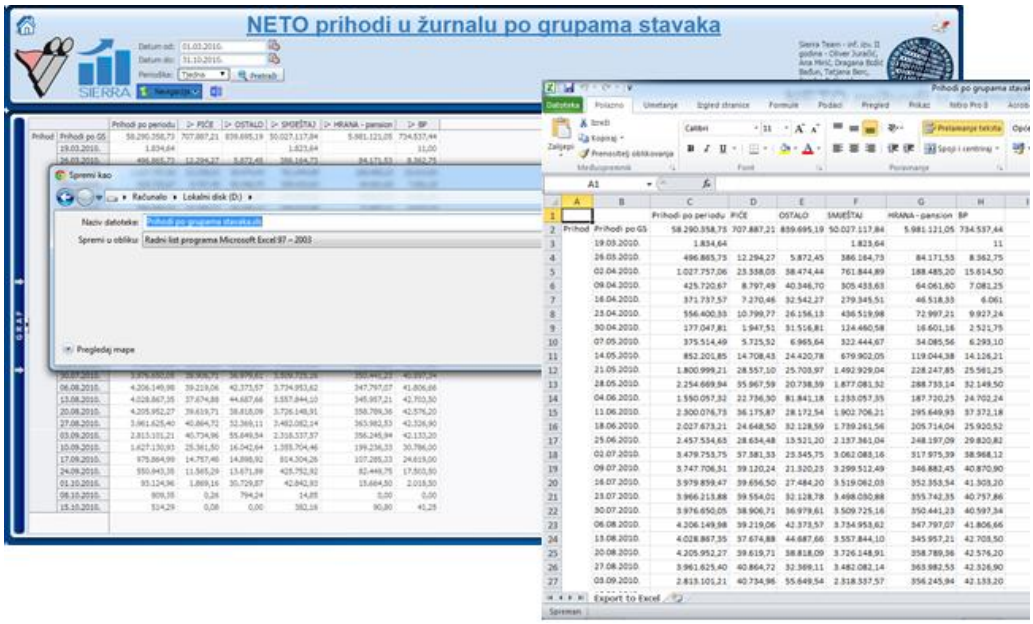
Ovaj upit na jednostavan način povezuje sve tablice prema primanim ključevima tabeli šifranta i vanjskim ključevima prometne tabele.



Slika 20. "Sierra", pivot tablica

Izvor: Samostalna izrada autora

U aplikaciju je uvrštena mogućnost izvoza u MS Excell

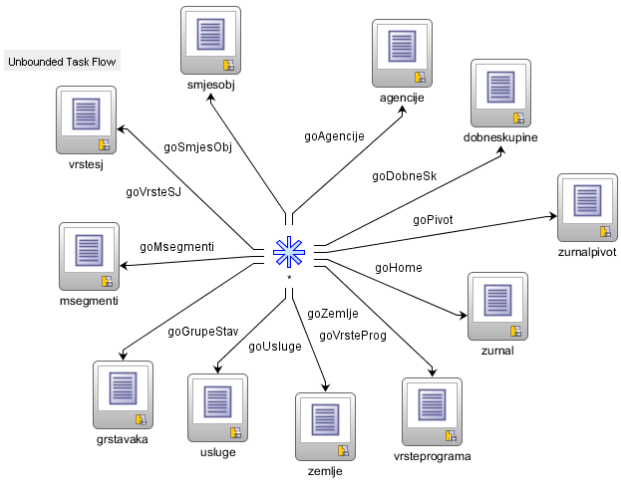


Slika 21. "Sierra", izvoz u MS Excel

Izvor: Samostalna izrada autora

3.4.3 Izrada stranica aplikacije

Nakon što su napravljeni odgovarajući SQL upiti, odnosno VO, krenulo se na izradu stranica aplikacije. U programu JDeveloper unutar View Controlera kreirane su JSF stranice aplikacije. Kreirano je 7 stranica povezanih na Wildcard (*). U JDeveloperu Wildcard služi kao agregator svih veza i koristimo ga da ne bismo morali povezivati svaku stanicu sa svakom. Stranice povezujemo pomoću Control Flow Casea koji služi za kreiranje veza između stranica. Svakoj vezi dano je ime npr. *goMSegmenti* zbog lakšeg snalaženja prilikom kreiranja izbornika.



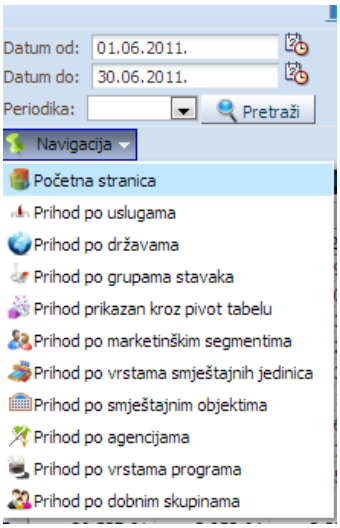
Slika 22. "Sierra", shema veze između stranica

Izvor: Samostalna izrada autora

Početna stranica se razlikuje od ostalih jer ne prikazuje podatke nego nudi izbornik koji vodi na slijedeće stranice: usluge,

- grupe stavaka,
- države,
- vrste programa,
- vrste smještajnih jedinica,
- agencije,
- marketinški segmenti,
- dobne skupine,
- smještajni objekte i
- pivot tabele žurnala.

Ostale stranice kao i naslovna napravljene su uspomoć ADF komponenata: Panel Stretch Layout, Decorative Box, Panel Splitter, Panel Border Layout, Panel Form Layout, Panel List, Output text i Button. Početna stranica sadrži poveznice na ostale stranice, a u ostalim stranicama je nadodan poseban navigacijski izbornik pomoću kojeg se može direktno pristupiti ostalim sadržajima.



Slika 23. "Sierra", navigacijski izbornik

Izvor; Samostalna izrada autora

4 ZAKLJUČAK

Kao i većini poslovnih organizacija, tako i u hotelskom poslovanju menadžeri su oni koji imaju najveće odgovornosti i ključni su za opstanak na tržištu. Oni moraju donositi odluke koje direktno utječu na poslovanje. Tradicionalno su se menadžeri hotelskih poduzeća pri donošenju odluka oslanjali na iskustvo, ali to je nešto za što, ako do toga uopće dođe, trebaju godine. Loša odluka, uzrokovana neiskustvom ili lošom informiranošću vodi do katastrofalnih rezultata. Odluke donesene na individualnom nivou manifestirat će se na cijelu organizaciju.

Tržišta više nisu gladna roba i usluga kao nekada. Proizvoda je više nego li postoji potrebe za njima. Isto je i sa turističkim uslugama. Konkurencija u cijelom svijetu raste. Opstati se može jedino nudeći kvalitetnije i nudeći ciljano. Implementacija poslovne inteligencije olakšat će pronalazak ciljanog. U primjeru jednostavne poslovne inteligencije hotelskog poduzeća moglo se naslutiti koliko je bitnih informacija lako dobiti, uz samo malo truda. Jednostavno je vidjeti koje dobne skupine donose najveći prihod i fokusirati se na njih kao na ciljanu skupinu. Lako je naslutiti koje zemlje i koje agencije nisu dovoljno zastupljene i pokušati ih privući na neki način, možda upravo ciljajući na dobnu skupinu koja je najprofitabilnija. Lako je uočiti nepravilnosti u prihodima uspoređujući mjesece i potražiti uzrok te anomalije. Ako je toliko mnogo moguće postići jednostavnim primjerom s kojim smo se mi susreli, koliko je tek moguće implementacijom ozbiljne poslovne inteligencije?
Implementacija poslovne inteligencije u hotelskom poslovanju ne treba stati na menadžerima. U radu je objašnjeno koliki je spektar primjene poslovne inteligencije u svim sferama poslovanja. Ona će u stvari omogućiti svim zaposlenicima s dovoljno informacija da donose dobre odluke, a to rasterećuje menadžment i olakšava rad svima.

Iz ovog rada da se zaključiti da bi uvođenje poslovne inteligencije u hotelsko, ali i bilo koje drugo poslovanje dovelo do smanjenja troškova, povećanja prihoda i zadovoljnijih korisnika.

LITERATURA

a) knjige

Mirko Bilandžić, Benjamin Čulig, Danijela Lucić, Martina Putar-Novoselec i Jelena Jakšić, „Business intelligence u hrvatskom gospodarstvu“, 2012

Javorović, B., Bilandžić, M., Poslovne informacije i business intelligence. Zagreb: Golden marketing-Tehnička knjiga, 2007

Successful Business Intelligence: Unlock the Value of BI & Big Data – Cindy Howson, Cpt.1, BI and Big Data from the Business side, McGraw-Hill Education; 2 edition (November 8, 2013)

Panian, Ž. et al.: Poslovna inteligencija – Studije slučajeva iz hrvatske prakse, Ekonomska biblioteka, Zagreb, 2007.

Krzysztof J. Cios , Witold Pedrycz, Roman W. Swiniarski: Data Mining and Knowledge Discovery, 2007

Introduction to OLAP, Seagate Info Technical Roadmap Series, Crystal Decisions, 2002

b) web

http://www.dresneradvisory.com/our-approach-to-research , kolovoz 2015.

https://www.gartner.com/doc/2715117/business-intelligence-performance-management-key, kolovoz 2015.

http://www.yellowfinbi.com/YFCommunityNews-Defining-Business-Intelligence-3-0-159445, kolovoz 2015.

https://www.capgemini.com/blog/capping-it-off/2012/07/bi-30-the-journey-to-business-intelligence-what-does-it-mean, kolovoz 2015.

http://www.ittechnewsdaily.com/203-business-intelligence-tools.html, kolovoz 2015.

http://searchdatamanagement.techtarget.com/definition/business-intelligence, kolovoz 2015.

http://searchsqlserver.techtarget.com/definition/data-warehouse, kolovoz, 2015.

https://en.wikipedia.org/wiki/Data_mining, kolovoz 2015.

http://docs.oracle.com/cd/B28359_01/datamine.111/b28129/process.htm,kolovoz 2015

https://technet.microsoft.com/en-us/library/hh916543.aspx, kolovoz 2015.

POPIS SLIKA

Slika 1. Howard Dresner 3
Slika 2. Evolucija poslovne inteligencije 8
Slika 3. Tijek razvoja poslovne inteligencije 10
Slika 4. William H. Inmon 12
Slika 5. Shema sustava poslovne inteligencije 13
Slika 6. Arhitektura skladišta podataka 14
Slika 7. Proces rudarenja podataka 17
Slika 8. OLTP „vs“ OLAP 20
Slika 9. Verzije OLAP-a 23
Slika 10. "Sierra", Početni zaslon 25
Slika 11. "Sierra", Relacijski model korištenog dijela baze podataka 28
Slika 12. "Sierra", prikaz odabira datuma 30
Slika 13. "Sierra", odabir periodike 31
Slika 14. "Sierra", Prijenos datuma iz jednog u drugi pregled 32
Slika 15. "Sierra", Tablični prikaz prihoda po uslugama 33
Slika 16. "Sierra", grafički prikaz najboljih 5 prihoda 34
Slika 17. "Sierra", sumirani prihod od najboljih x usluga 34
Slika 18. "Sierra", Suma prihoda u stupčastom grafikonu 35
Slika 19. "Sierra", master-detail prikaz grafa 36
Slika 20. "Sierra", pivot tablica 38
Slika 21. "Sierra", izvoz u MS Excel 39
Slika 22. "Sierra", shema veze između stranica 40
Slika 23. "Sierra", navigacijski izbornik 41

POPIS TABLICA

Tablica 1. Relacijska tablica koja sadrži podatke o prodaji 21
Tablica 2. Tablica 1. prikazana u obliku kocke 21
Tablica 3. Argumenti format parametra 30