PRIMJENA POSLOVNE INTELIGENCIJE U UNAPREĐENJU PERFORMANSI POSLOVANJA BANAKA

Stipić, Martina

Master's thesis / Diplomski rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Split, Faculty of economics Split / Sveučilište u Splitu, Ekonomski fakultet**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:124:772882

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

REFST - Repository of Economics faculty in Split

zir.nsk.hr

UNIVERSITY OF SPLIT

dabar

DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U SPLITU

EKONOMSKI FAKULTET SPLIT

DIPLOMSKI RAD

PRIMJENA POSLOVNE INTELIGENCIJE U UNAPREĐENJU PERFORMANSI POSLOVANJA BANAKA

Mentor:

dr.sc Roberto Ercegovac

Student:

univ.bacc.oec Martina Stipić

Split, kolovoz 2017

SADRŽAJ

1. UVOD 1

1.1 Problem istraživanja 1
1.2 Predmet istraživanja 2
1.3 Istraživačke hipoteze 2
1.4 Ciljevi istraživanja 3
1.5 Metode istraživanja 4
1.6 Doprinos istraživanja 5
1.7 Struktura diplomskog rada 5

2. POSLOVNA INTELIGENCIJA 7

2.1 Pojmovna definicija poslovne inteligencije 7
2.2 Pregled razvoja sustava poslovne inteligencije 11
2.3 Tehnički alati primjene 13
2.3.1 Skladište podataka 13
2.3.2 Rudarenje podataka 14
2.3.3 Online analitička obrada 15
2.4 Primijenjena poslovna inteligencija u poslovnim procesima 16

3. POSLOVNA INTELIGENCIJA U BANKARSTVU 20

3.1 Područja primjene poslovne inteligencije u bankovnoj firmi 20
3.2 Dimenzioniranje modela primjene 21
3.3 Raspoloživost podataka 24
3.4 Utjecaj primijenjene poslovne inteligencije na konkurentnost bankovne firme 26

4. PRIMJENA MODELA POSLOVNE INTELIGENCIJE U KLASIFIKACIJI RIZIČNIH GRUPA SEKTORA STANOVNIŠTVU 30

4.1 Opis uzorka istraživanja i definiranje ciljeva 31
4.1.1 Definiranje ciljeva i razumijevanje problema istraživanja 32
4.1.2 Opis uzoraka istraživanja 33
4.2 Definiranje modela i metoda primjene poslovne inteligencije 33
4.2.1 Metode primjene poslovne inteligencije 33
4.2.2 Model podataka 34
4.2.3 Dimenzije i hijerarhije 38

4.3 Rezultati istraživanja 41
4.3.1 Izvještavanje 41
4.3.2 Vizualizacija 44
4.4 Zaključne analize i primjena u poslovnoj praksi 46
4.5 Usporedba alata Excel i Tableau 48
4.6 Ključni doprinosi alata poslovne inteligencije u kontroli rizika 50

5. RIZICI I PERSPEKTIVE PRIMJENE SUSTAVA POSLOVNE INTELIGENCIJE 52

5.1 Pretpostavke efikasne primjene sustava poslovne inteligencije u poslovnim procesima i odlukama 52
5.2 Zaštita podataka i informacija 53
5.3 Perspektiva primjene poslovne inteligencije u unapređenju poslovanja i globalnom tržišnom natjecateljstvu 56

6. ZAKLJUČAK 59

LITERATURA 63

POPIS SLIKA 67

POPIS KRATICA 69

SAŽETAK 70

SUMMARY 71

1. UVOD

1.1 Problem istraživanja

Osnove teorije banke odnosno njezinu suštinu i bankarski mehanizam čini upravljanje rizicima odnosno upravljanje događajima koji bi mogli dovesti do neželjene situacije s obzirom na onu koja je očekivana. Rizici čine važnu komponentu u poslovanju svake bankarske institucije jer može se reći da nema situacije koja ne sadrži nekakvu neizvjesnost odnosno rizik. Problem ovog istraživanja je kako zapravo unaprijediti upravljanje rizicima koristeći poslovnu inteligenciju. Poslovna inteligencija je relativno mlad pojam za kojeg postoji više definicija al svaka se svodi na to da je poslovna inteligencija proces prikupljanja podataka, pretvaranje tih podataka u informacije koje su korisne za donošenje važnih odluka za poslovanje kompanije. Naime, danas smo svjedoci nevjerojatnog napretka u područjima upotrebe novih metoda koji donose inovacije i u poslovnom planu. Upravo sposobnost upravljanja podacima rezultira uspješnim upravljanjem poslovnih procesa banke. Primjena poslovne inteligencije ima za cilj uspješno rješavanje poslovnih problema kao i efikasno donošenje odluka na vrijeme koje su bazirane na informacijama koje su pouzdane i točne. Efikasnost znači da se cilj treba postići uz što manje ulaganja. Velike probleme koji se javljaju u bankarskom poslovanju čini ogromna količina podataka u transakcijskim bazama podataka. Ti podaci čine bogat izvor informacija te navedeni problem se može lako riješiti primjenom poslovne inteligencije te na taj način dolazi do poboljšanja poslovanja svake kompanije pa tako i banke.[1]

Problem ovog istraživanja predstavlja upravo problem postizanja cilja poboljšanja poslovanja bankarskog sektora te ulogu koju poslovna inteligencija zapravo ima u analizi ključnih poslovnih čimbenika u bankarstvu. Moderna tehnologija bazirana na informacijskim sustavima donosi poboljšanje značajki s naglaskom na kvalitetu podataka te banke koriste poslovnu inteligenciju kao priliku za ostvarenje konkurentne prednosti na današnjem tržištu.

[1] Ubiparipović,B.,Raković,L.(2011): Primjena sistema poslovne inteligencije u banci, Ekonomski fakultet Subotica, str 917-918.

Financijske institucije iz tog razloga iskorištavaju metode poslovne inteligencije analizirajući podatke te zadovoljavajući potrebe svojih klijenata.[2]

1.2 Predmet istraživanja

Predmet istraživanja ovog rada je kako poboljšati poslovanje banke primjenom informacijskih sustava zasnovanih na poslovnoj inteligenciji. Svrha diplomskog rada je zapravo istražiti i objasniti načine kojim današnje moderne banke mogu postići napredak u odlučivanju i svom cjelokupnom poslovanju koristeći upravo rješenja poslovne inteligencije. Istražit ćemo područja bankarskog sektora u kojima se sve mogu primijeniti metode poslovne inteligencije te utjecaj tih metoda na poboljšanje i unaprjeđenje bankarskog poslovanja.

1.3 Istraživačke hipoteze

Na temelju prethodno opisanog predmeta i problema istraživanja te analize različitih izvora podataka postavit ćemo hipotezu.

Temeljem prikupljanja podataka te istraživanjem hipoteza će se na kraju samog istraživanja prihvatiti ili odbaciti.

Hipoteza:

H1 ... Primjenom metoda poslovne inteligencije može se unaprijediti efikasnost upravljanja kreditnim rizicima u bankama.

Efikasnost se odnosi na interne ekonomske procese a može se definirati kao ostvarivanje ciljeva koristeći što je manje moguće raspoloživih resursa.[3] U ovom radu će se dokazati da je primjenom metoda poslovne inteligencije potrebno manje resursa i manje vremena za obradu i analizu mnoštva podataka o klijentima i njihovim kreditima. Koristeći alate poslovne inteligencije, na temelju prikupljanja internih i eksternih podataka te njihove analize dobit će se rezultati istraživanja na temelju kojih će se moći odlučivati o važnim pitanjima vezanim za

[2] Ljubetić, V.(2005): Upravljanje znanjem primjenom alata poslovne inteligencije, Ekonomski fakultet, Zagreb, str 66-69.

[3] Link group: Efikasnost i efektivnost: http://www.linkelearning.com/site/kursevi/lekcija/1138

kreditne rizike bankarske kompanije. Na ovaj način će se pokazati da se koristeći ove metode može unaprijediti postupak donošenja odluka i postići efikasnije upravljanje rizicima odnosno upravljanje događajima kojima bi se spriječila neželjena situacija.

1.4 Ciljevi istraživanja

Cilj ovog istraživanja je zapravo prilagoditi sustav poslovne inteligencije problemu upravljanja rizicima. U ovom radu pokazat ćemo kako adaptirati metode poslovne inteligencije na konkretan problem i kako taj primijenjeni model testirati i prilagođavati tom problemu.

Dokazivanjem istinitosti zadane hipoteze naš cilj se svodi na donošenje zaključka da se primjenom poslovne inteligencije može unaprijediti poslovanje banke.

Još jedan od ciljeva je taj da analizom postavljenih hipoteza trebamo dokazati kako se te metode mogu primijeniti u raznim područjima bankarskog sektora čime možemo poboljšati poslovne procese banke.

Navedeni ciljevi istraživanja postignut će se korištenjem metodološkog dijela koji je opisan u nastavku. Rezultati koji će se dobiti istraživanjem odnosnom analizom postavljene hipoteze služe u svrhu što boljeg prihvaćanja korištenja poslovne inteligencije u području upravljanja podacima što omogućuje efikasnije poslovanje banaka. Pod pojmom efikasnosti podrazumijevamo uspješnost ostvarivanja poslovnih ciljeva banke odnosno ostvarivanje najboljih mogućih rezultata uz minimalna ulaganja.[4] To znači da se poslovi koje obavlja banka trebaju raditi na pravi način, brzo i kvalitetno. [5]

[4] Gledović, M. (2015): Principi efikasnosti poslovanja poduzeća, sl. 1-2.

[5] EduCentar (2014): Znate li razliku između pojmova eikasnost i efektivnost, http://www.educentar.net/Vijest/11447/Znate-li-razliku-izmedju-pojmova-efikasnost-i

1.5 Metode istraživanja

Prilikom ovog istraživanja koristit će se različite istraživačke metode. Metodologija istraživanja u ovom radu dijeli se na dva dijela- teorijska analiza i empirijska analiza.

U teorijskom dijelu rada koristit ćemo stručnu i znanstvenu literaturu koja se odnosi na problematiku ovog istraživanja. Ova literatura odnosi se na već postojeće podatke odnosno sekundarne podatke koje smo prikupili iz različitih izvora.

Metode koje će se koristiti su:

- Komparativna metoda: Metoda pomoću koje ćemo uspoređivati sličnosti i razlike u ponašanju, procesima i pojavama banke koja koristi metode poslovne inteligencije i banke koja ne koristi. Primjenom ove metode možemo usporediti poslovanje te razvoj dviju banaka. Ova metoda zahtjeva veliku preciznost i opreznost u obradi podataka kao i u donošenju zaključaka.
- Induktivna i deduktivna metoda: Metode koje ćemo koristiti radi donošenja zaključaka i dokazivanja. Koristeći induktivnu metodu, na temelju pojedinačnih zapažanja doći ćemo do općih zaključaka, dok deduktivnom metodom ćemo izvesti posebne stavove iz općih zaključaka. Primjenom ovih metoda donijet ćemo zaključak o efikasnosti primjene poslovne inteligencije u poslovnim procesima banke.
- Metoda analize i sinteze: Analizom se naziva svako raščlanjivanje složenih dijelova na jednostavnije dijelove, dok sintezu možemo definirati kao spajanje više dijelova u jednu cjelinu. Ovom metodom analizirat ćemo sam pojam poslovne inteligencije, alate koji se mogu primijeniti u poslovnim procesima banke i njihov utjecaj na poboljšanje poslovanja.[6]
- Metoda deskripcije: Ovu metodu ćemo koristiti kako bi opisali važnija obilježja te odnose nekih procesa u banci.
- Statistička metoda: U ovom radu ćemo provesti pojedinačna statistička istraživanja kojim ćemo dokazati zadanu hipotezu.

[6] Metode znanstvenog istraživanja: http://www.pfri.uniri.hr/~ines/MZiR/20132014%20Materijal%20za%20web/Znanstvene%20metode.pdf

- Metoda modeliranja: Pomoću ove metode pojednostavnit ćemo zadani problem na način da ćemo izraditi model primjene poslovne inteligencije u banci.

Empirijski dio zapravo služi za praktičnu primjenu. U analizi empirijskog dijela rada koristit će se rezultati primarnih i sekundarnih podataka.

Na samom kraju slijedi posljednja faza a to je faza koja spaja teorijski i empirijski dio istraživanja. Taj dio odnosi se na interpretaciju prikupljenih podataka te na samom kraju donošenje zaključka istraživanja i konačnog izvještaja rada.

1.6 Doprinos istraživanja

Današnje banke žele prilagoditi odnosno povezati napredak u tehnološkom procesu poslovne inteligencije sa upravljačkim procesom u banci. Rezultati ovog istraživanja mogu uvelike pomoći u razumijevanju prednosti koje se ostvaruju uvođenjem poslovne inteligencije kao što su ušteda novca i vremena te mnoge druge prednosti. [7]

Isto tako svi znamo da se svakodnevno uvode nove metode koje možemo iskoristiti na poslovnom planu. Iz tog razloga, ovo istraživanje može poslužiti daljnjim, novim istraživanjima kao podloga u njihovim analizama na ovom području. Sve to ima za cilj stjecanje znanja kako bi se redovito unaprjeđivali poslovni procesi organizacija i naravno ostvarili njihovi poslovni ciljevi.[8]

1.7 Struktura diplomskog rada

Diplomski rad se sastoji od šest dijelova odnosno poglavlja. Prvo poglavlje je zapravo uvodni dio rada. Taj uvod sastoji se od problema, predmeta istraživanja, zatim postavljanja hipoteza, ciljeva istraživanja, metoda te doprinosa ovog istraživanja.

U drugom dijelu diplomskog rada razrađen je pojam poslovne inteligencije. Najprije je objašnjen i definiran pojam poslovne inteligencije kako bi bolje upoznali značenje ove, još

[7] Krstić, Ž. (2014): Big Data i semantička analiza-Iskorištavanje vrijednosti nestrukturiranih podataka u poslovanju, Ekonomski fakultet Split, str. 5-10.

[8] Vukušić, P,: Koncentracija banka, mjerenje i posljedice, str. 21.

uvijek mlade grane. Zatim slijedi povijest razvoja poslovne inteligencije gdje je opisano kako je uopće došlo do nastanka i kako je slijedio njen razvoj. Poslije toga prikazuju se tehnički alati poslovne inteligencije koji se primjenjuju u unaprjeđenju poslovanja. Nakon što se definirao sam pojam, opisali alati i povijest poslovne inteligencije, na samom kraju ostavljena je primjena poslovne inteligencije u poslovnim procesima.

U slijedećem poglavlju odnosno u trećem dijelu ovog istraživanja govori se o poslovnoj inteligenciji u bankarstvu. Najprije je opisano koja područja u banci primjenjuju poslovnu inteligenciju. Zatim slijedi dimenzioniranje modela primjene poslovne inteligencije u banci te raspoloživost podataka. Za sam kraj trećeg dijela donesen je zaključak o utjecaju primjene poslovne inteligencije na konkurentnost banke.

Primjena poslovne inteligencije u jednom od rizika banke nalazi se u četvrtom dijelu. U ovom poglavlju definiran je model i metode primjene poslovne inteligencije. Zatim slijedi opis uzoraka i definiranje ciljeva. Na temelju svega toga donesen je zaključak.

Iduće poglavlje govori o pretpostavkama unaprjeđenja koje donosi poslovna inteligencija u bankarstvu. Opisana je zaštita podataka i informacija koje posjeduje pojedina banka, te perspektivama primjene poslovne inteligencije u unaprjeđenju poslovanja banke.

I konačno zadnje , šesto poglavlje donosi zaključak ovog diplomskog rada. U ovom poglavlju navedeni su popis grafova, tablica i popis slika.

2. POSLOVNA INTELIGENCIJA

Poslovna inteligencija je danas jedan od važnijih komponenata u poslovnom svijetu svake suvremene kompanije. Iz tog razloga jako je važno prije svega proučiti i razumjeti značenje samog pojma poslovne inteligencije, povijest njenog razvoja kao i alate što je opisano u ovom poglavlju.

2.1 Pojmovna definicija poslovne inteligencije

Da bi poslovanje tvrtke bilo uspješno potrebno je ispuniti preduvjet planiranja, upravljanja i odlučivanja koji nisu mogući bez pristupa pravoj informaciji. Upravo ta informacija ima veliku važnost pri donošenju kvalitetnih poslovnih odluka i ostvarivanju strateških prednosti firme. Prikupljanje podataka i njihova analiza nekada je bio dugotrajan proces i predstavljao je pravi izazov za kompaniju koja je prije razvoja informacijskog doba svoje odluke donosila prema intuiciji. Neke odluke se i mogu donijeti na temelju jednostavnih informacija, no postoje i one za koje sadašnji oblik informacije ne može poslužiti za konačno odlučivanje. Upravo kod takvih odluka potrebno je taj neobrađeni oblik informacije obraditi i filtrirati što ne predstavlja jednostavan proces zbog ogromne količine podataka. Kako bi se sam taj proces olakšao odnosno kako bi se zadovoljile informacijske potrebe kompanije dolazi do razvoja poslovne inteligencije. Prije nego napišemo njenu definiciju, važno je objasniti značenje riječi inteligencija koja se obično definira kao sposobnost snalaženja u novim situacijama.

Prijevod ovog pojma sa engleskog jezika (engl. „Business Intelligence“) u Hrvatskoj se prevodi kao poslovna inteligencija iako, najtočniji prijevod je vjerojatno poslovno izvještavanje. Riječ inteligencija (engl. Intelligence) ima dva značenja: sposobnost razumijevanja, učenja i logičkog razmišljanja te tajna informacija o stranoj zemlji koju osobe skupljaju.

Prema Rječniku hrvatskog jezika inteligencija je definirana kao oštroumnost i pamet, odnosno kao sposobnost brzog snalaženja u novim prilikama i sposobnost brzog shvaćanja.[9]

[9] Luetić, A., Šerić,N.(2009): Business Intelligence u funkciji upravljanja nabavnim lancem, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 27.

Definicija pojma poslovne inteligencije definirana je od strane različitih autora na različite načine, no svi imaju isti smisao a to je prikupiti sirove podatke, pretvoriti ih u informacije i donijeti poslovne odluke. Jedna od definicija kaže da je poslovna inteligencija proces prikupljanja raspoloživih internih i relevantnih eksternih podatka, te njihove konverzije u korisne informacije koje mogu pomoći poslovnim korisnicima pri donošenju odluka. Radi se o procesu prikupljanja informacija i znanja o konkurenciji, dobavljačima, kupcima i prikupljanju podataka o procesima neke kompanije. Na taj način se može kvalitetno planirati i predviđati buduće pojave, također pratiti ponašanje konkurencije i promatrati tržišne segmente. Najšira definicija ovog pojma kaže da poslovna inteligencija predstavlja obavještajnu aktivnost u poslovnom svijetu, koju planiraju, organiziraju i provode poslovni subjekti, pri čemu ta aktivnost podrazumijeva proces legalnog prikupljanja podataka, njihovu analizu i pretvaranje u gotove, upotrebljive informacije, radi pružanja potpore menadžmentu poslovnog subjekta, s ciljem donošenja i realizacije što kvalitetnijih poslovnih odluka.

Dakle, radi se o načinu prikupljanja i analize informacija o konkurenciji kako bi se budući poslovni trendovi mogli planirati. Ukoliko se posjeduju prave informacije, ti planovi će biti učinkoviti.[10] Može se kazati kako poslovna inteligencija objedinjuje metodologije za skladištenje, procesuiranje i rudarenje podataka s ciljem dobivanja informacija o poslovanju. Odnosno, obrada i transformiranje informacija u kvalitetne podatke na korisnicima razumljiv način. Dakle, poslovna inteligencija predstavlja sustav aktivnog korištenja znanja koje se pretvara u aktivnost i neprestano je u potrazi za novim informacijama s ciljem postizanja ciljeva organizacije. Kako bi razumjeli značenje poslovne inteligencije treba razumjeti razliku između znanja koje nastaje spajanjem informacija i između inteligencije koja predstavlja informaciju koja je pročišćena i spremna za donošenje odluka. [11]

Obilježja koncepta poslovne inteligencije:

- glavni cilj poslovne inteligencije nije prikupiti što više informacija već prikupiti informacije koje su kvalitetne za donošenje poslovnih odluka,

[10] Pfeifer, S., Alpeza, M.: Business Intelligence, Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet u Osijeku, Osijek, 2011., str. 5-6.

[11] Pfeifer, S., Alpeza, M. Op.cit, str 2.

- pruža pravim korisnicima samo one informacije koje su im potrebne i to u obliku koji im je najkorisniji odnosno koji im najviše odgovara,
- smanjuje veliku količinu podataka i povećava njihovu kvalitetu

Osnovne značajke poslovne inteligencije:

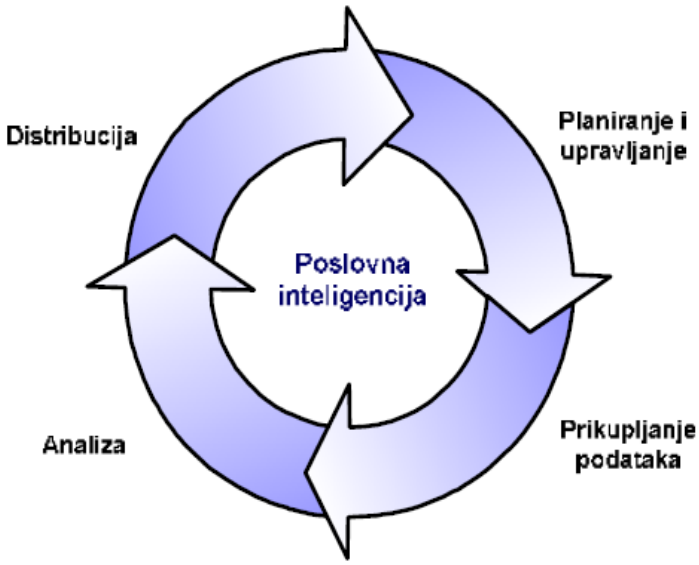
- pro aktivnost- usmjerena je prema postizanju ciljeva organizacije,
- personalizacija- dostavljanje informacija ciljanim korisnicima,
- nastaje iz operativnih podataka.

Sustav poslovne inteligencije koristi tehnologije za prikupljanje i analizu podataka i na taj način dobivaju informacije koje utječu na njihovo poslovanje.

Poslovna inteligencija predstavlja ciklus koji je kontinuiran i stalan i poduzeća tu postavljaju svoje ciljeve, analiziraju svoj napredak, poduzimaju radnje i mjere uspješnost. Radi se o procesu kod kojeg nema konačnih odgovora i koji nema kraj.[12] Taj proces se sastoji od različitih faza. Prva faza je faza u kojoj kompanije postavljaju svoje ciljeve odnosno faza planiranja. Iduća faza je faza u kojoj se podaci prikupljaju. Nakon toga slijedi analiza tih podataka s ciljem identificiranja trendova te predviđanja potencijalnih mogućnosti i prepreka. Zadnja faza je faza distribucije odnosno dostavljanja podataka onima koji donose odluke. Taj ciklus ipak ne završava ovom fazom već se dalje nastavlja zadajući nove ciljeve i postavljajući nova pitanja.[13]

[12] Luetić, A.,Šerić N, Op.cit, str. 54.

[13] Nadrljanski M, (2013): Specifičnosti razvoja sustava poslovne inteligencije, Sveučilište u Splitu, Pomorski fakultet, Split, str 9.



Slika 1: Ciklus poslovne inteligencije

Izvor: Luetić, A., Šerić, N.: Business Intelligence u funkciji upravljanja nabavnim lancem, Sveučilište u Splitu, Ekonomski fakultet, Split, 2009.

Proces poslovne inteligencije započinje izgradnjom skladišta podataka. Skladište podataka je zapravo jedna centralna baza podataka u koju dolaze sve informacije koje su se prikupile unutar samog poduzeća i podaci prikupljeni izvan poduzeća odnosno u njegovoj okolini. Nakon prikupljanja podataka slijedi proces ekstrakcije, transformacije i proces punjenja podataka. Završetkom tih procesa podaci su spremni za analize.[14]

Sustav poslovne inteligencije pomaže nam pratiti sve bitne informacije vezane o poslovanju kao što su informacije o tržištu, kupcima, partnerima kako bi bolje razumjeli njihovo ponašanje. Iz tog razloga pohranjuje te informacije koje se pretvaraju u oblik koji je vizualno prihvatljiv te ih se podliježe procesu analize kako bi se omogućilo kvalitetno planiranje.[15]

Poslovna inteligencija, kao znanje izvedeno iz tih podataka, zapravo nije i ne može biti homogena kategorija, već sadrži određene podskupine, podvrste ili komponente inteligencije

[14] Nadrljanski M, Op.cit, str 17-18.

[15] Mit Software: Općenito o Business intelligence sustavima: http://www.mit-software.hr/usluge/bi/bi1/

koje u svojoj ukupnosti čine ono što smatramo i nazivamo poslovnom inteligencijom.[16] Poslovnu inteligenciju čine četiri osnovne komponente:

- infrastruktura – skladište podataka, alati za transformaciju i punjenje podataka (engl. extraction, transformation and loading - ETL), operativno spremište podataka,
- funkcionalnost – platforme poslovne inteligencije, rudarenje podataka (engl. data mining, aplikacije poslovne inteligencije (operativne, strateške, analitičke), izvještavanje koje ima određenu svrhu (engl. ad–hoc izvještavanje),
- organizacija – mjerenje performansi, informacijska/korporativna kultura, metodologije poslovne inteligencije, centar poslovne inteligencije (objedinjavanje znanja i vještina),
- poslovanje – ključni pokazatelji uspješnosti, trendovi, transparentnost.[17]

Današnje kompanije kao rezultat zaoštravanja konkurencije i izbirljivosti kupaca nailaze na razne zahtjeve svog poslovanja te se u takvim situacijama moraju održati u tržišnoj utakmici. Iz tog razloga banke i sve ostale kompanije ulažu sredstva u rješenja poslovne inteligencije koja im pomaže u rješavanju ovih problema a sve to kako bi ostvarili cilj dobrog poslovnog odlučivanja.[18]

2.2 Pregled razvoja sustava poslovne inteligencije

Poslovna inteligencija postojala je prije tehnologije i koristila se u različitim područjima života već tisućama godina. Povijesne preteče poslovne inteligencije su vojna inteligencija (umijeće vođenja strategije snalaženja na nepoznatim okruženjima), zaštita državne sigurnosti (različiti oblici zaštite nacionalne sigurnosti), te zaštita unutrašnje sigurnosti (različite forme kojima se osigurava poštivanje zakona i zaštita poretka). Još u vrijeme davne povijesti borba za preživljavanje u turbulentnoj okolini oduvijek se svodila na traženje i korištenje informacija. Prvi koji su skupljali informacije bili su vladari, vojskovođe i bankari. Tada je cilj bio dobiti bitku ili rat dok danas se taj cilj promijenio i okrenuo se prema ostvarivanju

[16] Panian, Ž. et al.: Poslovna inteligencija – Studije slučajeva iz hrvatske prakse, Ekonomska biblioteka, Zagreb, 2007., str. 2.

[17] Ljubetić, V. Op.cit, str. 87.

[18] Varga, M.: Poslovna inteligencija: Ciljevi i metode, Ekonomski fakultet Zagreb,str 1.

konkurentske prednosti gdje glavno oružje u tom poslovnom ratovanju postaje znanje. Ono što se promijenilo kod poslovne inteligencije od njenog nastanka do danas su korisnici, i ciljevi prikupljanja. Informacije prenose znanstvene spoznaje i njihovim sređivanjem nastaje znanje.[19] Poslovne informacije važne su za ostvarenje poslovnih interesa kompanije i iz tog razloga danas su neizostavan dio svakog poslovanja.[20] Sun Tzu u svom djelu „Umijeće ratovanja" navodi da će mudri vladar pobijediti svog neprijatelja ako može unaprijed predviđati. Odnosno onaj tko ima informaciju ima moć.

To da je informacija i kroz povijest bila važna govori otkriće da se prva pisana riječ pojavila prije 5000 godina. Također, 280. pr. Kr. knjižnica u Aleksandriji imala je 700 000 dokumenata.[21] Venecija je imala najjaču snagu između X. i XII. stoljeća jer su stvorili dobro organiziranu mrežu informatora diljem Europe. Isto tako, Dubrovačka Republika je 1301. godine formirala centar za skupljanje informacija o politici, gospodarstvu i vojsci drugih zemalja. Korijeni poslovne inteligencije leže u vojnom planiranju. U poslovanju se javljaju 60-ih godina a prava ekspanzija se dogodila 80-ih godina.[22]

Pojam poslovna inteligencija (engl. „Business Intelligence") prvi put je spomenuo Howard Dresner 1989. godine s ciljem kategorizacije metoda koji služe kako bi se donosile odluke.

S vremenom dolazi do razvoja tehnologije (računala, razvoj interneta ...) koja mijenja način donošenja odluka. Razvojem tehnologije dolazi do migracije poslovne inteligencije na internet i stvaranja web aplikacija te poslovna inteligencija postaje dostupna i na mobilnim uređajima.[23]

[19] Pfeifer, S., Alpeza, M. Op.cit, str 8-9.

[20] Alfirević N. (2008): Poslovne informacije i Business intelligence, Sveučilište u Splitu, Ekonomski fakultet, Split, sl. 1-7.

[21] Alfirević N. (2008): Poslovna inteligencija, uvod u teoriju informacija, Sveučilište u Splitu, Ekonomski fakultet, sl 2-9.

[22] Luetić, A., Šerić,N. Op.cit, str. 15.

[23] Dukić,B. ,(2014): Alati poslovne inteligencije, sl. 2.

Nastanak poslovne inteligencije mnogi autori vežu uz sustave za potporu odlučivanju (engl. Decision support system - DSS) čiji je cilj podržavati poslovne procese donošenja odluka.[24] Poslovna inteligencija započinje svoj veliki razvoj u trenutku kada su kompanije automatizirale svoje procese što se jako dobro pokazalo u generiranju velikih količina podataka. S vremenom se povećava važnost informacija i dolazi do gomilanja podataka do kojih se nije moglo jednostavno doći s obzirom da su se stalno formirale nove baze. Svijest o vrijednosti i potencijalu tih podataka naglo je rasla i bilo ih je potrebno obraditi i omogućiti da budu raspoložive donositeljima odluka. Iz tog razloga dolazi do evolucije informacijskih sustava koji su uvelike olakšali i poboljšali donošenje odluka u kompanijama.[25]

2.3 Tehnički alati primjene

Pod alatima koji se primjenjuju za poslovnu inteligenciju smatra se skup aplikacija i metodologija čiji je zadatak pretvoriti prikupljeni podatak u informaciju korisnu za donošenje kvalitetnih poslovnih odluka. Ti alati ne postoje kao gotovi proizvodi već se prilagođavaju potrebama korisnika jer svaka kompanija zahtjeva posebna rješenja.[26]

2.3.1 Skladište podataka

Skladište podataka (engl. data werehouse) je proces integracije odnosno prikupljanja podataka u jedan repozitorij gdje ti podaci postaju dostupni krajnjim korisnicima u bilo koje vrijeme kako bi mogli dobiti izvještaje i raditi izvještavanje koje ima određenu svrhu (engl. Ad-hoc analize). Podaci koji se nalaze u skladištu podataka prikupljeni su iz različitih izvora. To su podaci koji su prikupljeni iz vanjskog okruženja, i povijesni podaci o poslovanju kompanije. Skladište podataka omogućuje dobivanje izvještaja, pretraživanje podataka i online analitičku obradu a ima važnu ulogu u podržavanju procesa donošenja odluka. Njihov glavni cilj je taj da donositelji odluka na brz i jednostavan način koriste lako dostupne podatke kako bi proveli analizu poslovanja. Sastoji se od nekoliko koraka procesa a to je planiranje, prikupljanje, građenje podataka, korištenje, upravljanje, održavanje i neprestano

[24] Glavaš J. (2008): Poslovna inteligencija, Ekonomski fakultet u Osijeku,str 3.

[25] Nadrljanski M, Op.cit, str 11-12.

[26] Ljubetić, V. Op.cit, str. 87.

unaprjeđivanje. Skladište podataka zapravo služi za razvijanje i korištenje znanja koje je zasnovano na podacima. Njegova struktura se sastoji od podataka i mehanizama manipulacije tim podacima. Podatke čine osnovni podaci i agregirani višedimenzijski podaci. Mehanizmi manipulacije se sastoje od više procesa a to su procesi ekstrakcije, transformacije i punjenja podataka (engl. extraction, transformation and loading- ETL), sustav upravljanja podacima, postupci analitičke obrade podataka i sama prezentacija podataka.[27]

2.3.2 Rudarenje podataka

Rudarenje podataka ili Data Mining predstavlja proces pronalaženja korisnog znanja unutar velike količine podataka. Rudarenjem se ti podaci čiste kako bi se lakše pristupilo znanju. Dakle, radi se o organiziranju, sortiranju i grupiranju velikog broja podataka i izvlačenju relevantnih informacija. To je skup metoda, alata i postupaka čiji je cilj otkrivanje zakonitosti i odnosa među podacima koristeći regresijske, ekonometrijske i statističke procedure. U obradi podataka najvažniju ulogu imaju računala bez kojih je obrada nemoguća.[28] Tehnike koje se koriste za rudarenje podataka rezultat su dugog procesa istraživanja i razvoja statističkih algoritama a te tehnike su : statističke metode, genetički algoritmi, neuralne mreže, stabla odlučivanja, umjetna inteligencija i asocijacijska pravila. Tri glavne metode rudarenja podataka su klasifikacija, klasteriranje i asocijacija.[29] Rudarenje podataka potpomognuto je s tri tehnologije koje su već dovoljno sazrele:

- moćnom multiprocesorskom kompjutorskom tehnologijom,
- tehnologijom za masivno prikupljanje podataka,
- algoritamskim tehnikama za rudarenje podataka.

[27] Ljubetić, V. Op.cit, str. 46.

[28] Rovčanin A.,Mataradžija A.,Mataradžija A.(2012): Upravljanje znanjem kroz primjenu alata poslovne inteligencije, str 611.

[29] Kruljac, F. (2016): Koncept poslovne inteligencije u suvremenim organizacijamaM, str 6.

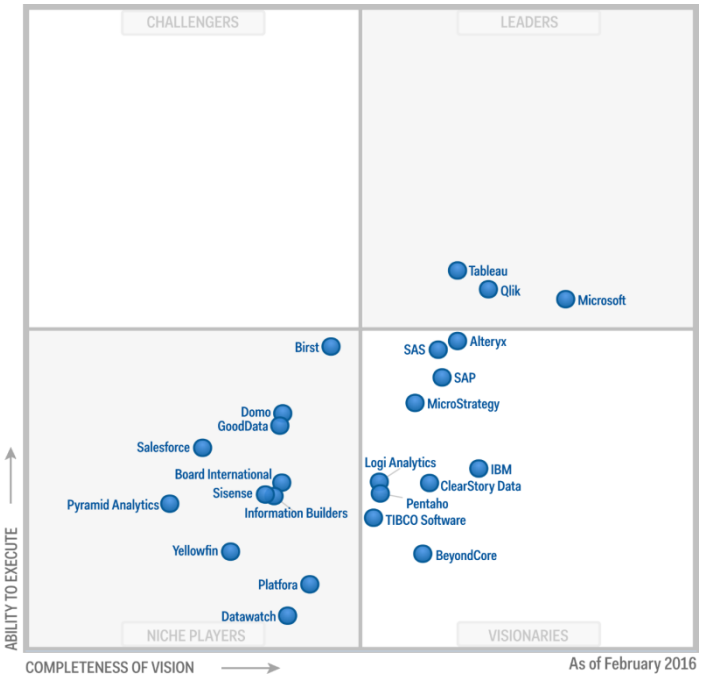
2.3.3 Online analitička obrada

Nakon izgradnje skladišta podataka svi podaci se slijevaju u jednu centralnu bazu podataka gdje prolaze kroz procese ekstrakcije, transformacije i punjenja. Završetkom tih procesa podaci su spremni za analize. Danas postoji mnogo mogućnosti kojima se mogu eksploatirati i vizualizirati podaci a najraširenija pristup predstavljaju multidimenzijske analize ili model OLAP alata. OLAP je engl. skraćenica za On-Line Analytical Processing a prevodi se kao „online analitička obrada". OLAP zapravo predstavlja skup alata i tehnologija koji se koriste za skupljanje, upravljanje, obradu i prezentaciju multidimenzijskih podataka koji imaju važnu ulogu u procesu donošenja odluka i upravljanja. Podaci se mogu istovremeno promatrati kroz veći broj dimenzija jer se model OLAP alata zasniva na sustavu multidimenzijske analize. Jako je lagano koristiti alate i za bavljenje ovim poslom korisnici ne trebaju biti posebno obučavani za korištenje. Velika brzina rada jedna je od karakteristika OLAP alata jer korisnici u kratkom vremenskom roku dobivaju odgovore na svoje upite. Radi se o sekundama, ovisno o jednostavnosti upita. Još jednu njihovu prednost čini sposobnost analiziranja velikog broja dimenzija. Također je specifično provođenje brzih analiza za određenu svrhu (engl. ad–hoc analiza) koje mogu generirati odgovore u stvarnom vremenu te na kraju dati njihov grafički prikaz. OLAP alati omogućuju interaktivno pretraživanje podataka, omogućuju korisnicima da iskoriste sve prednosti višedimenzijskog prikaza podataka, da promatraju podatke na različite načine, omogućuju modeliranje, analizu i vizualizaciju velikih količina podataka.[30] Osnovne strukture OLAP alata su : relacijski OLAP (ROLAP- engl. Relational OLAP), hibridni OLAP (HOLAP- engl. Hybrid OLAP), višedimenzijski OLAP (MOLAP-engl. Multidimensional OLAP).[31] Najpoznatiji proizvođači OLAP alata su prikazani ispod na slici broj dva. Uspoređujući te magične kvadrate iz godine u godinu, položaj OLAP proizvođača se neprestano mijenjao. Možemo primijetiti da su prema podacima iz 2016. godine glavni lideri Microsoft i Tableau. Svaki od ovih proizvođača ima svoje alate i nudi svoja rješenja koja se koriste u poslovnoj inteligenciji. Najpopularniji alati koji se najviše koriste su Tableau, Microsoft SQL Server, Excel i PowerPivot. Tehnologije nude razne mogućnosti kao što su

[30] Ljubetić, V. Op.cit, str. 88-89.

[31] Sovilj,D.(2004.): Business intelligence u nautičkom turizmu - implementacija OLAP sustava, str.9.

vizualizacija podataka, dizajniranje infografike. Nešto više o ovim alatima ćemo saznati u slijedećim poglavljima.



Slika 2: Magic Quadrant for Business Intelligence and Analytics Platforms

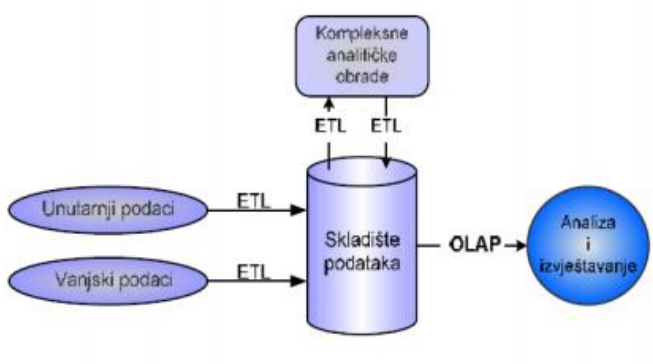
Izvor: Howson C., Oestreich T.W., Parentau J., Sallam R.L., Schlegel K., Tapadinhas J., (2016) Magic quadrant for business intelligence and analytics platforms

2.4 Primijenjena poslovna inteligencija u poslovnim procesima

Poslovna inteligencija se primjenjuje u svim funkcijama neke kompanije gdje ima doticaj sa svim zaposlenicima i može se primijeniti u svakoj industriji. Danas je brojne kompanije koriste u svojim poslovnim procesima na razini cijelog poduzeća.

Korištenje poslovne inteligencije se isplati kada je učinkovito korištena od strane ljudi jer posjedovanje podataka ne znači da će neka tvrtka postići poslovnu uspješnost već je potrebno

znati raditi s podacima koje ona posjeduje.[32] Danas sve više kompanija implementiraju poslovnu inteligenciju koju koriste u svojim poslovnim procesima. Pretvaraju prikupljene informacije u poslovnu inteligenciju a nju u znanje koje donosi profit. [33] Svaki poslovni proces sastoji se od više pojedinačnih poslovnih procesa i u svakom od njih poslovna inteligencija može podržavati odluke koje se donose, dakle može ubrzati proces, mjeriti koliko traje i ono najvažnije- pronaći područja koja se mogu poboljšati.



Slika 3. Shema sustava poslovne inteligencije

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

Poslovni sustavi kompanija danas su dosta složeni te potreba za uvođenjem i implementacijom ovih alata je velika. Potreba za uvođenjem poslovne inteligencije javlja se kao poslovna potreba nastala zbog dinamike poslovanja i zbog kompleksnosti koja ima kontinuiran rast.[34]

Uvođenje poslovne inteligencije u sustav poslovanja predstavlja kontinuirani proces koji nema završetak i koji se neprestano prilagođava novim uvjetima. Radi se o projektu koji zahtjeva poseban pristup i za kojeg je potrebno ostaviti dovoljno vremena. Postoji nekoliko

[32] Juračić O.,(2015): Sustavi poslovne inteligencije hotela, Sveučilište Jurja Dobrile u Puli Fakultet za ekonomiju i turizam „Dr.Mijo Mirkovic“, str. 4.

[33] Glavaš J. Op.cit, str.8.

[34] Ljubetić,V. Op.cit, str. 68.-69.

strategija implementacije poslovne inteligencije. Jedna od njih je da se uvede u one organizacije gdje će se najprije vidjeti rezultati i gdje se očekuju najmanji otpori. Glavnu ulogu u kvalitetnom uvođenju ima ljudski faktor. Prvi korak u procesu implementacije je planiranje, određivanje ciljeva koji se žele postići i definiranje problema koji se žele riješiti uvođenjem ovog sustava. Jako je važno sve zainteresirane strane aktivno uključiti u provedbu projekta. Nakon toga idući korak je definiranje poslovnih zahtjeva i izgradnja modela podataka. Osnova modela je zapravo proces i on je važan jer se njime određuju analitičke mogućnosti cijelog sustava. Prije uvođenja poslovne inteligencije, potrebno je ocijeniti izvodljivost ovog projekta nakon čega slijedi implementacija.

Svako prikupljanje, obrada podataka i davanje rješenja može se smatrati zasebnim procesom te sustav poslovne inteligencije je moguće prikazati kao dva međusobno povezana spiralna procesa. Svaka ta spirala je zapravo poslovni ciklus koji sadrži više spirala odnosno pod procesa. Razvoj poslovne inteligencije putem spiralnog pristupa se odvija u nekoliko faza. Počinje sa identifikacijom problema, procesuiranjem podataka i primjenom rudarenja podataka. Nakon toga idući korak je razvoj modela, primjena na testnom uzorku i na samom kraju slijedi mjerenje rezultata. Na ovaj način je omogućeno da se bude u toku sa odvijanjem procesa i mogućnošću njihovog mijenjanja.[35] Glavni razlog implementacije poslovne inteligencije je kako bi nam pomogla na brz i efikasan način izvući informacije koje su nam potrebne. Važno je definirati probleme koji se trebaju riješiti, i odrediti zahtjeve korisnika kao što su prikaz podataka, brzina i druge zahtjeve koji su potrebni kako bi se dobio kvalitetan rezultat. Sustav poslovne inteligencije jako je težak i unosi veliku promjenu u kompaniju. Važno je da ovaj sustav ima i političku potporu unutar kompanije koja je u biti glavni razlog ukoliko dođe do propadanja ovog projekta. Implementacija zahtjeva znatna ulaganja što se tiče područja novčanih sredstava a s druge strane je izložen velikim rizikom povrata uloženog. To se događa iz tog razloga jer se svaka kompanija opire novim promjenama što znači da neuspjeh ovog projekta leži u ljudskom faktoru a ne u tehnologiji. Kako bi postigli prihvaćenost svih zaposlenika potrebno je glavnog rukovoditelja informirati i uključiti u projekt implementacije.

[35] Kruljac, F. Op.cit, str 15.

Potreba za uvođenjem rješenja poslovne inteligencije u poslovnim procesima neke kompanije najviše se javlja zbog samih klijenata, kako bi se pronašli načini da se pridobiju novi i kako bi se zadržali već postojeći klijenti. Primjena ovih rješenja vezana su za gotovo sva područja važnih procesa neke firme kao što su uvođenje novih proizvoda, područje marketinga, fokusiranja na kupca, razvoj investicija. Glavni zadatak koji nam pružaju je zapravo dobivanje informacija o stanjima tih procesa.[36]

[36] Ljubetić,V. Op.cit, str. 74.-77.

3. POSLOVNA INTELIGENCIJA U BANKARSTVU

Poslovanje svake banke se temelji na mnoštvu podataka čiji se broj svakim danom sve više povećava. Iz tog razloga poslovna inteligencija je nužna komponenta poslovanja svake banke i važan dio uspješnog ostvarenja ciljeva. U ovom poglavlju se govori o područjima primjene poslovne inteligencije i njezin značaj i utjecaj na konkurentnost poslovanja.

3.1 Područja primjene poslovne inteligencije u bankovnoj firmi

Kako bi donositelji odluka iz svih segmenata banke mogli eksploatirati i upravljati mnoštvom vanjskih i unutarnjih podataka, rješenja poslovne inteligencije koja se koriste u bankama su većinom složena. Poslovna inteligencija obuhvaća većinu dijelova bankarskog poslovanja.

Najvažniji od njih su:

- upravljanje odnosima sa klijentima (engl. costumer relationship management - CRM),
- upravljanje performansom banke (engl. PM, Performance Management),
- upravljanje rizicima (engl. Enterprise Risk Management),
- upravljanje aktivom i pasivom (engl. ALM, Asset & Liability Management),
- usklađivanje sa regulativom i standardima (engl. Compliance).

Kako bi poslovanje banke bilo uspješno jako je važno provoditi analizu odnosa s klijentima. Rješenja poslovne inteligencije koja se koriste u ovom dijelu su većinom fokusirana na definiranje jasne slike o klijentima i njihovom odnosu prema banci, na segmentiranje tržišta, definiranje jasne slike o tržišnom potencijalu i mogućnostima banke da taj potencijal iskoristi:

- segmentacija - analiziraju se grupe klijenata, prema zajedničkim karakteristikama,
- profitabilnost klijenata - radi se o analizama klijenata s obzirom na očekivanu profitabilnost banke i na ROE,
- analize gdje se procjenjuje mogućnost klijenata da koriste više usluga banke istovremeno (engl. cross selling i up selling)
- efektivnost kanala - analiziraju se kanali kojima se ostvaruje komunikacija s klijentima i putem kojih im se isporučuju proizvodi,

- upravljanje kampanjama - analiziraju se utjecaji marketinških kampanja na povećanje broja klijenata, povećanje prodaje usluga i proizvoda, povećanje profita.

Kod upravljanja aktivom i pasivom banke gdje je cilj uspostaviti ravnotežu između profita i rizika, rješenja poslovne inteligencije imaju veliku ulogu u generiranju izvještaja kao što su analize likvidnosti i tokova gotovine. Također obuhvaćaju i analizu prihoda i dugoročnih kreditnih aranžmana.

Kod upravljanja performansom rade se analize gdje se prate ključni indikatori performansi poslovanja preko izvještaja uravnoteženih ciljeva kako bi se kontrolirala usklađenost tekućeg stanja sa definiranim ciljevima. Ta rješenja pomažu korisnicima brz pristup karticama koji omogućuju pogled na detalje podataka, na vrijednosti performansi ključnih indikatora, i kad se prijeđu dozvoljene granice daju znakove uzbune. Iz tog razloga jako je važno imati infrastrukturu koja će podržavati procese planiranja i budžetiranja. [37]

3.2 Dimenzioniranje modela primjene

Rješenja poslovne inteligencije koja se primjenjuju u banci imaju veoma heterogenu arhitekturu. Ta arhitektura se sastoji od nekoliko dijelova:

- operativna baza podataka i eksterni podaci,
- nivo integracije i transformacije podataka,
- nivo skladišta podataka,
- nivo za pristup podacima (aplikacije, OLAP, rudarenje podataka),
- nivo za pristup informacijama.

Glavni informacijski sistem banke čini upravo sustavi za izvođenje poslovnih procesa čiji je zadatak bilježiti veliki broj transakcijskih podataka (engl. OnLine Tranaction Processing-OLTP) koja se koristi za svakodnevne poslovne transakcije. Radi se o velikom broju svakodnevno prikupljenih podataka tijekom dužeg razdoblja što znatno smanjuje performanse samog sistema. Iz tog razloga ti podaci se ne koriste za složenije analitičke obrade. U banci OLTP infrastrukturu čini:

[37] Ubiparipović,B., Raković,L. Op.cit, str. 918.

- bankarska rješenja za izvršavanje osnovnih bankarskih operacija, engl. core banking rješenja (depoziti, plasmani, platni promet, kartičarstvo, elektroničko i mobilno bankarstvo, brokerski poslovi),
- aplikacije za cjeloviti proizvodno-poslovni informacijski sustav engl. Enterprise Resource Planning - ERP (računovodstvo i financije,osnovna sredstva),
- eksterne aplikacije.

Nivo integracije i transformacije podataka odnosi se na nivo gdje ETL procesi transformiraju podatke iz operativnih izvora u oblik koji je pogodan da bi se ti podaci mogli smjestiti u skladište podataka. To se treba odvijati na način da se OLTP što manje trpe jer su oni uvelike opterećeni velikim brojem podataka. Rješenja poslovne inteligencije su dizajnirana na način da se mogu koristiti na efikasan način upravo za ove procese i u što kraćem vremenskom roku. Isto tako ti alati su dizajnirani na način da su laki za korištenje.

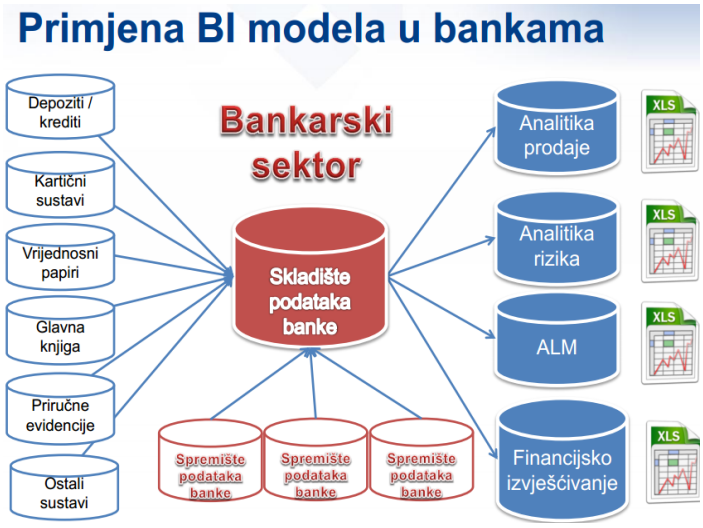
Skladište podataka služi kao što smo već opisali u prethodim poglavljima, za prikupljanje velike količine podataka koji se održavaju i kojima se upravlja kako bi se mogli koristiti u procesima donošenja odluka. Banka postavlja dosta veliku količinu podataka pred skladište podataka i radi se o dosta složenim zahtjevima te iz tog razloga njihova nadgradnja u formi dvoslojne arhitekture s više nezavisnih lokalnih skladišta podataka (engl. data-martova) su obično dimenzionalni modeli. Model koji se koristi u bankama je komercijalnog tipa i sastoji se od entiteta i atributa koji su vezani za one važne dijelove bankarskog poslovanja (marketing, upravljanje rizicima, odnosi s klijentima).

Dvoslojna arhitektura s više nezavisnih lokalnih skladišta podataka (engl. data-mart) predstavlja direktni pristup podacima za krajnje korisnike. Mogu se koristiti za skladište podataka kao i za analitičku obradu podataka gdje zahtjeva brz i lak pristup krajnjim korisnicima gdje je dimenzionalni model najpovoljniji za zadovoljenje tog zahtjeva. Odnose se na poslovanje unutar jedne funkcije odnosno jednog poslovnog procesa. Data martovi mogu biti bazirani na modelima koji su definirani kao kocke podataka od kojih svaka ima skup mjera i dimenzija koji su prilagođeni za analitičke procese (engl. Business Solution Templates - BST). Data mart modeli mogu biti bazirani i na rješenjima čiji je glavni zadatak prilagoditi podatke za aplikacije (engl. Application Solution Templates -AST). Kao što smo

već rekli, OLAP služi da korisnici na brz i lagan način pretvaraju podatke u informacije a to se radi uz pomoć SQL upita. OLAP alati moraju biti prilagođeni na način da osiguravaju korisnicima interaktivno istraživanje podataka i različit prikaz podataka prema potrebama korisnika. Mogu biti u obliku multidimenzionalnih analiza, statusnih izvještaja. Podaci su organizirani multidimenzionalno odnosno kao kocke koje su fleksibilne.

Rudarenje podataka služi za pronalaženje zakonitosti među podacima i može biti jako korisno u bankarstvu. Jedan od mnogih primjera korištenja je taj da banka može predvidjeti koji klijenti bi mogli koristiti određene usluge na temelju analize karakteristika klijenta banke. Isto tako banka može smanjiti svoj rizik poslovanja a to se radi na temelju podataka koje banka već ima i pomoću kojih određuje karakteristike klijenta kako bi došla do zaključka hoće li klijent moći vratiti kredit.

Nivo za pristup informacijama čine alati koji se koriste svakodnevno. Te aplikacije i alati su jednostavni i vizualno atraktivni a omogućuju analizu i prezentaciju informacija. Koriste ih menadžeri, analitičari i operativni korisnici. Mogu biti u formi: izvještaja, analize, scorecard tablice. [38]



Slika 4: Primjena BI modela u bankama

Izvor: Infosistem : Sustav poslovne inteligencije za banke: http://www.infosistem.hr/pdf/rjesenja/BI_info.pdf

[38] Ubiparipović,B., Raković,L. Op.cit, str. 919-920.

Na prethodnoj slici možemo vidjeti primjenu modela poslovne inteligencije u bankama. Vidimo kako se svi prikupljeni podaci iz svih područja banke (kartični sustavi, krediti, glavna knjiga,...i ostali sustavi) smještaju u skladište podataka. Nakon čega ti podaci dolaze u svaki dio poslovanja banke gdje su potrebni. Podaci potrebni za upravljanje rizikom idu u dio rizika gdje se provode analize, isto tako je i s ostalim područjima kao što je analitika prodaje, financijsko izvješćivanje i sva ostala područja koja čine poslovanje bankovne firme. Na samom kraju se nalaze vizualni izvještaji odnosno rezultati obrade podataka koji se koriste za daljnje donošenje odluka koje su potrebni bankama kako bi poboljšali svoje poslovanje.

3.3 Raspoloživost podataka

Svaka bankovna transakcija predstavlja grumen podataka što znači da bankarska industrija leži na ogromnim količinama podataka.[39] Njihovo poslovanje uvelike ovisi o korištenju informacija koje su ključne za ostvarivanje poslovnih ciljeva.[40]

Kako bi banke mogle dobiti sve informacije koje joj trebaju u svrhu donošenja odluka, potrebno je raditi na održavanju i upravljanju odnosima s klijentima. Banke iz tog razloga bilježe svaku transakciju i svaki kontakt s klijentom kao glavni izvor informacija koje se dalje provode kroz procese analize, usporedbe i zaključivanja. To su podaci iz prodaje, podaci o profitabilnosti klijenta, podaci o uslugama i plaćanjima, podaci o pritužbama. Banka nadalje prati daljnje ponašanje klijenta kroz nastavak interakcije s klijentom. Kako bi bankarske institucije izbjegle rizik i ostvarile uspješnu prodaju, mora neprestano održavati vezu sa klijentima i biti im blizu. Iz tog razloga banke uvode upravljanje odnosima s klijentima (Customer Relationship Management –CRM) koji obuhvaća prikupljanje informacija, ekstrakciju i izvještavanje o podacima klijenata. Tehnologija CRM-a također omogućuje suradnju s klijentima i ostvarivanje komunikacije. Pomoću današnje suvremene tehnologije odvija se prikupljanje i spremanje podataka o klijentima, informacije o njihovom profilu, demografskim karakteristikama, o navikama kupovine i slično. Današnja računala bilježe sve

[39] Finextra (2017) The force awakens: Big Data in banking: https://www.finextra.com/newsarticle/28541/the-force-awakens-big-data-in-banking

[40] HNB (2006): Smjernice za upravljanje informacijskim sustavom u cilju smanjenja operativnog rizika, str. 8.

podatke i omogućuju usporedbu tih podataka. Glavni cilj CRM-a je dobivanje što potpunijeg znanja o klijentima što rezultira efikasnošću poslovanja.

Osim već postojećih, internih podataka banka na raspolaganju ima i eksterne podatke koji su javno dostupni.

Banke također skupljaju informacije o klijentima na temelju upravljanja marketinškim kampanjama gdje se uz pomoć marketinških aktivnosti prikupljaju podaci o željama, o namjerama kupnje i o očekivanjima klijenata. Na ovaj način dolazi se do statističkih podataka o odgovoru klijenta kao reakciji na kampanje na temelju čega se donose predviđanja o budućim ponašanjima i na temelju čega se formira model za praćenje uspješnosti klijenta. Upravljanjem potporom prodaji također se dolazi do jako bitnih podataka i informacija. Prodaja predstavlja glavni bankarski proces te u sklopu nje se neprestano prikupljaju i distribuiraju informacije potrebne za daljnje poslovanje i to na način da se ostvaruje stalna interakcija sa klijentima. Jedan od važnih izvora informacija je upravljanje pozivnim centrima koji su orijentirani na interakciju kako bi se formirali vlastiti podaci o zadovoljstvu usluga i ostalim mjerenjima.

Do informacija se dolazi i ponovljenim dolascima klijenata u banku gdje se uspostavljaju odnosi između banke i klijenta. Da bi se dobile potrebne informacije, potrebno je ostvariti povjerenje s klijentom jer neki se podaci mogu dobiti samo uz njegovu suglasnost.

Dosta podataka se dobije korištenjem IT tehnologije dakle putem interneta i mobitela. Prikupljajući podatke, banke dobivaju povratne informacije klijenata o tome kakvu uslugu žele i mnoge druge informacije bitne za uvođenje novih usluga. Jako je važan proces privlačenja klijenata , održavanje odnosa s klijentima te njihovo zadržavanje. Na ovaj način se lako dolazi do svih potrebnih informacija jer se uspostavlja odnos i suradnja. Danas mnoge kompanije „prate“ klijenta u svrhu lakšeg dobivanja informacija. Svi ti zabilježeni podaci dalje prolaze kroz proces analize s ciljem uspostavljanja što bolje suradnje s klijentima. Korištenjem poslovne inteligencije dolazi se do novih znanja.[41]

[41] Severović, K (2013): Upravljanje odnosima s klijentima kao izvor informacija za oblikovanje i poboljšanje usluga, Fakultet organizacije i informatike u Zagrebu, str 84.-102.

3.4 Utjecaj primijenjene poslovne inteligencije na konkurentnost bankovne firme

Poslovna inteligencija stavlja pravu informaciju u prave ruke i u pravo vrijeme što stvara zajednički kontekst za donošenje odluka u svim odjelima i razinama kompanije.[42] Očito je da u ovom trenutku poslovna inteligencija pruža mnoge prednosti bankama koje su u mogućnosti to iskoristiti. Neke od tih prednosti su u prvom redu, eliminiranje puno nagađanja unutar organizacije što znači da banka sada uz pomoć obrađenih informacija može donositi odluke na temelju rezultata. Kao drugo, daje mogućnost poboljšanja komunikacije među odjelima, a koordinacija aktivnosti omogućuje brzo reagiranje na promjene u financijskim uvjetima. Podaci se općenito smatraju najvažnijim resursom kojeg banka ima. Dakle, kada banka može donositi odluke na temelju pravovremene i točne informacije, banka može poboljšati svoju učinkovitost. Poslovna inteligencija ubrzava donošenje odluka i daje brze i točne informacije prije konkurencije. Također može poboljšati korisničko iskustvo čime omogućuje pravovremeni i odgovarajući odgovor na probleme s klijentima.

Neke od prednosti koje su stekli, objašnjeni su u intervjuima koje su navedeni ispod. Uz napredne alate poslovne inteligencije banke mogu :

- lako pretvoriti poslovna znanja svojih zaposlenika u analitičku inteligenciju,
- identificirati svoje najprofitabilnije kupce kao i temeljne razloge za njihovu lojalnost kao i prepoznavanje budućih kupaca,
- analizirati click-stream podatke kako bi se poboljšale online bankarske strategije,
- brzo otkrivanje problema što omogućuje izbjegavanje složenih situacija,
- otkrivanje pranja novca,
- analizirati potencijalnu profitabilnost kupaca i smanjiti izloženost riziku kroz točnije financijsko kreditne bodovanje njihovih kupaca,
- odrediti koje kombinacije proizvoda i usluga će kupci vjerojatno kupiti i kada,
- postaviti isplativije stope za premije osiguranja,
- uz pomoć analiza odrediti zašto kupci napuštaju konkurenciju i postaju naši klijenti,

[42] Vaidya T., Sagar A., Kiran K., Kundan L. (2014) : Business Intelligence System for Banking and Finance, str. 4336.

- otkriti i spriječiti malverzacije prilikom ukradenih kartica.[43]

Prednosti koje pruža poslovna inteligencija s obzirom na konkurenciju ne prestaju. Rješenja poslovne inteligencije omogućuju bankama da prate pojedine izvore prihoda kako bi bolje odredili koji proizvodi i usluge su profitabilni a koji nisu. Također pružaju i analizu velike količine podataka kako bi dobili uvid o potrebama kupaca i na taj način poboljšali bankarske proizvode i usluge. Upravo tako banke bolje zadovoljavaju potrebe klijenata i stvaraju konkurentsku prednost. Banke ostvaruju prednosti i na području marketinga gdje analiziraju CRM podatke te na temelju niza kriterija na taj način mogu otkriti najprofitabilniji profil kupaca kao i analizirati nove prodajne mogućnosti kako bi dobili informacije o provedbi ciljanih marketinških kampanja. Poslovna inteligencija pruža veliku ulogu u zadržavanju i lojalnosti klijenata te mogu pomoći bankama prepoznati i slijediti najisplativije kupce. Također, korištenjem alata i tehnika poslovne inteligencije, banke mogu otkriti razloge zbog kojih klijenti odlaze u druge, konkurentske banke. Tada banke mogu implementirati nove procese kako bi se smanjio gubitak klijenata. To rade na način da banke mogu pratiti ponašanje, preferencije i navike kupaca kako bi prilagodile svoje proizvode i usluge i zadovoljile njihove potrebe što rezultira rješenjem problema te zadržavanja klijenata i njihove lojalnosti.

Poslovna inteligencija ima važnu ulogu i u razvijanju novih strategija. Jedna od važnijih uloga koju poslovna inteligencija igra u bankarskom sektoru je smanjenje rizika. Rizik je područje velike neizvjesnosti i podložno je neprestanim promjenama. Banke više nego ikad trebaju koristiti svaki alat koji im je na raspolaganju kako bi smanjili rizik. Danas rješenja poslovne inteligencije pružaju djelotvorne informacije koje organizacije mogu koristiti za ublažavanje rizika u brojnim područjima. Pomoću ranije spremljenih podataka u sustavu banke mogu predvidjeti kreditni rizik druge ugovorne strane. Isto tako mogu dobiti točnu procjenu rizika od korisnika kredita na temelju ključnih kriterija kao što je zarađivanje dužnika i kratkotrajna financijska imovina. BI alati se mogu koristiti za analizu kreditnih portfelja, rano otkriti

[43] Lorenzetti C. (2009/2010): Business intelligence systems in the financial industry, Sveučilište Milanu, str 33-38

potencijalne slučajeve delikvencije te ranije djelovati. Također, mogu pratiti povijest kupčevih transakcija i spriječiti mnoge prijevare.[44]

Najkritičniji aspekt bankarskog poslovanja predstavljaju upravo klijenti. Da nema klijenta financijske institucije uopće ne bi ni postojale, te iz tog razloga jako je važno da banke imaju sve informacije koje su im potrebne kako bi se mogle usredotočiti na njihove preferencije. Banke se moraju vrlo brzo prilagoditi na promjene i zahtjeve i upravo im poslovna inteligencija omogućuje prikupljanje podataka o novim trendovima na tržištu i dolazi s novim inovativnim proizvodima i uslugama kako bi zadovoljila zahtjeve klijenata koji se iz dana u dan mijenjaju. Konkurencija predstavlja veliku prepreku na putu za uspjeh. Njihovi ciljevi su isti kao i ciljevi drugih banaka a to je povećati dobit i zadovoljstvo klijenata kao i biti spreman suočiti se s rizičnim situacijama. Iz tog razloga da bi bile uspješne, banke moraju biti jedan korak ispred konkurencije a upravo je poslovna inteligencija ta koja im pomaže u otkrivanju akcija koje konkurencija poduzima. Dakle, poslovna inteligencija ima veliki utjecaj na konkurentnost banke što rezultira većom učinkovitosti procesa donošenja odluka, sposobnost bržeg reagiranja, jedinstvenom vizijom informacija, više ostvarenih ciljeva, smanjenje troškova za analizu podataka, više informacija, veća komunikacija i koordinacija te manje posla za IT.[45] Konkurentne prednosti neke banke s obzirom na drugu čini učinkovitije dijeljenje znanja pružajući menadžerima i ostalim korisnicima nove alate pomoću kojih mogu vidjeti podatke na novi način i tako brže i bolje donositi odluke. Platforma poslovne inteligencije pruža ključne informacije za poslovne korisnike i omogućuje im podršku u odlučivanju i putem interneta.[46]

Danas mnoge kompanije koriste poslovnu inteligenciju kako bi povećale profitabilnost, smanjile rizik i stekle konkurentsku prednost. U današnjem izrazito konkurentnom tržištu banaka treba biti učinkovit što je više moguće koristeći rješenja poslovne inteligencije za analizu podataka. Tehnologija koja se koristi u bankarstvu se neprestano mijenja i tu još uvijek nije kraj. Smatra se da će u budućnosti bankarske institucije u potpunosti iskoristiti

[44] Qubole: Applications of Business Intelligence in Banking and Finance: https://www.qubole.com/blog/big-data/business-intelligence-and-finance/

[45] Lorenzetti C. Op.cit, str 55

[46] Nadeem M., Jaffri S.A.H.:Application of Business Intelligence In Banks (Pakistan), str. 1.-6.

rješenja poslovne inteligencije za upravljanje rizikom, za povećanje operativne učinkovitosti, za pružanje proizvoda i usluga koji zadovoljavaju stvarne potrebe kupaca a sve to s ciljem kako bi bili bolje pozicionirani i uživali stalni rast, profitabilnost i konkurentnost u godinama koje tek dolaze.[47]

[47] Qubole: Applications of Business Intelligence in Banking and Finance. Op.cit, https://www.qubole.com/blog/big-data/business-intelligence-and-finance/

4. PRIMJENA MODELA POSLOVNE INTELIGENCIJE U KLASIFIKACIJI RIZIČNIH GRUPA SEKTORA STANOVNIŠTVU

U ovom poglavlju smo koristili neke od alata poslovne inteligencije i na konkretnom primjeru pokazali kako poslovna inteligencija može pomoći prilikom analize mnoštva podataka.

Banke su izložene raznim ekonomskim i neekonomskim rizicima i iz tog razloga ključni dio bankarskog poslovanja predstavlja upravo upravljanje rizicima. Prema Ercegovcu, može se reći da ne postoji događaj koji ne sadrži nekakvu neizvjesnost njegove budućnosti a razlog tome je nedostatak potrebnih informacija.[48]

Rizik predstavlja stanje kod kojeg postoji mogućnost dolaska do neželjenog događaja za razliku od onog ishoda koji je poželjan odnosno kojeg očekujemo. Možemo reći da se radi o mogućoj promjenjivosti rezultata s obzirom na onu koja je očekivana. [49]

Kreditni rizik predstavlja jedan od većih rizika s kojim se banke suočavaju i to je rizik koji najviše dominira. Definira se kao rizik kod kojeg dužnik neće vratiti posuđena novčana sredstva u dogovorenom roku pri čemu banka ostaje u gubitku. [50] Odnosi se na rizik kamatnih stopa, rizik likvidnosti te valutni rizik.

Iako se upravljanje kreditnim rizikom neprestano poboljšava, njegov se volumen nije smanjio. On izravno utječe na solventnost banke. Nadzor kreditne sposobnosti klijenta je važan dio upravljačkog procesa svake bankovne firme i umanjena kreditna sposobnost klijenta ima negativan utjecaj na uspjeh banke.[51]

Potrebno je neprestano nadzirati kreditnu sposobnost dužnika kao i provoditi analize da bi se moglo na vrijeme reagirati. Povijesni podaci su jako važni jer služe za provjeru pojave

[48] Ercegovac, R. (2016) : Teorija i praksa bankovnog menadžmenta, Ekonomski fakulteta Split str 28-29.

[49] Ercegovac, R. Op.cit, str 33

[50] Gabelica H. (2013) : Primjena metoda rudarenja podataka na primjeru procjene kreditnog rizika, Skladištenje.com

[51] Ercegovac, R. Op.cit, str 155.

kreditnog rizika. Modeli mjerenja rizika temelje se na rangiranju klijenata i analizi pomoću više kriterija.[52]

Kako banke razvijaju nove proizvode te šire svoje tržište, dolazi do povećanja rizika koji prijeti njenoj stabilnosti. Iz tog razloga banka koristi povijesne podatke na osnovu kojih provodi razne analize, procjenjuje rizike, planira aktivnosti u slučaju pojave rizika. Glavni cilj upravljanja rizicima je taj da banka ostvari zadane ciljeve. Da bi upravljanje rizikom bilo uspješno potrebno je prepoznati rizik, mjeriti, nadzirati rizične faktore, izgraditi sustav upravljanja. [53]

Banke moraju neprestano težiti da njihovo poslovanje bude u skladu s načelima likvidnosti i solventnosti. Kako bi to osigurale, moraju neprestano upravljati i mjeriti rizike kojima je banka izložena. [54]

Bankovne firme su danas velike kompanije koje su uvođenjem novih informacijskih tehnologija uvelike unaprijedile svoje poslovanje. No, dosta veliki problem stvara se zbog ogromnih količina podataka koje im stoje na raspolaganju radi poboljšanja i unaprjeđenja njihovog poslovanja. Iz tog razloga potrebno je neprestano uvoditi nove načine kojima bi se riješio ovaj problem.[55]

4.1 Opis uzorka istraživanja i definiranje ciljeva

Kako bi došli do znanja prvo moramo proći nekoliko koraka koji se mogu ponavljati sve dok se ne dobije onaj model podataka koji je pouzdan:

- u prvom koraku treba odrediti ciljeve i dobro proučiti i razumjeti problem,
- odrediti izvore podataka koje će se provesti kroz postupak analize,
- ovaj korak je korak gdje se podaci čiste,

[52] Ercegovac, R. Op.cit, str 156-160.

[53] Ercegovac, R. Op.cit, str 37-41.

[54] HNB (2006) : Smjernice za upravljanje informacijskim sustavom u cilju smanjenja operativnog rizika: http://old.hnb.hr/supervizija/h-smjernice-za-upravljanje-informacijskim-sustavom.pdf, str. 4.

[55] Stipić, M. (2016) : Implementacija sustava poslovne inteligencije u zračnoj luci Croatia Airlines,str.5-6.

- transformacija podataka u onaj oblik koji je prikladan za istraživanje,
- odabir pogodne metode i njena primjena te istraživanje rezultata,
- interpretacija dobivenih rezultata.56

4.1.1 Definiranje ciljeva i razumijevanje problema istraživanja

Definiranje ciljeva istraživanja kao i njihovo razumijevanje te prethodno proučavanje problema istraživanja jedan je od glavnih i prvih koraka poslovne inteligencije. Glavni cilj ovog istraživanja je istražiti kako pojedine varijable skupine sektora stanovništva koje imamo u prikupljenoj bazi podataka mogu biti korisne kod procjene kreditnog rizika. Procjena se radi na temelju povijesnih podataka kao i podataka koji su prikupljeni o klijentima koji imaju dug prema banci. Glavne varijable za analizu su visina neisplaćene glavnice i visina kamatne stope po skupini stanovništva koje se analiziraju kako bi se odredilo koje su skupine sektora stanovništva rizične a koje ne. Koristeći podatke o neisplaćenoj glavnici i podatke o visini kamatne stope možemo donijeti zaključke o kreditnom riziku i na taj način razumjeti klijente kako bi donijeli konačne odluke o pripremi novih kreditnih paketa koji će se nuditi i davati u budućnosti različitim sektorima stanovništva. Pri tome se koriste različiti alati kojima se na samom kraju i vizualno prikazuju rezultati istraživanja kako bi dobili bolji pregled i točne zaključke istraživanja.

Krajnji cilj ovog istraživanja je u biti dokazati da primjena alata poslovne inteligencije omogućuje unaprjeđenje poslovnih procesa banke. Cilj je pokazati kako se pomoću prikupljenih podataka i alata mogu donijeti kvalitetni zaključci koji su ključni kod donošenja poslovnih odluka, kod planova i postavljanja budućih poslovnih ciljeva banke. Bitno je pokazati kako se na ovaj način ubrzava sam proces obrade velike količine podataka koje banka posjeduje i na taj način se dobiju jako bitne i važne informacije koje se koriste u poslovanju.

[56] Varga, M.: Poslovna inteligencija: Ciljevi i metode, Ekonomski fakultet Zagreb, str. 5.

4.1.2 Opis uzoraka istraživanja

U ovom istraživanju provodi se analiza na temelju populacije stanovništva u Republici Hrvatskoj. Uzorak za istraživanje je sektor stanovništva koji je podijeljen po gradovima RH. Podaci koji su izvučeni iz skladišta podataka sadrže sve gradove Hrvatske. Prilikom analize odabrani su samo oni gradovi koje želimo istraživati. Tako su za ovo istraživanje izabrani gradovi Dubrovnik, Imotski, Osijek, Split, Šibenik, Zadar, Zagreb, Omiš, Knin, Pula, Rijeka. Ukoliko želimo dobiti rezultate za stanovništvo nekih drugih gradova, samo prilikom analize u alatu izaberemo druge željene gradove. Svaki klijent ima svoje atribute što znači da svaki od njih ima svoj broj odnosno broj klijenta po čemu možemo razlikovati klijente jedan od drugih. Isto tako klijenti imaju atribute po poslovnicama u kojima su sklopili kredit. Još jedan od atributa klijenata je bonitet koji označuje sposobnost plaćanja dospjelih obveza svakog od klijenata. Na temelju izabranih uzoraka populacije provodi se istraživanje. Odabrani uzorak istraživanja služi nam kao varijabla pomoću koje se dolazi do krajnjeg rezultata za donošenje zaključka o hipotezi koja je postavljena na početku.

4.2 Definiranje modela i metoda primjene poslovne inteligencije

Na samom početku potrebno je definirati model podataka koji će se koristiti u istraživanju kao i metode pomoću kojih se dobiju traženi rezultati.

4.2.1 Metode primjene poslovne inteligencije

U nastavku je definiran model podataka prema kojem je prikazan primjer korištenja alata poslovne inteligencije u klasifikaciji rizičnih grupa sektora stanovništvu. Za tu svrhu najprije je izrađen model podataka u Microsoft Accessu te nakon toga je izrađena kocka koristeći alat BI-Lite Cube-It Zero kako bi izradili potrebne izvještaje. Kako bi se što bolje razumjeli i prikazali dobiveni rezultati, korišten je alat Tableau kojim su podaci vizualno prikazani. Ovi alati su izabrani za ovaj rad zbog jednostavnosti korištenja i brzo se nauči raditi u njima. Postoje i drugi alati poslovne inteligencije od koji svaki od njih ima svoje prednosti.

4.2.2 Model podataka

Najprije je izrađen model podataka. Izvukli smo podatke potrebne za analizu iz skladišta podataka. U ovom slučaju nije bilo potrebe za čišćenjem podataka jer podaci koji su izvučeni iz skladišta podataka nisu imali nikakve nedostajuće vrijednosti.[57] Podaci se nalaze u Excelu te ih je potrebno transformirati u MS Access. Model podataka kreiran je u alatu MS Access 2007. Podaci su transformirani u Access kako bi se napravile tablice. Model smo kreirali na način da se sastoji od pet tablica. Jedna tablica je činjenična tablica i povezana je sa četiri dimenzijske tablice. Činjenična tablica je tablica pod nazivom Dug. Činjenične tablice su one tablice koje sadrže ključne mjere i pokazatelje i one su zapravo u centru procesa donošenja odluka poslovnog procesa. Dimenzijske tablice sadrže atribute pomoću kojih znamo po čemu vodimo analizu. Jako bitno je naglasiti da u ovom našem istraživanju imamo vremensku dimenziju koja je veoma ključna za skladište podataka.[58]

Dimenzijske tablice i njihovi ključevi su :

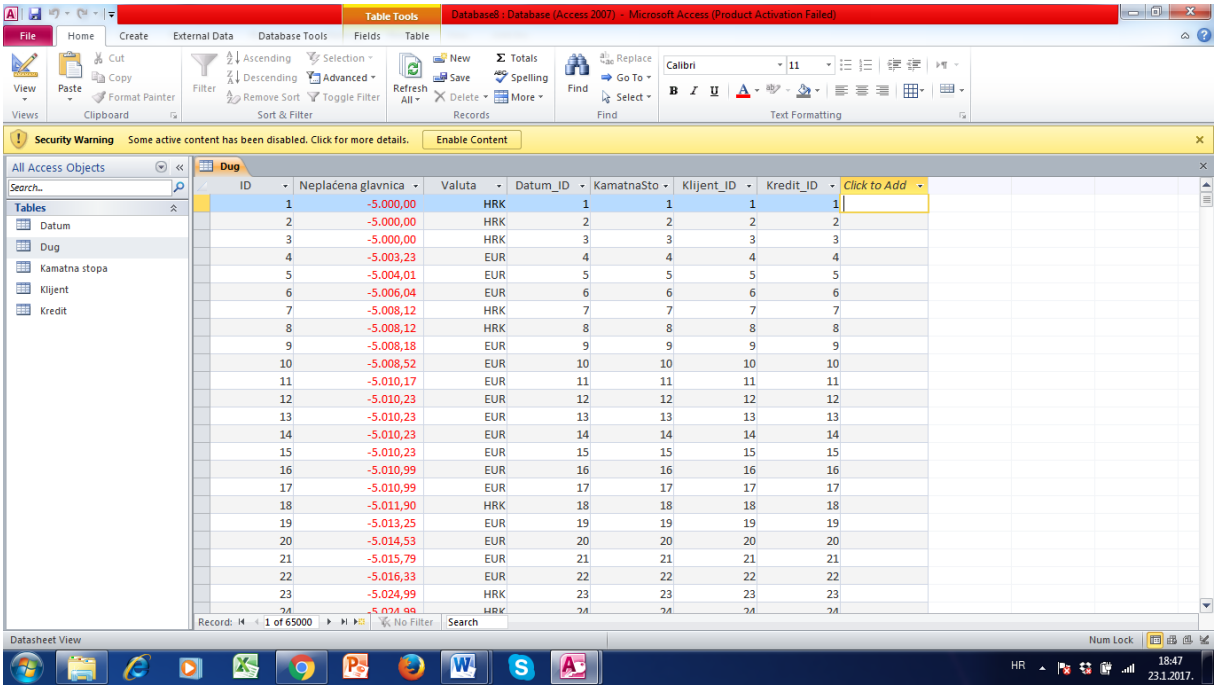
- DATUM: Datum_ID, Datum odobrenja, Datum dospijeća
- KAMATNA STOPA: KamatnaStopa_ID, Kamatna stopa (F/V), Kamatna stopa, Margina
- KLIJENT: Klijent_ID, Broj klijenta, Grad, Poslovnica, Bonitet
- KREDIT: Kredit_ID, Broj kredita, Vrsta kredita, Rezervacija

Dimenzijska tablica DATUM sadrži podatke o datumu odobrenja i dospijeća. Tablica KAMATNA STOPA nam daje informacije o visini kamate kredita. Tablica KLIJENT sadrži podatke odnosno informacije o klijentima. Dakle radi se o podacima gdje možemo vidjeti o kojem klijentu se radi, iz kojeg grada je klijent koji je uzeo kredit, u kojoj poslovnici je ugovoren kredit kao i podaci o sposobnosti klijenta i vraćanja kredita. Dimenzijska tablica KREDIT sadrži informacije o samom kredit dakle, broj kredita kao i vrstu kredita o kojoj se radi.

[57] Gabelica H. Op.cit, Skladištenje.com

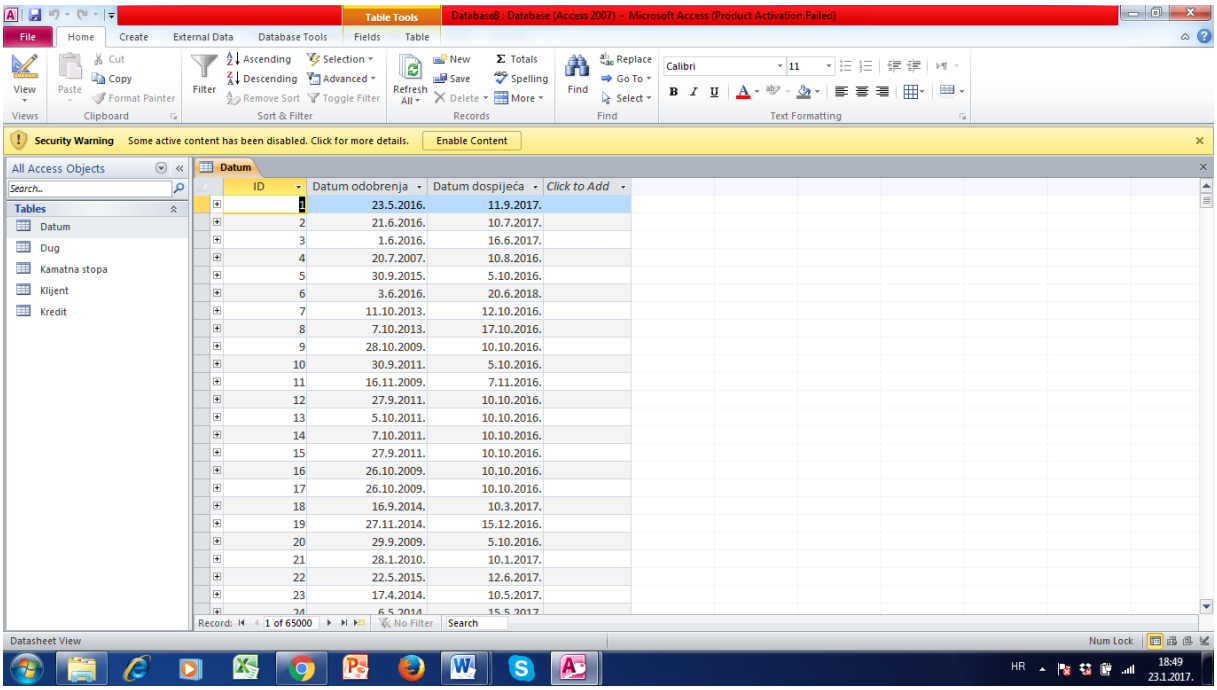
[58] Stojanović,A. (2013.): Implementacija „Business Intelligence“ sustava u Koncertnu dvoranu Vatroslava Lisinskog, Sveučilište u Splitu, Ekonomski fakultet Split, str. 32.-34.

Činjenična tablica ima dva atributa i sadrži nekoliko stranih ključeva. Atributi su Neplaćena glavnica i Valuta. Strani ključevi su ujedno i primarni ključevi tablica s kojima je činjenična tablica povezana a to su : Datum_ID, KamatnaStopa_ID, Klijent_ID, Kredit_ID.



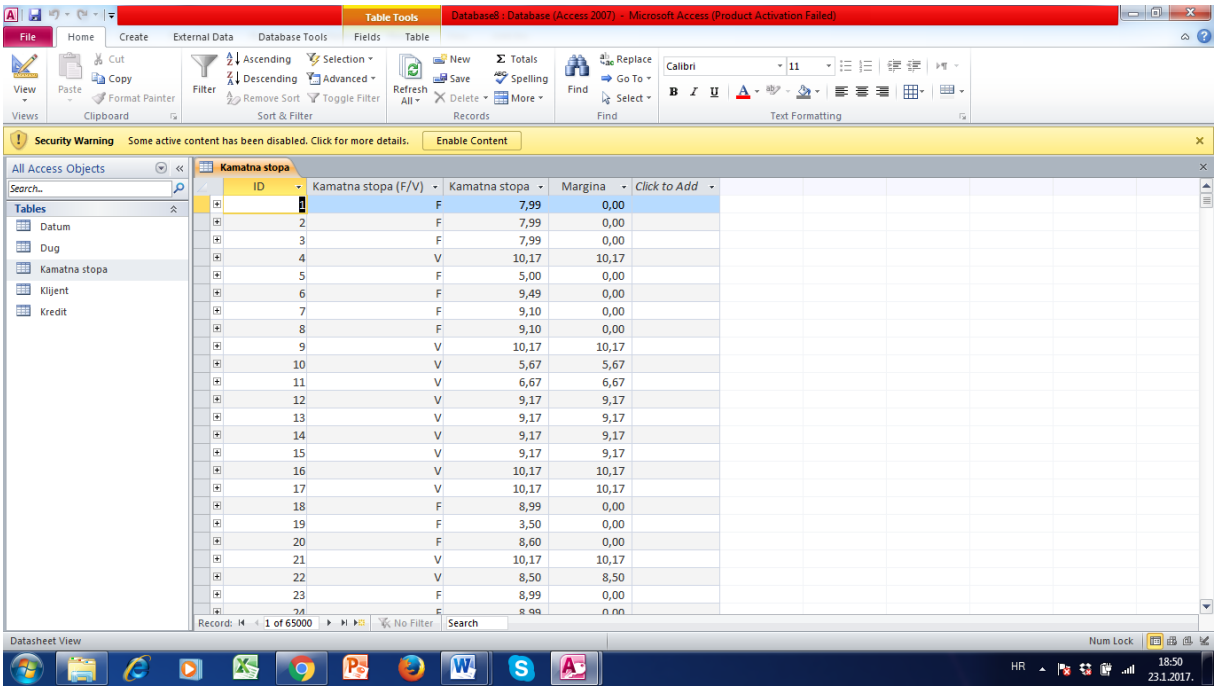
Slika 5. Činjenična tablica: Dug

Izvor: Stvarni podaci poslovne banke. Ime i adresa banke poznati mentoru i članovima komisije



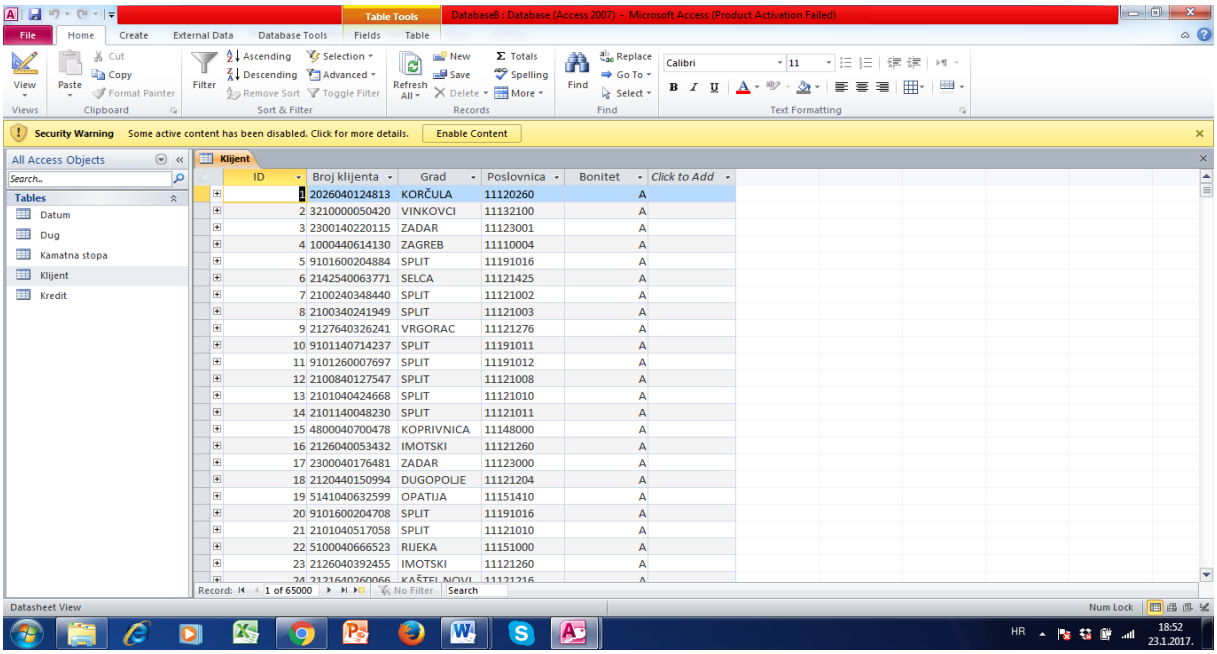
Slika 6: Dimenzijska tablica Datum

Izvor: Stvarni podaci poslovne banke. Ime i adresa banke poznati mentoru i članovima komisije



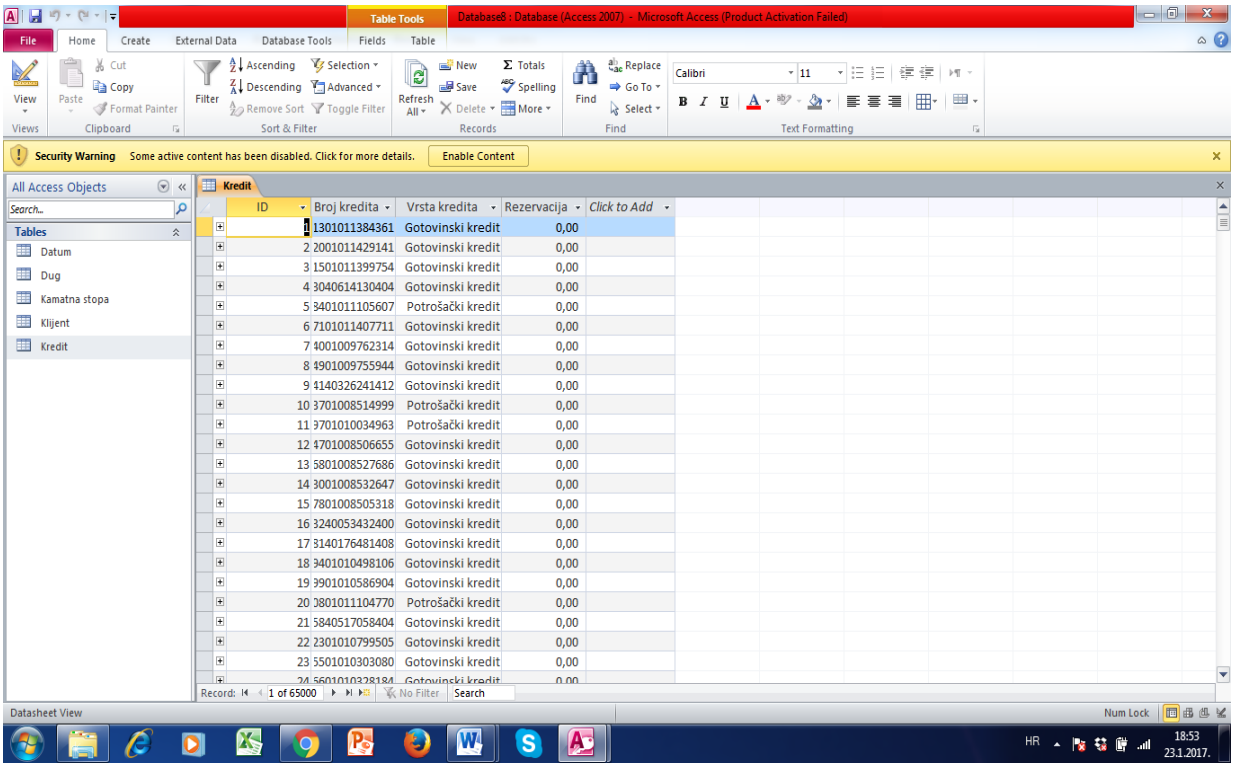
Slika 7: Dimenzijska tablica Kamatna stopa

Izvor: Stvarni podaci poslovne banke. Ime i adresa banke poznati mentoru i članovima komisije



Slika 8: Dimenzijska tablica Klijent

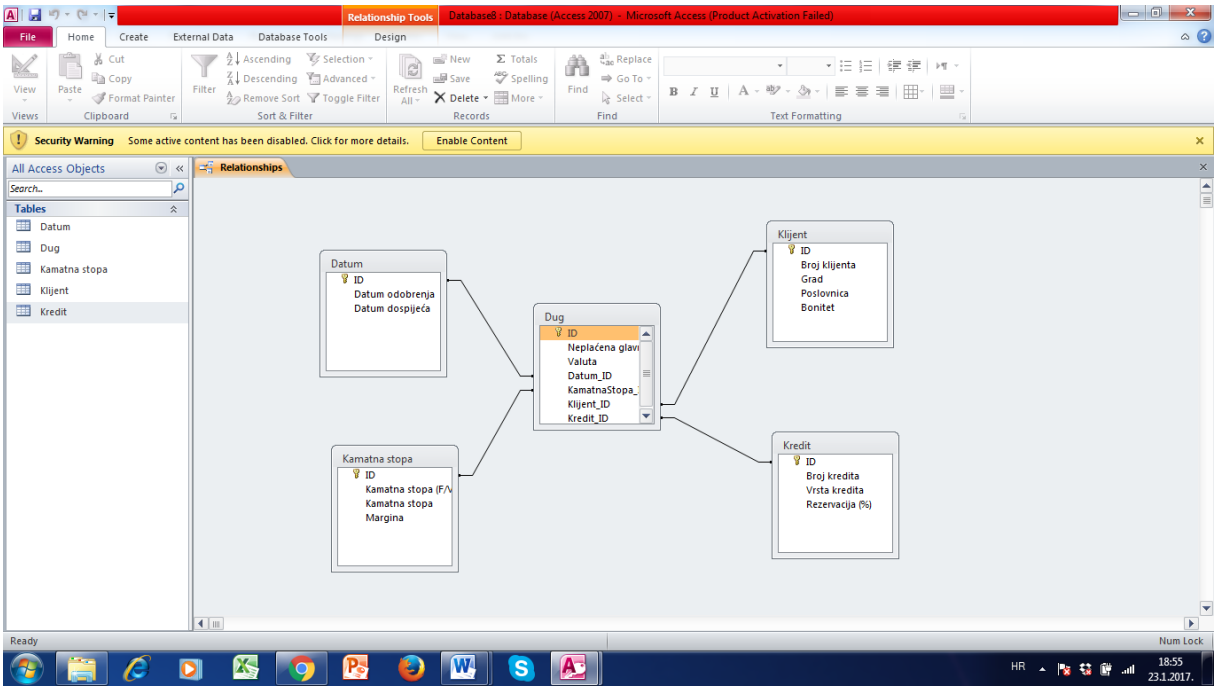
Izvor: Stvarni podaci poslovne banke. Ime i adresa banke poznati mentoru i članovima komisije



Slika 9: Dimenzijska tablica Kredit

Izvor: Stvarni podaci poslovne banke. Ime i adresa banke poznati mentoru i članovima komisije

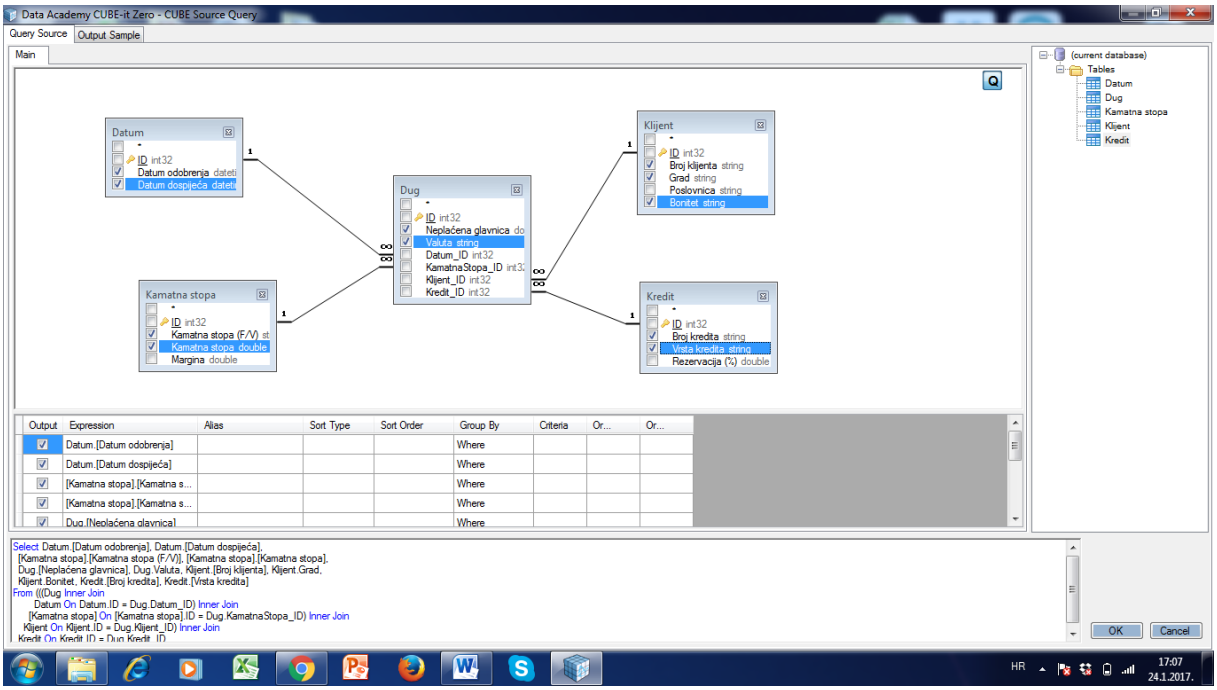
Na slici ispod možemo vidjeti kako je činjenična tablica neposredno povezana za dimenzijskim tablicama što znači da se radi o zvjezdastoj shemi:



Slika 10 : Konceptualni model

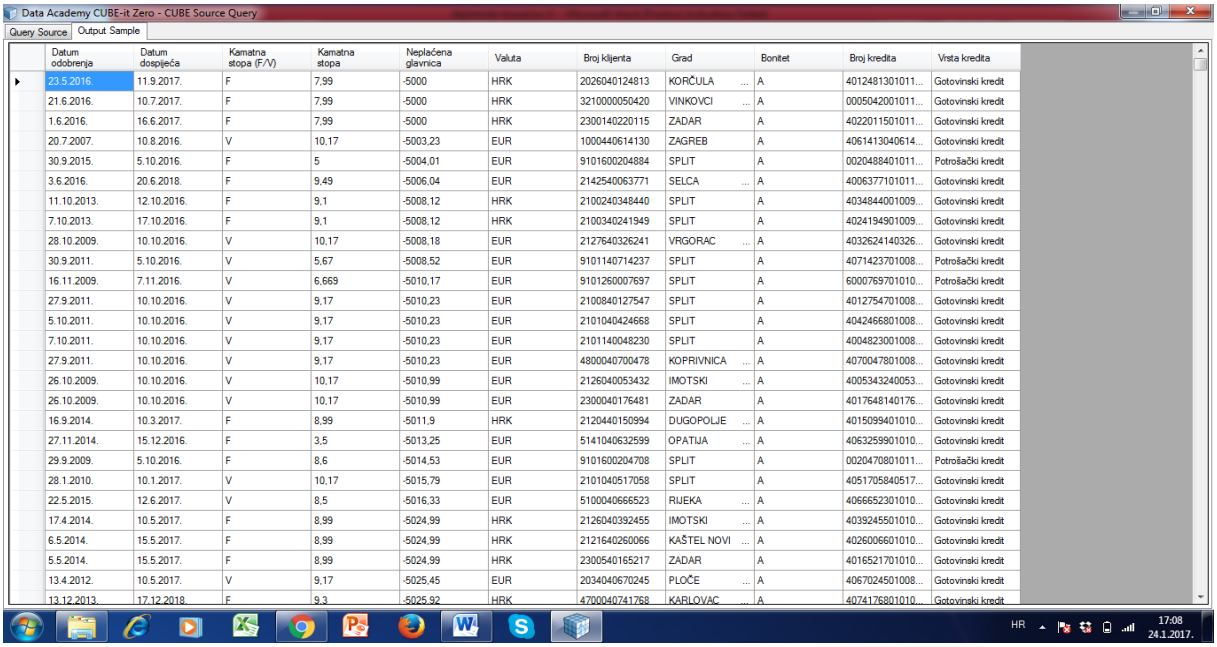
4.2.3 Dimenzije i hijerarhije

Nakon što smo koristeći MS Access izradili bazu podataka, slijedi izrada kocke. Kocka je izrađena koristeći jednostavan alat BI-lite Cube-it Zero. Proces izrade kocke sastoji se od pet koraka. U prvom koraku se potrebno povezati sa već formiranom bazom podataka u MS Accessu. Nakon toga je na jednostavan način, koristeći tehniku drag&drop potrebno izabrati tablice za izradu modela te izabrati atribute.



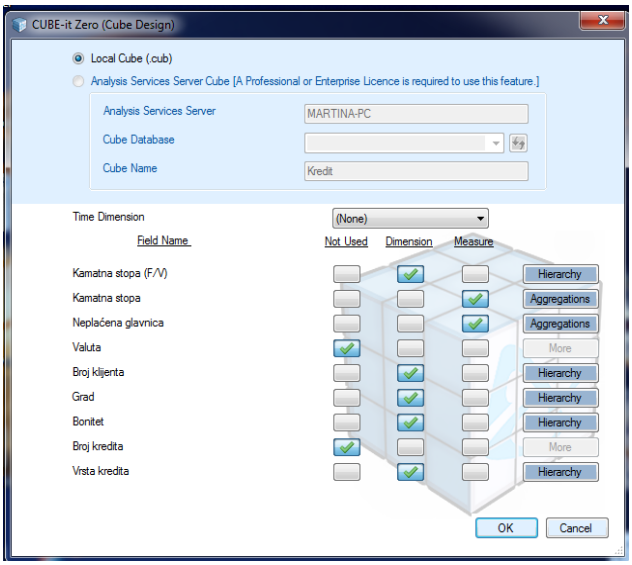
Slika 11 : Model podataka u BI Lite-u

Ovaj alat nam također omogućuje i prikaz baze podataka. Prikaz možemo vidjeti na slici ispod:



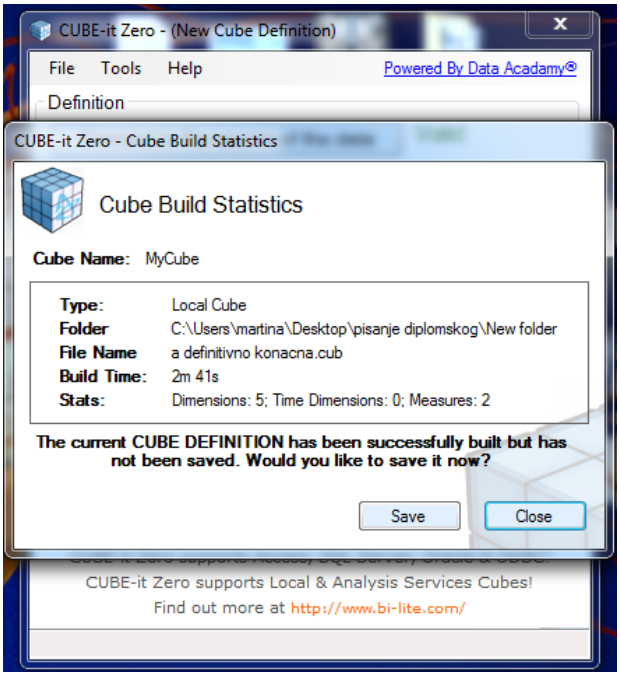
Slika 12 : Prikaz baze podataka u BI Lite-u

U trećem koraku je kreirana strukturu kocke.



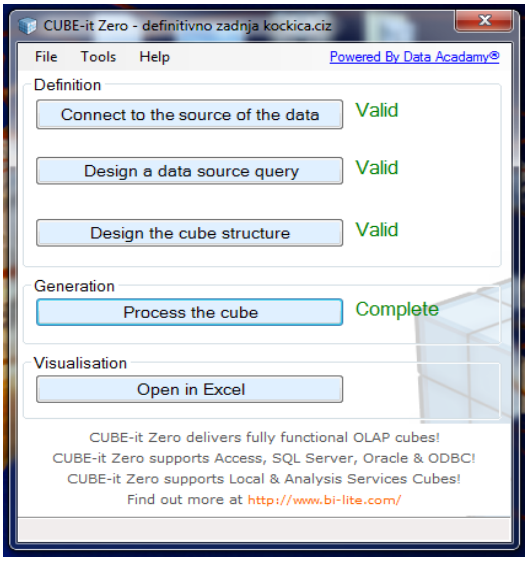
Slika 13 : Kreiranje strukture kocke

Slijedeći korak je korak procesuiranja kocke kojeg prikazuje slika 14.



Slika 14: Procesuiranje kocke

Nakon toga dolazimo i do posljednjeg koraka. U petom dijelu slijedi otvaranje u Excelu. Na ovaj način se kreiraju potrebni izvještaji koristeći pivot tablice. Na slici ispod vidimo uspješno odrađene sve korake u procesu izrade kocke:



Slika 15: Pet koraka

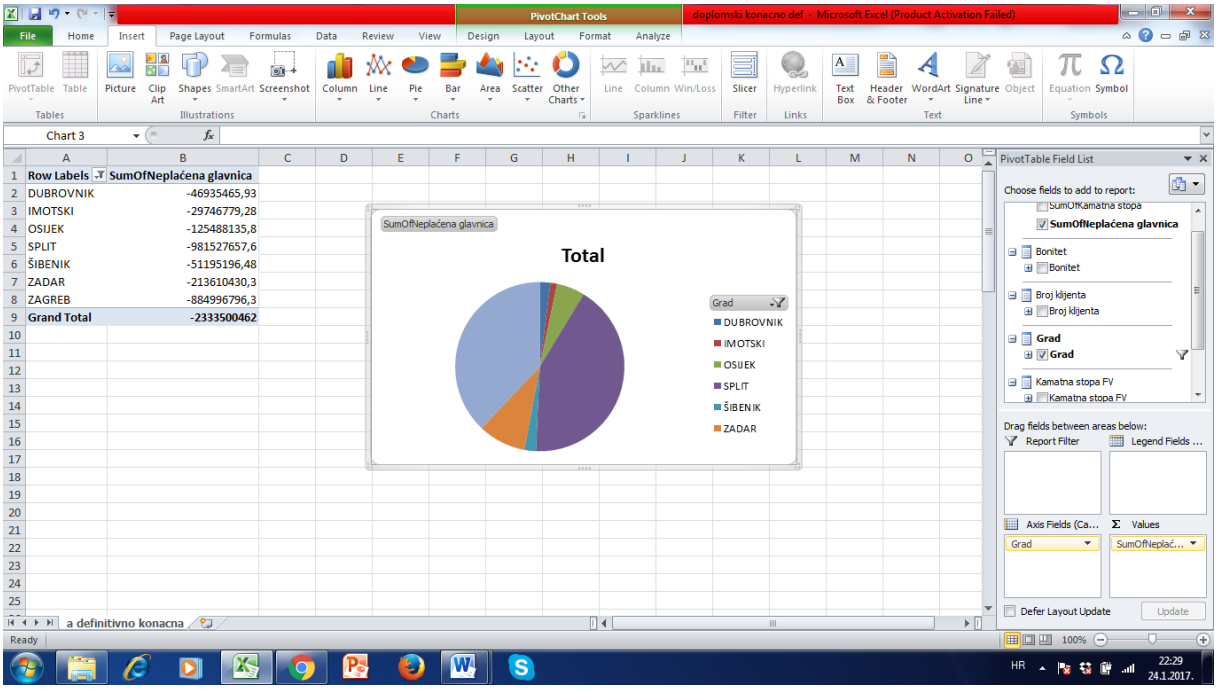
4.3 Rezultati istraživanja

U ovom dijelu su se koristila dva alata : Excel i Tableau. Pomoću ovih alata možemo vizualno prikazati rezultate ovog istraživanja i pokazati kako je ovaj način jednostavniji za donošenje odluka i tumačenje dobivenih rezultata.

4.3.1 Izvještavanje

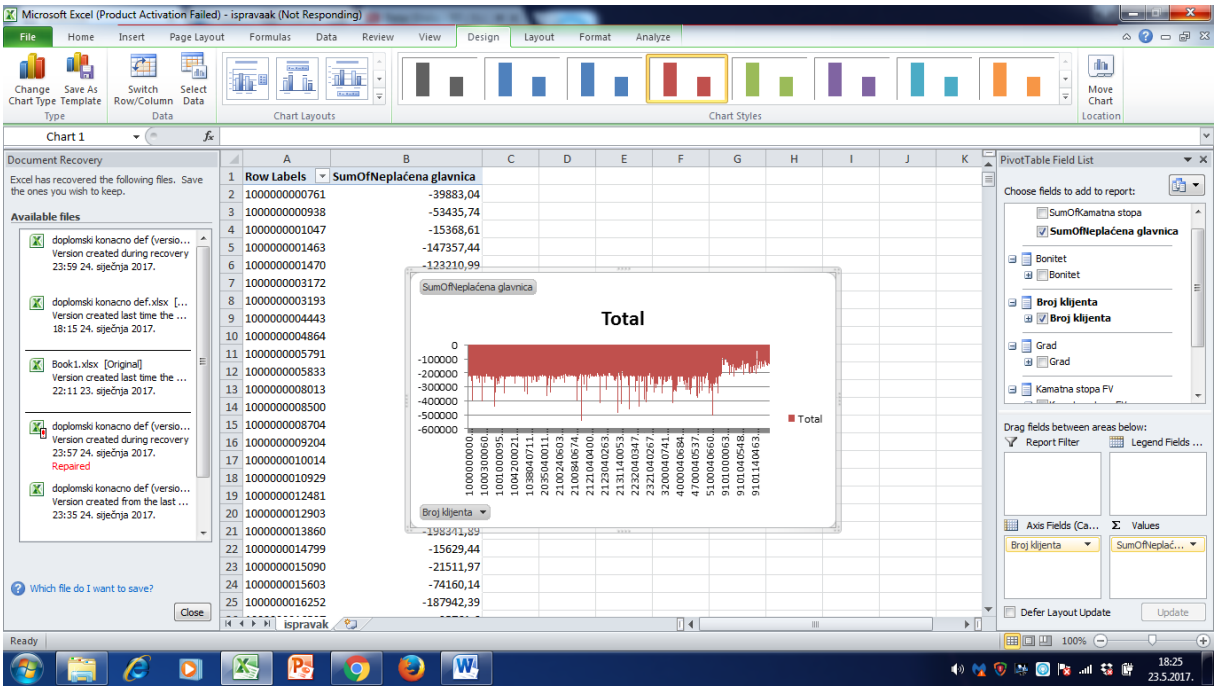
Kako bi napravili izvještaj koristili smo Excel. Pomoću pivot tablica izradili smo izvještaj o neisplaćenim glavnicama po lokacijama. Dakle , odabrali smo dimenzije za izvještaj a to su *Neisplaćena glavnica* i *Grad.* Kod dimenzije Grad , odabrali smo samo gradove koje želimo analizirati (Dubrovnik, Imotski, Osijek, Split, Šibenik, Zadar, Zagreb). Kako prikazuje slika ispod, možemo vidjeti da najveću neisplaćenu glavnicu od izabranih gradova ima Split čija suma neisplaćene glavnice iznosi – 981.527.657,6 kuna, iza nje je Zagreb sa -884.996.796,3 kune. Najmanju neisplaćenu glavnicu ima Osijek sa -125.488.135,8 kuna. Ovaj izvještaj

prikazan je pomoću strukturnog kruga. Izvještaje možemo prikazati i pomoću dijagrama što prikazuje Slika 18 gdje smo analizirali visinu neisplaćene glavnice po broju klijenta. Prema slici, možemo vidjeti da smo izabrali nekoliko nasumično odabranih klijenata. Vidimo da je najveću neisplaćenu glavnicu od odabranih klijenata imao klijent 2100840674. Iza njega je klijent 5100040660 čija je neisplaćena glavnica 500000 kuna. Slika 19 prikazuje izvještaj o vrsti i visini kamatne stope (fiksna i varijabilna kamatna stropa) po broju klijenta. Odabrano je nekoliko klijenata. Vidimo da su varijabilne kamatne stope prikazane u svjetlijoj boji od fiksnih kamatnih stopa.

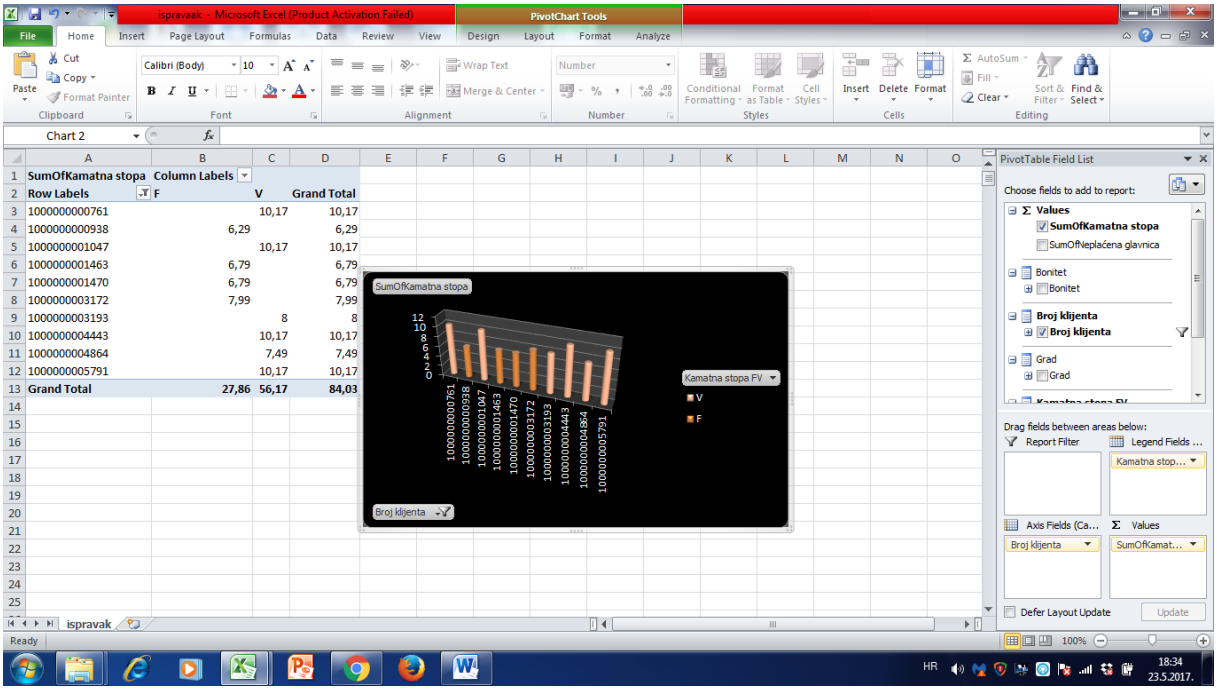


Row Labels	SumOfNeplaćena glavnica
DUBROVNIK	-46935465,93
IMOTSKI	-29746779,28
OSIJEK	-125488135,8
SPLIT	-981527657,6
ŠIBENIK	-51195196,48
ZADAR	-213610430,3
ZAGREB	-884996796,3
Grand Total	-2333500462

Slika 16: Izrada izvještaja o neisplaćenoj glavnici po gradovima



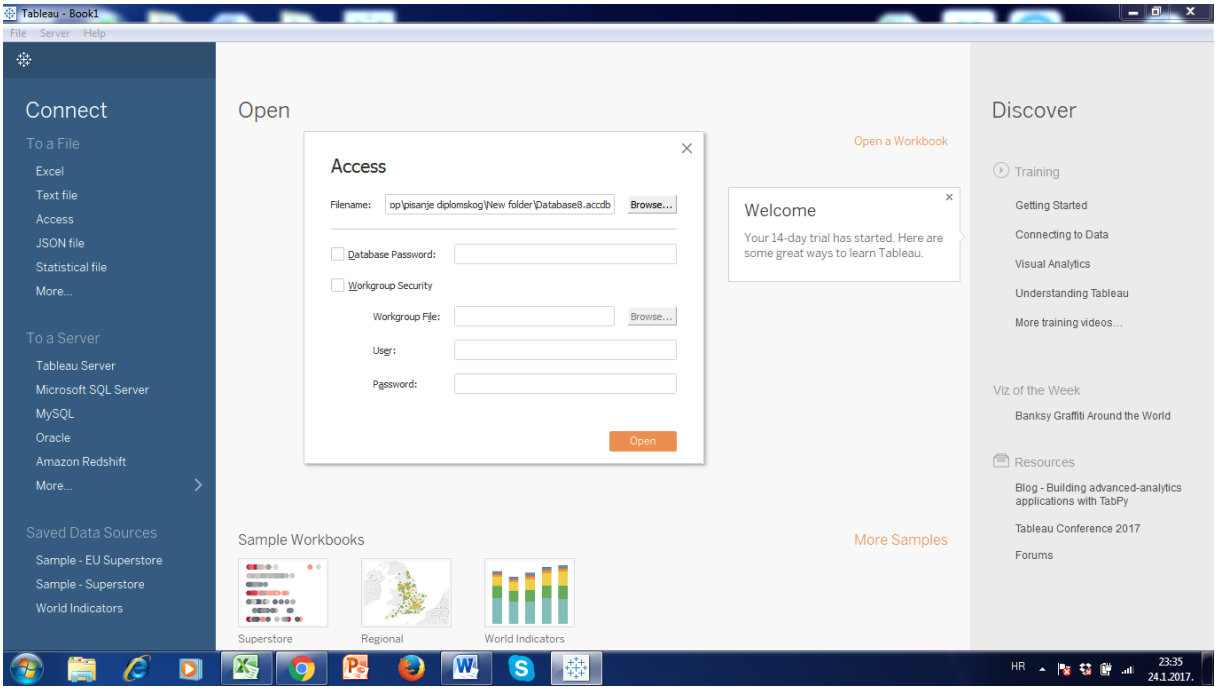
Slika 17: Izrada izvještaja o visini neisplaćene glavnice po broju klijenta



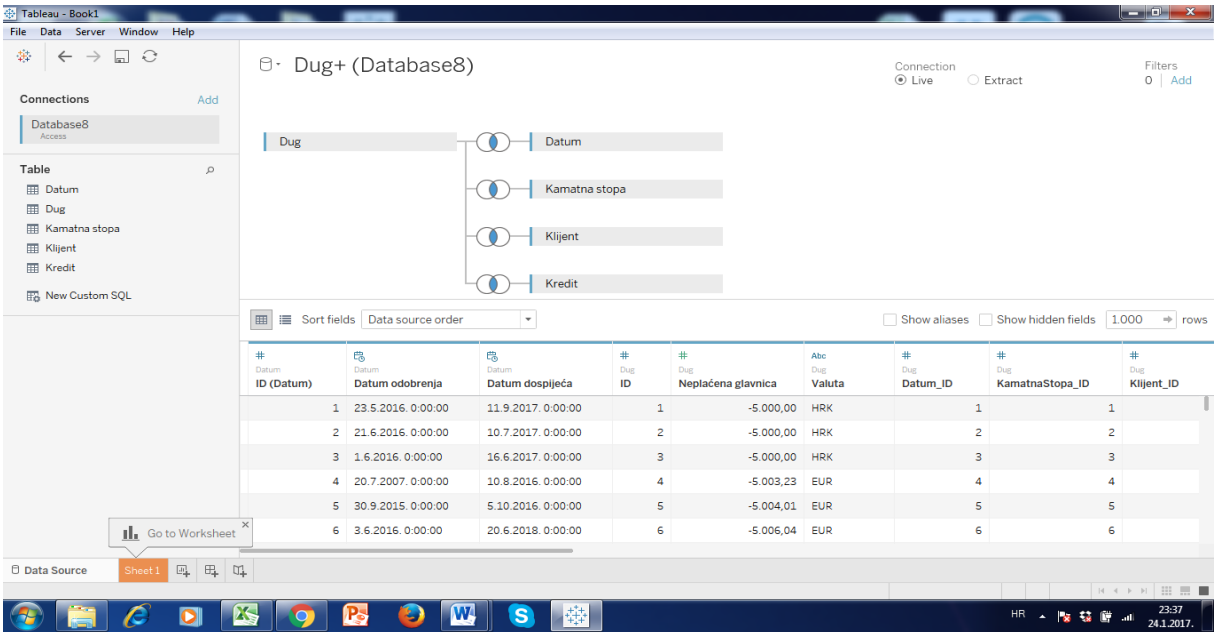
Slika 18: Izrada izvještaja o vrsti i visini kamatne stope po broju klijenta

4.3.2 Vizualizacija

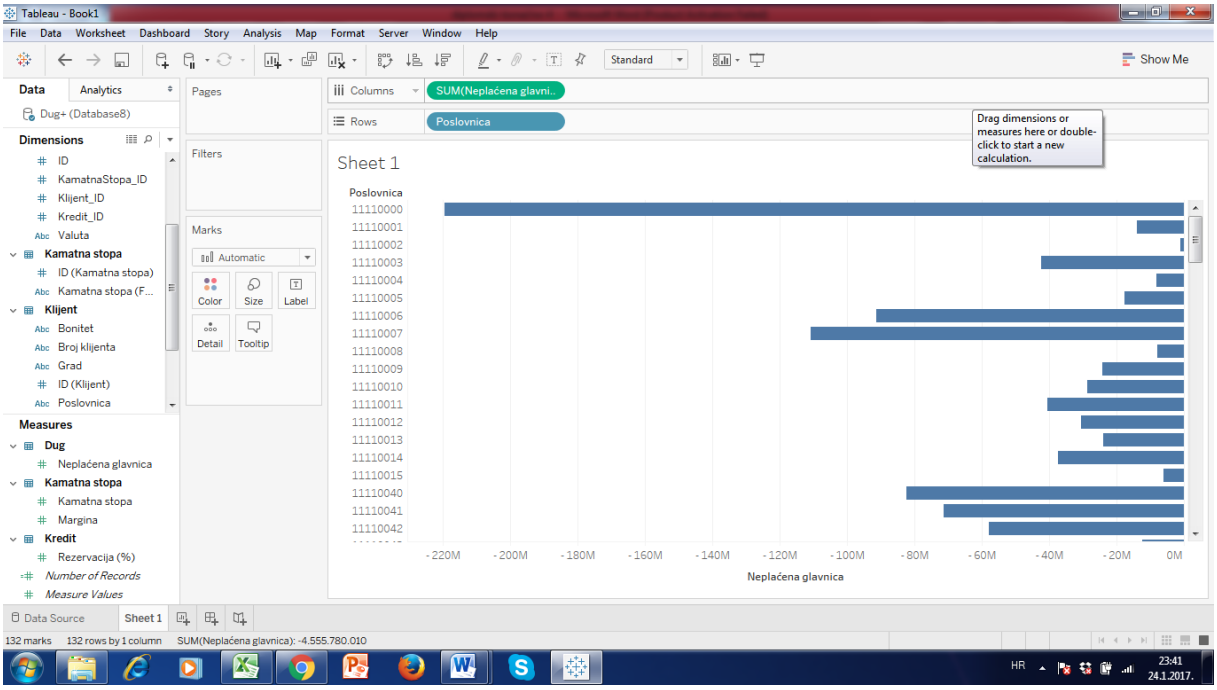
Za vizualizaciju sam izabrala alat Tableau jer je jako jednostavan za korištenje i brzo se nauči raditi u tom alatu . Prvi korak nakon instalacije alata je importiranje baze podataka iz Accessa. Nakon toga jednostavno možemo izabrati tablice koje ćemo koristiti za analizu. Slika 22 prikazuje vizualizaciju neisplaćene glavnice po poslovnicama. Možemo vidjeti da poslovnica 1111000 ima najveću neisplaćenu glavnicu. Iza nje je poslovnica 11110007. Najmanju neisplaćenu glavnicu ima poslovnica 11110002. Slika 23 prikazuje visinu kamatne stope po klijentima. Izvještaj na ovoj slici prikazan je pomoću krugova. Opet je nasumično izabrano nekoliko klijenata i prikazana je visina kamatne stope njihovih kredita. Od izabranih klijenata najmanju kamatnu stopu ima klijent 1000000000938 a ona iznosi 6,290 . Najviša kamatna stopa je 10,170 a tu kamatnu stopu imaju četiri klijenta od deset kojih su izabrani.



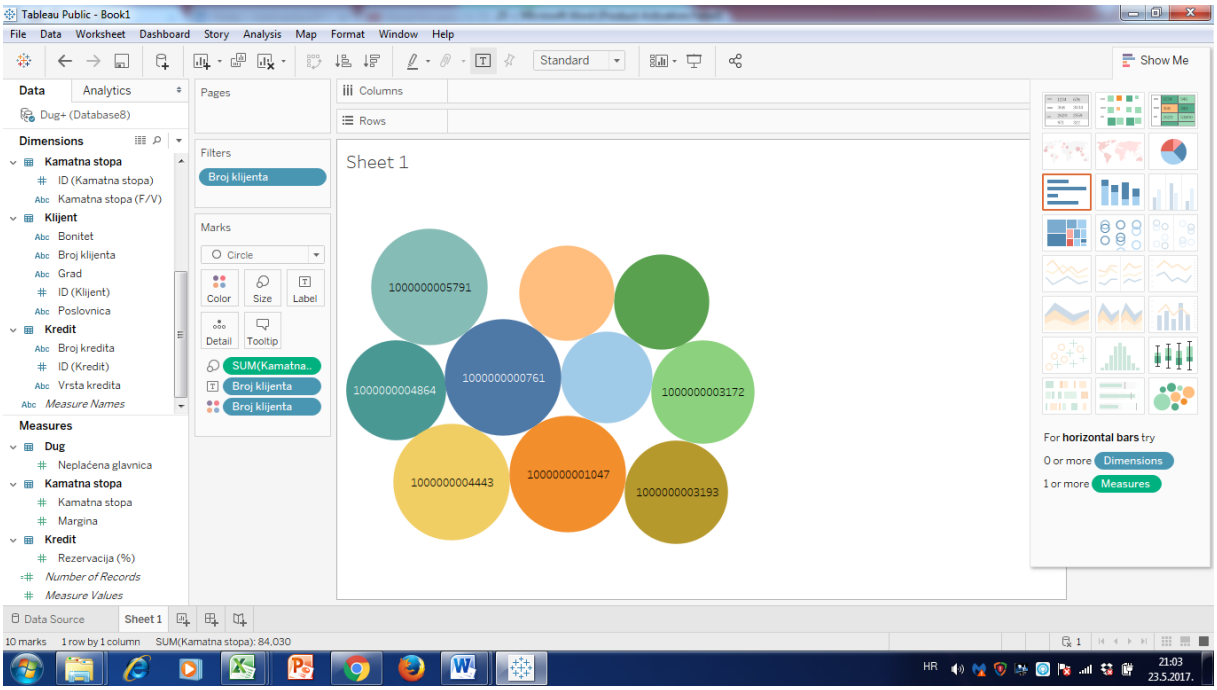
Slika 19 : Importiranje baze podataka



Slika 20 : Odabir tablica za analizu



Slika 21 : Vizualizacija neisplaćene glavnice po poslovnicama



Slika 22: Vizualizacija visine kamatne stope po klijentima

4.4 Zaključne analize i primjena u poslovnoj praksi

Moderna tehnologija bazirana na informacijskim sustavima donosi poboljšanje značajki s naglaskom na kvalitetu podataka što smo upravo pokazali u ovom istraživanju.

U ovom radu smo pokazali kako uz pomoć korištenih alata možemo lako doći do potrebnih podataka i informacija koji su važni za daljnje poslovanje. Napravili smo analizu duga prema banci odnosno neisplaćene glavnice od strane različitih sektora stanovništva. U radu smo formirali bazu podataka, izradili kocku te na kraju smo dobili potrebne izvještaje i vizualizaciju.

Na temelju izvještaja i analize možemo donijeti zaključak. Najrizičniji sektor stanovništva od odabranih varijabli je sektor stanovništva grada Splita. Na drugom mjestu po visini neisplaćene glavnice odnosno po rizičnosti se nalazi grad Zagreb. Treće mjesto zauzimaju stanovnici grada Zadra. Također smo napravili analizu visine neisplaćene glavnice po klijentima i visine kamatne stope po klijentima. Vidimo da je najveću neisplaćenu glavnicu od odabranih klijenata imao klijent 2100840674. Iza njega je klijent 5100040660 čija je

neisplaćena glavnica 500000 kuna. Na ovaj način se lakše dobila informacija o klijentima koji imaju najveću neisplaćenu glavnicu. Kad bi se to radilo bez alata bilo bi potrebno jako puno vremena za usporedbu i analizu željenih varijabli s obzirom da se radi o ogromnoj količini podataka.

Na temelju analize i istraživanja koje smo proveli možemo donijeti zaključak o prihvaćanju hipoteze koju smo na početku rada postavili a to je da se primjenom metoda poslovne inteligencije može unaprijediti efikasnost upravljanja kreditnim rizicima u bankama. Hipoteza se prihvaća na temelju rezultata provedene analize gdje možemo zaključiti kako uz pomoć alata poslovne inteligencije možemo uvelike skratiti vrijeme procesa donošenja odluka i unaprijediti efikasnost upravljanja kreditnim rizicima s obzirom da smo na ovaj način lakše analizirali željene varijable i dobili potrebne izvještaje za donošenje odluka koje su potrebne u poslovima banke. Na ovaj način smo dokazali da koristeći alate možemo lakše analizirati varijable, odabrati samo one varijable koje želimo istražiti, lakše ih usporediti te na taj način uvelike skratiti vrijeme.

Rezultati ovog istraživanja jako su nam bitni u procesima donošenja odluka kao i u analizi klijenata. Ovo istraživanje koristit će bankarskom sektoru u procjeni formiranja novih paketa davanja kredita. Na ovaj način banka će moći formirati prikladne uvjete kredita koje će davati sektorima stanovništva. Baza podataka koju smo koristili prilikom ove analize jako je koristila u daljnjem poslovanju ove financijske institucije i pomogla u ocjeni kreditnog rizika različitih sektora stanovništva. Ovo istraživanje nam je koristilo jer smo došli do zaključaka koji sektori stanovništva i koji klijenti su rizičniji. Uz pomoć poslovne inteligencije banka može na vrijeme reagirati i smanjiti rizik neisplate kredita od strane klijenata. Ovo istraživanje predstavlja samo jedan primjer u unaprjeđenju poslovnih procesa bankarskog sektora. Već prije opisana područja u kojima se može primijeniti poslovna inteligencija također se mogu unaprijediti korištenjem alata i na taj način može se doći do ključnih rezultata i zaključaka.

Važnost pravilnog upravljanja i analize informacija danas je prepoznata od mnogih kompanija koje je uspješno primjenjuju. Vidjeli smo kako banke iz godine u godinu uvode nove tehnologije koje unaprjeđuju njihovo poslovanje. Uvođenje poslovne inteligencije uvelike pomaže ovoj kompaniji s mnoštvom podataka koje se iz godine u godinu povećavaju s

obzirom da ove kompanije prema zadnjim podacima imaju sve veći broj klijenata i s obzirom da namjeravaju uvoditi neke nove inovacije kako bi bile u koraku s vremenom.

4.5 Usporedba alata Excel i Tableau

U ovom radu su se koristila dva alata za vizualizaciju: Tableau i Excel. Ovi alati su odabrani iz razloga jer je Tableau jako jednostavan za učenje i korištenje a Excel je alat koji je najčešće korišten od strane korisnika. I Excel i Tableau su dva alata koja se koriste za analizu podataka a na ovaj način smo pokazali da se za ovu svrhu mogu koristiti različiti alati. I jedan i drugi su praktični i prikazuju tražene rezultate. No, ipak postoje i neke razlike među njima. Svaki od njih ima drugačiji pristup istraživanju podataka. Iako je Excel češće korišten Tableau ima neke veće prednosti. [59]

Postoje tri najvažnije karakteristike po kojima možemo usporediti ova dva alata.

- Otkrivanje podataka: Kod Excela je potrebno unaprijed imati predodžbu gdje bi podaci trebali voditi da bi pronašli ključne odgovore. Excel sprema podatke u tabličnom formatu što znači da put do krajnjih rezultata uključuje mapiranje odgovora, izgradnju formula i vizualizacije te konačno analizu podataka. Sve to uzrokuje da je proces manje fleksibilan što otežava istraživanje. Tableau za razliku od Excela omogućuje slobodno istraživanje podataka bez da moramo unaprijed znati rezultat. Tableau ima ugrađene značajke koje daju mogućnost da se mogu vidjeti korelacije i trendovi.
- Automatska funkcionalnost: I Excel i Tableau mogu raditi sa statičnim podacima. U Excelu osvježavanje radnog lista omogućuje automatsko ažuriranje podataka radnog lista kad se otvori datoteka. Jednostavnije naredbe se mogu izraditi pomoću programa Excel Power Pivot dok one složenije zahtjeva znanje Visual Basic aplikacije. Stvaranje naredbi može biti dugotrajno, ali smanjuje vrijeme potrebno za dugoročno ispunjavanje zadataka koji se ponavljaju. Tableau je malo drugačiji u stvaranju procesa. Na primjer, prilikom izrade izračuna u tabličnom obliku, formula se može upisati jednom, pohraniti

[59] Minnesota Society of Certified Public Accountants: Excel vs. Tableau Which bi tool is right for you?: http://www.mncpa.org/publications/footnote/2015-05/excel-vs-tableau.aspx

kao polje i primijeniti na sve retke koji se odnose na taj izvor. To olakšava izradu i primjenu ponavljajućih procesa. Fleksibilnost tablice također omogućuje korisnicima stvaranje prilagođenih formula koje nisu dostupne u programu Power Pivot tablice programa Excel.

- Vizualizacija: U Excelu je prvo potrebno manipulirati podacima na razini ćelija a zatim napraviti ručno vizualizaciju u obliku grafikona, grafova, prezentacija... Za pojednostavljenje vizualizacije, treba duboko razumjeti kako funkcioniraju Excelove značajke. Tableau vizualizira podatke od početka, što omogućuje da se njihovo značenje odmah vidi. Tableau razlikuje korelacije pomoću boje, veličine, oznaka i oblika što olakšava analizu podataka.[60]

Excel omogućuje izradu grafikona, no ukoliko korisnik želi promijeniti izvor podataka ili vrstu grafikona, mora krenuti ispočetka. Kod Tableua nije takav slučaj. Tableau omogućuje brzo i jednostavno kreiranje grafikona - dodavanje podataka kao i njihovu izmjenu. Tableau ima prednost jer omogućuje praćenje točno određenih podataka koji se svi vide na istoj stranici u stvarnom vremenu. Omogućuje praćenje povezanih odnosa između ključnih analiza. Tableau je izgrađen za velike količine podataka i tu je ostvario bolji položaj od Excela kojemu treba više vremena za dobivanje rezultata. Standardna funkcionalnost u alatima za vizualizaciju tako i Tableau-a je ta da omogućuje pregledavanje podataka u mapi što nije dostupno u Excelu.[61] Mnogi korisnici Excela koriste različite komponente Excelove funkcije uključujući pivot tablice, sortiranje i filtriranje, te opsežan niz drugih funkcija. No, u mnogim slučajevima izvješća koja su generirana Excelom ne pružaju sve potrebne funkcije za uspješnu poslovnu inteligenciju. Iako većina korisnika pokušava koristiti Excel kao alat poslovne inteligencije, rezultati često nisu optimalni. Tableau nudi niz proizvoda za generiranje izvješća. Korisnicima omogućuje povezivanje s vanjskim izvorima podataka.

[60] Betterbuys (2017): Tableau vs excel: comparing core features and functions: https://www.betterbuys.com/bi/tableau-vs-excel/

[61] Numeric analitycs: Tableau vs. Excel- How do you know if you need to make the switch?: http://numericanalytics.com/tableau-vs-excel-how-do-you-know-if-you-need-to-make-the-switch/

Tableau je pogodan za one tvrtke koje imaju složenije potrebe. Ukoliko se razmišlja o implementaciji Tableua potrebno je planirati budžet zbog mogućih značajnijih troškova.[62]

Odluka o tome koji alat koristiti ovisi o budžetu kojim raspolažemo, o tipu izvještaja koji nam treba, o tome koliko često se izrađuju izvještaji. Excel je dobar za brzu izradu izvještaja i tijekom godina je znatno poboljšao svoje specifikacije i na taj način omogućio korisnicima bolju analizu podataka. Također je dostupan s Microsoft Officeom. No, vizualizacija i prezentacija zahtjeva naporedno poznavanje njegove funkcionalnosti. Tableau rješenje može biti skuplje ali se isplati uložiti ukoliko se radi više ponavljajućih izvještaja koji moraju biti brzo ažurirani. No unatoč svemu tome Excel je i dalje najčešće korišteni alat koji posjeduje vrijednost u manipulaciji podataka. Tu vrijednost je prepoznao i Tableau koji se može povezati s Excelom što omogućuje upotrebu dvaju rješenja za veće analize. No povezivanje dvaju alata dovodi do nekih poteškoća kao na primjer izvoz podataka iz Excela postaje prespor i težak što izaziva strah kod korisnika.[63]

Svakim danom se dolazi do raznih inovacija i unaprjeđenja u svim područjima tako i u području poslovne inteligencije. Mnogo proizvođača je razvilo niz alata koji pomažu u analizi i obradi podataka. Svaki od njih ima svoje prednosti, drugačiji proizvod i svaki od njih odgovara potrebama različitih sektora. No, na pitanje koji alat izabrati nema točnog odgovora. Sve ovisi o željama i potrebama samog korisnika. [64] Iz tog razloga je najbolje odabrati alat koji najbolje odgovara potrebama i zahtjevima.

4.6 Ključni doprinosi alata poslovne inteligencije u kontroli rizika

Prema istraživanju autora Pejić-Bach et al. poslovna inteligencija je danas jedno od najboljih inovativnih „oružja“ za tvrtke koje žele postići konkurentsku prednost. Njezina primjena u bankarskim institucijama postaje sve važnija zbog primjene Basel 2 regulacije koje Europska

[62] Minnesota Society of Certified Public Accountants: Excel vs. Tableau Which bi tool is right for you?: http://www.mncpa.org/publications/footnote/2015-05/excel-vs-tableau.aspx

[63] Betterbuys (2017): Tableau vs excel: comparing core features and functions: https://www.betterbuys.com/bi/tableau-vs-excel/

[64] Ekonomski portal (2010) : Poslovna inteligencija: zašto, što i kako? http://ekonomskiportal.com/poslovna inteligencija-zasto-sto-i-kako/

unija traži od svih zemalja. Basel 2 predstavlja bankarske propise koje određuje Baselski odbor za bankarski nadzor.[65]

Koristeći rješenja poslovne inteligencije banke mogu pojednostavniti i poboljšati procese upravljanja rizicima. Kod svakog ulaganja ili davanja zajma postoji rizik od gubitka novca. Alati poslovne inteligencije imaju uvid u transakcije i ostale informacije vezane za klijente kao i ostala ključna područja kako bi se ublažili rizici.[66] U promjenjivom i neizvjesnom financijskom svijetu bankovne institucije se sve više trebaju oslanjati na činjenice utemeljene na djelotvornim informacijama kako bi se smanjio rizik gdje je god to moguće. Prema istraživanju autora Lacha, rizici se mogu ublažiti pomoću rješenja poslovne inteligencije. Može se brzo i učinkovito otkriti i smanjiti incidenti lažne aktivnosti (kao na primjer prijevare s kreditnim karticama) praćenjem povijesti transakcija klijenta. Omogućuje točnu procjenu rizika na temelju financijske imovine i visine plaće klijenta. Poslovna inteligencija se također koristi za analizu kreditnih izvješća i otkrivanje potencijalnih delinkvencija, tako da se unaprijed mogu poduzeti preventivne radnje. Analiza podataka može otkriti delinkvencije kod klijenata, gdje se mogu razviti nove politike kako bi se ublažile stope slučajeva delinkvencije u budućnosti. Poslovna inteligencija poboljšava učinkovitost poslovanja i povećava profit kompanije.[67] Bez primjene poslovne inteligencije analiza podataka bi trajala mjesecima što bi za bankarsku instituciju predstavljalo velik problem jer bi izgubila dosta vremena ali i dobila manje kvalitetne podatke za donošenje važnih odluka. Vrijeme je danas jako važna komponenta u poslovnim procesima i ovime bi došlo do zaostajanja za konkurencijom. Iz tog razloga rješenja poslovne inteligencije predstavljaju nužnost za upravljanje procesima rizika. Rizici su područje u kojima se moraju predvidjeti buduće situacije i djelovati unaprijed a to omogućava samo poslovna inteligencija.

[65] Pejić-Bach,M., Šarlija,N.,Jaković,B.(2008.): Business Intelligence and Risk Management: Case Study of Croatian Banking Sector

[66] Sesame inspire innovate (2017) : 5 ways business intelligence software can benefit banks: https://www.sesameindia.com/blog/5-ways-business-intelligence-software-can-benefit-banks/

[67] Lach, J. (2011): Business intelligence for the finance and banking sector: https://www.yellowfinbi.com/blog/2011/02/yfcommunitynews-business-intelligence-for-the-finance-and-banking-sector-102389

5. RIZICI I PERSPEKTIVE PRIMJENE SUSTAVA POSLOVNE INTELIGENCIJE

Danas veliki problem predstavlja zaštita važnih podataka i informacija što predstavlja bitan dio poslovne inteligencije i njene primjene u kompanijama. Iz tog razloga istražit ćemo probleme zaštite podataka i načine na koje se ona danas primjenjuje. U ovom poglavlju istražit ćemo efikasnost primjene poslovne inteligencije u tvrtkama kao i njenu ulogu u globalnom natjecateljstvu.

5.1 Pretpostavke efikasne primjene sustava poslovne inteligencije u poslovnim procesima i odlukama

Odluka se smatra kvalitetna ukoliko je donesena u pravom trenutku odnosno na vrijeme te na taj način omogućuje ostvarenje ciljeva i realizaciju strategije. Brzina donošenja odluka ima veliku važnost , možemo reći da je to jedan od faktora presudne važnosti za budućnost tvrtke i za ostvarenje njene konkurentne prednosti. Prije je vrijeme za bilo koju akciju ili korak bilo puno duže za razliku od danas kad se s vremenom sve više skraćuje. Kada nedostaju podaci koji su dostupni u pravom trenutku, menadžment se oslanja na svoju vlastitu intuiciju. Ukoliko se nove informacije ne razmjenjuju unutar samog poduzeća dolazi do toga da se donose odluke na temelju zastarjelih informacija. S obzirom da kompanije najviše vremena utroše na prikupljanju informacija dok ostali, manji udio se odnosi na njihovu analizu, potrebno je raditi na tome da se skrati to vrijeme prikupljanja podataka. Glavni cilj je zapravo ubrzati proces donošenja odluka i tu svoju ulogu zauzima poslovna inteligencija koja donosi samo one informacije koje su potrebne te na taj način sve to rezultira boljom kvalitetom tih podataka. Danas se sve poslovanje okreće informacijskom sustavu ističući znanje kao fokus iz kojeg proizlazi moć.

Da bi neki podaci bili kvalitetni za donošenje odluke potrebno je da ti podaci zadovoljavaju nekoliko uvjeta:

- jednostavnost upotrebe,
- prilagodljivost,
- učinkovitost,

- neovisnost o računalnoj platformi,
- ekonomičnost.

Poslovna inteligencija pruža informacije koje su potrebne svim razinama menadžmenta. Na ovaj način poboljšava produktivnost i pruža bolju učinkovitost svih korisnika kompanije. Prema jednom istraživanju, tvrtka analizira samo 10% informacija, dok ostalih 90% obavi poslovna inteligencija. Koliki značaj ona ima za tvrtku govori istraživanje koje je dokazalo kako poduzeća koja koriste alate poslovne inteligencije bilježe veći rast prihoda nego kompanije koje u svom poslovanju ne koriste. Kako smo već opisali u prethodnim poglavljima, efikasnost primjene poslovne inteligencije očituje se u svim dijelovima i poslovnim procesima koji su značajni za poslovanje. Poslovni procesi čine glavninu jer njihove akcije i radnje dovode do željenog rezultata. Kako bi se posao uspješno obavio potrebno je procese izvršavati na kvalitetan i brz način u što kraćem vremenskom roku. Prema istraživanju Luetić i Šerić, poslovna inteligencija pruža mogućnost predviđanja, mogućnost ranog otkrivanja prijetnji i prilika, pomaže poduzeću da održava svoj opstanak konkurentnije od drugih tvrtki na način da smanjuje dosadašnje prevelike troškove kao i vrijeme te tako dovodi do unaprjeđenja poslovanja i dovođenja do uspješnijih poslovnih rezultata. [68]

5.2 Zaštita podataka i informacija

Informacije i podaci imaju jako veliku vrijednost i značenje za samu kompaniju i za njeno poslovanje te iz tog razloga tvrtka ih mora čuvati i štititi na efikasan i siguran način. Sve te informacije je potrebno zaštititi od svih onih koji nisu autorizirani za njihovo korištenje s ciljem provođenja sigurnosti i sprječavanja rizika od gubitka tih podataka koje posjeduje kompanija kao i ostalih mogućih prijetnji. Kako smo već na početku opisali poslovnu inteligenciju kao špijunsko područje, ovaj dio zaštite poslovnih informacija može se nazvati obrambena ili defenzivna inteligencija. Jelens razlikuje ove dvije inteligencije. Prema njemu, defenzivna inteligencija se sastoji od :

- otkrivanja inteligencije aktivnosti protivnika odnosno kontraobavještajne aktivnosti,
- obrana od pokušaja protivnika ili provođenje sigurnosnih protumjera,

[68] Luetić, A., Šerić, N. Op.cit, str. 172.-175.

- operativne sigurnosti gdje se protivniku uskraćuju dokazi o izvršenju aktivnosti.

Dok autori McGonagle i Vella navode kako se obrambena inteligencija sastoji od aktivnosti:

- nadgledanje informacija,
- preporuka načina kontrole upravljanja osjetljivim informacijama,
- evaluacija konkurentskih aktivnosti.

Glavni cilj ovih aktivnosti je procjena mogućih opasnosti i zaštita poslovnog subjekta od napada konkurencije.

Ovaj proces se sastoji prema autorima Barrett i Nolan, od nekoliko faza. Prva od tih faza je ta da je potrebno odrediti što se treba zaštititi i odrediti tehnologiju pomoću koje bi se taj cilj realizirao. U idućoj fazi je potrebno procijeniti inteligenciju sposobnosti drugih poslovnih subjekata te također procijeniti kako oni ugrožavaju interese same kompanije. Treća faza je faza procjene ranjivosti kompanije. Slijedeća faza podrazumijeva dizajniranje i razvoj protumjera. Peta faza je faza u kojoj se ocjenjuje učinak poduzetih mjera. Šesta faza je distribucija gdje se menadžmentu dostavljaju analitičke procjene.

Kahaner ističe kako je važno identificirati svaku informaciju kako bi se provela prikladna zaštita. Važno je identificirati one informacije koje su konkurenciji potrebne kako bi stekle određenu prednost. Isto tako bitno je analizirati sposobnosti klijenta kao i provesti analizu vlastite ranjivosti odnosno mogućnosti curenja bitnih informacija. Analiza mogućih posljedica ukoliko konkurencija dođe do tih važnih informacija također je jako bitan korak u procesu zaštite podataka.

Bernhardt navodi da je važno postaviti nekoliko pitanja kako bi kompanija znala koliko je spremna zaštititi i obraniti podatke koje posjeduje. Potrebno je saznati što konkurenti žele saznati i zašto. Važno pitanje je i na koji način to žele postići. Također, važno je postaviti pitanje koje mjere se poduzimaju kako bi se spriječilo poduzimanje tih aktivnosti konkurencije.

Navodi i nekakve moguće naznake po kojima kompanija može prepoznati da neka tvrtka želi doći do njihovih informacija i podataka:

- zaposlenici važni za kompaniju odlaze u konkurentsku tvrtku,
- na raznim natječajima kompaniju pobjeđuju uvijek isti konkurenti,
- tvrtka dobiva upite o projektima i poslovnim tajnama od nepoznatih strana kao što su nekakvi istraživači,
- krađa računala ili krađa jako povjerljivog materijala,
- unutar kompanije su postavljeni nekakvi uređaji za prisluškivanje,
- konkurenti su upoznati s povjerljivim poslovima i strategijama tvrtke,
- konkurenti uvijek lansiraju prije kompanije proizvod koji je sličan onome kojeg je kompanija namjeravala lansirati prva,
- kompaniju posjećuju serviseri bez ikakvog poziva,
- kompanija zaprima upite o posjetu stranih delegacija.

Istraživanje koje je provedeno od strane autora Calofa pokazuju kako je zaštita informacija i podataka poduzeća na zadovoljavajućoj razini no glavni problem koji se javlja je taj da poduzeća slabo procjenjuju aktivnosti poslovne inteligencije koje se provode protiv njih. Jedno drugo istraživanje koje je proveo ASIS (American Society for Industrial Security , odnosno američko udruženje za industrijsku sigurnosti) dokazalo je da zaštita podataka pada ukoliko dođe do toga da kompanija poveća troškove, ako se smanji njezina konkurentska prednost i ako se smanji njezin tržišni udio. Inače, najčešći oblik zaštite informacija prema Barrieru je da zaposlenici potpisuju dokumente o povjerljivosti odnosno zaštiti podataka. Kako bi zaštita podataka bila sigurnija i učinkovitija potrebno je, prema autoru Bernhardtu educirati zaposlenike, ocijeniti ranjivost sustava te poduzeti obrambene mjere između zaposlenika.[69]

[69] Luetić, A., Šerić, N.(2009): Business Intelligence u funkciji upravljanja opskrbnim lancem, Sveučilište u Splitu, Ekonomski fakultet, Split, str. 76.-81.

5.3 Perspektiva primjene poslovne inteligencije u unapređenju poslovanja i globalnom tržišnom natjecateljstvu

Poslovna inteligencija se može primijeniti u svakom segmentu i može je primijeniti svaka poslovna organizacija. Kako su tvrtke različite jedna od druge, svaka od njih za sebe zahtjeva posebna rješenja poslovne inteligencije. Bitno je istaknuti da su se poduzeća godinama opirala uvođenju nove tehnologije i modernizaciji, no u konačnici su bili prisiljeni ulagati u ovaj sustav. Glavnu osnovu svega čini poslovna inteligencija te današnje suvremene kompanije koje ne mogu zamisliti donošenje poslovnih odluka bez korištenja alata poslovne inteligencije.

Kruljac donosi zaključak da se uz pomoć poslovne inteligencije kojeg koriste poduzeća diljem svijeta, danas mogu predvidjeti prijetnje i prilike koje dolaze iz okoline, kao i globalni trendovi. Na ovaj način poduzeća su shvatila da mogu iskoristiti svoje potencijale i smanjiti rizik te povećati svoju efektivnost i efikasnost. Kompanije ovako pozitivno utječu na cjelokupno gospodarstvo. Poslovna inteligencija danas je postala glavna komponenta za unaprjeđenje poslovanja svake kompanije.[70] Poslovni tok neke tvrtke sastoji se od mnoštva koraka odnosno zasebnih poslovnih procesa. Poslovna inteligencija tu ima veliku ulogu jer podržava donošenje odluka u svakom dijelu tih procesa. Poslovna inteligencija ubrzava sami proces i unaprjeđuje poslovanje na način da pronalazi područja koja se mogu poboljšati. Poslovna inteligencija unaprjeđuje niz područja u tvrtkama pa tako unaprjeđuje i područje podrške kupcima. Ova podrška se očituje u povećanju profita. Osim tih područja, poslovna inteligencija se proširila i na mnoga druga područja u politici, sportu, zdravstvu... Važnost njezine primjene u unaprjeđenju poslovanja s godinama je prepoznata od mnogih svjetskih korporacija i to kao jedan od najvažnijih prioriteta.[71]

Najvažnija karakteristika suvremenog poslovanja je karakteristika jačanja tržišne konkurencije. Pravi i veliki izazov za svaku kompaniju predstavlja ostvarenje prednosti s obzirom na ostale konkurente a najveću ulogu uz ostale subjekte, u tome ima informacija. Tvrtke žele doći do informacija o konkurentima. Informacije koje se žele saznati su zapravo

[70] Kruljac, F. Op.cit, str 30

[71] Juračić O. Op.cit, str.7-8.

podaci o ciljevima konkurencije, njihovim planovima, informacije o zaposlenicima kao i informacije o slabostima i jakim stranama. Sve to se može prikupiti na temelju lažnih upita toj kompaniji, na raznim skupovima i događanjima. Poduzeća koriste poslovnu inteligenciju s ciljem dolaska do važnih informacija a sve to kako bi konkurenciji preoteli tržište i učvrstili svoju poziciju na tržištu. Najvažniji izvori informacija su : javno dostupni materijal, unutarnje informacije, informacije koje su nastale kao posljedica osobnog kontakta. Na raspolaganju stoji niz alata koji pomažu istraživačima. Potrebno je poduzeti niz akcija nakon prikupljanja informacija s glavnim ciljem donošenja odluka i vrednovanja trenutnog položaja kako bi se stekla bolja pozicija u konkurentskom okruženju i ostvarila veća konkurentska prednost.

Iz tog razloga ovakva inteligencija se naziva kompetitivna inteligencija koja je nastala kao posljedica globalizacije i „umrežavanja“ svijeta i postala je glavna karakteristika današnjeg poslovanja suvremenih kompanija.[72]

Suvremeni sustavi poslovne inteligencije više se ne fokusiraju na prošle događaje već im je glavni cilj predvidjeti one koje dolaze u budućnosti, dakle dobiti odgovor na pitanje što učiniti ako se nešto dogodi? Iz tog razloga možemo zaključiti kako poslovna inteligencija današnjim kompanijama pomaže da ostvare kompetitivnu prednost s obzirom na konkurentska poduzeća kao i povećanje profita. [73]

Ako i dalje žele ostati u koraku s vremenom i ostalim konkurentnim tvrtkama, kompanije se moraju sve više okrenuti sustavu poslovne inteligencije u budućnosti koja će se i dalje razvijati a sve to s ciljem kako bi vodila do unaprjeđenja poslovanja. Korisnici sve više traže poslovnu inteligenciju u realnom vremenu i traže svježe informacije koje su dostupne u svakom trenutku. Činjenica je da će kompleksnost informacija i dalje rasti te će potreba za novim rješenjima biti još veća. Ta nova rješenja bi trebala omogućiti da u isto vrijeme korisnici brzo istraže i analiziraju podatke a pri tome alati i dalje budu jednostavni za korištenje, da korisnici svoja znanja mogu podijeliti za drugim korisnicima, da se mogu kombinirati znanja i podatke unutar poslovne inteligencije. Ta nova inteligencija bi trebala korisnika osloboditi od kompleksnosti podataka i njihove nedostupnosti. Smatra se da

[72] Panian, Ž. et al. Op.cit, str 14-21.

[73] Strgačić, M. : To BI or not to BI : http://www.infotrend.hr/clanak/2012/12/to-bi-or-not-to-bi,76,984.html

poslovna inteligencija napokon postaje ono što bi trebala biti : „Jezgrena komponenta u neprekidnim pokušajima da se unaprijedi poslovanje i kojom vladaju sami korisnici.“[74]

[74] Juračić O., Op.cit, str 9-10.

6. ZAKLJUČAK

Poslovna inteligencija danas je dio poslovnog svijeta kako svih kompanija tako i bankarskih. Predstavlja najvažniju komponentu koja pomaže u odlučivanju i usmjeravanju firme na put koji vodi do ostvarenja već postavljenog cilja. O njenoj važnosti govore već spomenuti povijesni podaci koji svjedoče o postojanju poslovne inteligencije još u davnim povijesnim vremenima. Razvijanje te više ne tako mlade grane dovelo je do upotrebe jako korisnih alata koji uvelike olakšavaju rad i skraćuju vrijeme obavljanja rada. Svakim danom ti alati se unaprjeđuju i dobivaju neku novu funkciju čime dodatno postižu poboljšanje rada u tim alatima. Poslovna inteligencija s vremenom je postala nužnost u svim kompanijama koje žele biti u koraku s konkurencijom odnosno u tržišnom natjecateljstvu. Puno je lakše djelovati u okolnostima koje su se predvidjele na temelju prikupljenih informacija što zapravo predstavlja pravu zadaću poslovne inteligencije a to je predvidjeti što se očekuje u budućnosti. Poslovna inteligencija donosi niz prednosti u svim poslovnim procesima banke čime donosi učinkovitost i efikasnost tvrtke te produktivnost zaposlenika. Riječ efikasnost je jako važna u poslovnom svijetu jer označava da se uz što manje korištenje resursa dobiju bolji rezultati što predstavlja cilj svake kompanije. U ovom radu je prikazano kako uz pomoć raznih alata možemo doći do potrebnih izvještaja. Ti alati su jako korisni jer se ti izvještaji mogu prikazati i vizualno što dodatno olakšava donošenje važnih zaključaka i poslovnih odluka. Danas je na tržištu dosta proizvođača različitih alata s različitim specifikacijama. Korisnici mogu izabrati onaj alat koji će najviše odgovarati njihovim potrebama.

Vidjeli smo da rizici predstavljaju najvažnije područje kojem banke daju posebnu pozornost. Rizik se definira kao mogućnost dolaska do neželjenog događaja za razliku od onog koji je poželjan i očekivan. Danas postoji niz rizika koje treba neprestano pratiti i analizirati kako bi se spriječile neželjene situacije. Poslovna inteligencija ima jako bitnu ulogu u tome jer koristeći alate može se doći do vrlo korisnih rezultata i zaključaka kako bi se ti rizici regulirali i kako bi se predvidjeli budući događaji. Alati poslovne inteligencije su jako korisni u reguliranju rizika jer skraćuju vrijeme analize i obrade podataka koji su ključni kako bi se kontroliralo stanje i kako ne bi došlo do neočekivanih situacija. Pokazali smo kako vrijeme obrade i analize podataka ne uzima previše vremena kad koristimo alate poslovne

inteligencije. Osim toga, uz pomoć njih dobivamo kvalitetne podatke koji su korisni za donošenje odluka. Bez alata, taj proces bi trajao mjesecima a kompanije ne bi mogle na vrijeme spriječiti rizike odnosno neželjenu situaciju. U ovom radu smo pokazali primjer da na temelju rezultata se može vidjeti koji sektori stanovništva su rizičniji i može se donijeti odluka o novim uvjetima kredita za sektore stanovništva.

U ovom istraživanju je korišteno nekoliko alata koji su uvelike olakšali analizu velike količine podataka. Pomoću ovih alata smo dokazali da korištenje poslovne inteligencije ima značajnu ulogu u poslovnom svijetu svih kompanija. Provela se analiza duga sektora stanovništva prema banci. Najprije je bilo potrebno formirati bazu podataka u Microsoft Accessu zatim izraditi kocku koristeći alat BI-Lite Cube-It Zero te na samom kraju dobiti izvještaje u Excelu koji su vizualno prikazani kako bi se lakše mogli analizirati potrebni podaci. Vizualizacija se provela koristeći alat Tableau. Na ovaj način je dokazano kako su korišteni alati pojednostavnili obradu ogromne količine podataka i samim time skratili vrijeme te obrade. Rezultati ovog istraživanja pokazali su koji klijent ima najveći dug, zatim se uspoređivala zaduženost različitog sektora stanovništva odnosno koji grad je najviše zadužen. Između odabranih gradova najveću zaduženost su imali stanovnici grada Splita (prikazano na slici 16). Klijent koji ima najveću neisplaćenu glavnicu od odabranih klijenata je klijent 2100840674. Izvještaji su prikazani strukturnim krugovima, tablicama i u različitim bojama koje se mogu odabrati što ovisi o željama i preferencijama korisnika. Na kraju smo donijeli zaključak da se prihvaća hipoteza koju smo postavili na početku. Polazna hipoteza je glasila da se primjenom metoda poslovne inteligencije može unaprijediti efikasnost upravljanja kreditnim rizicima u bankama. Zaključak je donesen na temelju rezultata analize podataka. Hipoteza je prihvaćena iz nekoliko razloga. Na početku smo imali ogromnu količinu podataka. Uz pomoć korištenih alata pokazano je da se u jako malo vremena ti podaci mogu analizirati, dakle dobili smo iz velike količine podataka zaključak koji je grad najviše zadužen i koji klijent ima najveću zaduženost. Ta usporedba bez korištenja alata bi oduzela dosta vremena s obzirom da se radi o velikoj hrpi podataka. Mjerenje rizika se temelji na rangiranju klijenata i analizi pomoću više kriterija. U radu smo pokazali nekoliko kriterija koji su važni kod mjerenja rizika kao na primjer analizirali smo vrstu i visinu kamatne stope po klijentima (slika broj 18 koja prikazuje vrstu i visinu kamatne stope po broju klijenta), visinu neisplaćene glavnice po sektorima stanovništva i po broju klijenta (dokazuje slika 16 i slika

17). Na isti način se može analizirati i po drugim kriterijima važnim za upravljanje rizicima. Također, efikasnija analiza podataka se dokazala i na način da smo uz pomoć alata Tableau vizualno prikazali izvještaje (slika 21 i slika 22 vizualno prikazuju visinu neisplaćene glavnice i visinu kamatne stope) što je olakšalo samu analizu i dobiven je bolji uvid u podatke. Na ovaj način je pokazano da uz pomoć rješenja se postiže efikasnije mjerenje rizika i donošenje zaključaka važnih za njihovo upravljanje. Iz tih razloga je hipoteza prihvaćena. Dokazali smo da se može unaprijediti efikasnost upravljanja rizicima odnosno da se može utrošiti manje resursa i manje vremena uz pomoć alata. Banka može na vrijeme reagirati i smanjiti rizik neisplate kredita od strane klijenata koristeći rješenja poslovne inteligencije. Na samom početku smo definirali određene ciljeve ovog rada od kojih je jedan bio primijeniti i prilagoditi rješenja poslovne inteligencije na konkretnom primjeru kod upravljanja rizicima što smo i pokazali u ovom radu. Koristili smo nekoliko alata i analizirali rizične grupe sektora stanovništva i pokazali koji od njih imaju najveću zaduženost (dokazano na slici 16). Još jedan od postavljenih ciljeva je bio pokazati da se te metode mogu koristiti i u ostalim procesima bankarskog sektora. U teorijskom dijelu smo naveli koja sve područja bankarskog poslovanja mogu koristiti rješenja poslovne inteligencije. U ovom radu je prikazan primjer korištenja alata kod upravljanja rizicima a na isti način se može primijeniti i u drugim sektorima. Alati su jako korisni na primjer u marketingu na način da poslovna inteligencija na ovaj način može uvelike pomoći identificirati najvjernije klijente te prepoznati i uključiti one klijente koji su manje aktivni ili zainteresirani za bankarske usluge i imaju mogućnost vizualizacije svojih najplodnijih klijenata. Na isti način rješenja mogu biti korisna i u ostalim sektorima.

U radu je korišteno nekoliko metoda. Koristeći komparativnu metodu uspoređivali smo banku koja koristi poslovnu inteligenciju i koja ne koristi. Koristeći induktivnu i deduktivnu metodu donijeli smo zaključak o efikasnosti primjene rješenja poslovne inteligencije. Također smo koristili još neke metode a to je metoda analize i sinteze, metoda deskripcije te metodu modeliranja gdje smo izradili model primjene poslovne inteligencije u banci. Ovo istraživanje može uvelike pomoći i potaknuti sve bankarske institucije kao i druge kompanije da prate inovacije u poslovanju i da razumiju prednosti koje se ostvaruju uvođenjem poslovne inteligencije u poslovnom svijetu. Na ovaj način mogu uvidjeti da se svaki proces može efikasnije obaviti i uštediti na resursima te ostvariti poslovne ciljeve unaprjeđivanjem poslovnih procesa. Također ovaj rad može koristiti u daljnjim, novim istraživanjima i analizama na ovom području.

Postoji mnoštvo prednosti koje donosi poslovna inteligencija kao i razlozi zašto je ona najbolje rješenje za dobivanje odgovora u poslovnom svijetu. U današnjem suvremenom poslovanju informacija predstavlja ključnu komponentu koja se nalazi između propasti tvrtke i njenog opstanka na tržištu. Njeno značenje je bilo važno još u davnim vremenima kad su se prikupljali podaci za različite potrebe od kojih je tada u povijesno doba najvažnije bilo imati podatke za potrebe ratovanja. Analiza podataka bez poslovne inteligencije znači potrošiti mjesece rada kako bi se izvukla potrebna informacija i donijela važna odluka za poslovanje kompanije. Sve to znači gubitak vremena. Danas je vrijeme novac a u ovom slučaju se zaostaje za konkurencijom i dovodi se do pitanja opstanka na tržištu. Ovo predstavlja jedan od glavnih razloga zašto je poslovna inteligencija najbolje rješenje za poslovne odluke. Prije nego što je postojao ovakav način obrade podataka sve odluke su se donosile na temelju intuicije što znači da su riskirali svoje poslovanje. Svaka kompanija teži da svakim danom rad tvrtke bude bolji nego prije , da se unaprjeđuje rad zaposlenika i poslovnih procesa što zapravo i pruža poslovna inteligencija – poslovanje koje je uspješnije od konkurencije. Kako kompleksnost informacija neprestano raste, tako i raste potreba za novim i boljim rješenjima poslovne inteligencije. U skladu s tim u budućnosti će morati doći do razvoja novih alata koji će se prilagođavati tim novim potrebama. Tehnologija postaje sve naprednija i kompanije moraju usmjeravati svoje poslovanje novitetima kako bi ostvarile uspješnost poslovanja. Svi ti putevi vode do poslovne inteligencije koja je zapravo dio suvremenog poslovanja današnjih kompanija.

LITERATURA

Knjige:

1. Ercegovac, R.(2016): Teorija i praksa bankovnog menadžmenta, Ekonomski fakultet Split
2. Panian Ž. i suradnici(2007): Poslovna inteligencija:studije slučajeva iz hrvatske prakse, Zagreb

Znanstveni i stručni članci i ostala literatura:

3. Alfirević N.(2008): Poslovna inteligencija, uvod u teoriju informacija, Sveučilište u Splitu, Ekonomski fakultet, Split
4. Alfirević N. (2008): Poslovne informacije i Business intelligence, Sveučilište u Splitu, Ekonomski fakultet, Split
5. Gabelica H. (2013): Primjena metoda rudarenja podataka na primjeru procjene kreditnog rizika, skladištenje.com
6. Glavaš J.(2008): Poslovna inteligencija , Ekonomski fakultet u Osijeku
7. Gledović, M.(2015): Principi efikasnosti poslovanja poduzeća
8. Javorović, B., Bilandžić, M.: Poslovne informacije i business intelligence, Golden marketing – Tehnička knjiga, Zagreb, 2007.
9. Juračić O.(2015): Sustavi poslovne inteligencije hotela, Sveučilište Jurja Dobrile u Puli Fakultet za ekonomiju i turizam „Dr.Mijo Mirkovic“
10. Kruljac, F. (2016): Koncept poslovne inteligencije u suvremenim organizacijama
11. Krstić, Ž. (2014) : Big Data i semantička analiza-Iskorištavanje vrijednosti nestrukturiranih podataka u poslovanju, Ekonomski fakultet Split
12. Lorenzetti C. (2009/2010) : Business intelligence systems in the financial industry
13. Luetić, A., Šerić, N.(2009): Business Intelligence u funkciji upravljanja opskrbnim lancem, Sveučilište u Splitu, Ekonomski fakultet, Split ;

14. Luetić, A., Šerić, N.(2009): Business Intelligence u funkciji upravljanja nabavnim lancem
15. Ljubetić,V.(2005): Upravljanje znanjem primjenom alata poslovne inteligencije, Sveučilište u Zagrebu, Ekonomski fakultet, Zagreb
16. Nadeem M., Jaffri S.A.H.: Application of Business Intelligence In Banks (Pakistan)
17. Nadrljanski M. 2013): Specifičnosti razvoja sustava poslovne inteligencije, Sveučilište u Splitu, Pomorski fakultet, Split
18. Panian, Ž., Klepac,G.(2003): Poslovna inteligencija, Zagreb
19. Pejić-Bach,M., Šarlija,N.,Jaković,B.(2008.): Business Intelligence and Risk Management: Case Study of Croatian Banking Sector
20. Pfeifer, S., Alpeza,M.(2011): Business Intelligence, Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet u Osijeku, Osijek
21. Pupavac, D: Znanstvene metode
22. Rovčanin A.,Mataradžija A.,Mataradžija A.(2012): Upravljanje znanjem kroz primjenu alata poslovne inteligencije
23. Severović K. (2013): Upravljanje odnosima s klijentima kao izvor informacija za oblikovanje i poboljšanje usluga, Fakultet organizacije i informatike u Zagrebu
24. Sovilj,D. (2004.): Business intelligence u nautičkom turizmu - implementacija OLAP sustava
25. Stipić, M. (2016): Implementacija sustava poslovne inteligencije u zračnoj luci Croatia Airlines
26. Stojanović,A. (2013.): Implementacija „Business Intelligence“ sustava u Koncertnu dvoranu Vatroslava Lisinskog, Sveučilište u Splitu, Ekonomski fakultet Split
27. Ubiparipović,B.,Raković,L.(2011): Primjena sistema poslovne inteligencije u banici, Ekonomski fakultet Subotica
28. Vaidya T., Sagar A., Kiran K., Kundan L. (2014): Business Intelligence System for Banking and Finance

29. Varga, M.: Poslovna inteligencija: Ciljevi i metode, Ekonomski fakultet Zagreb
30. Vukušić, P,: Koncentracija banka, mjerenje i posljedice

Izvori s interneta:

1. Betterbuys (2017): Tableau vs excel: comparing core features and functions: https://www.betterbuys.com/bi/tableau-vs-excel/
2. Dukić,B. ,(2014): Alati poslovne inteligencije: http://www.mathos.unios.hr/~dskrobar/BP_MATHOS_Alati.pdf
3. Ekonomski portal (2010): Poslovna inteligencija: Zašto, što i kako? http://ekonomskiportal.com/poslovna-inteligencija-zasto-sto-i-kako/+
4. EduCentar(2014): Znate li razliku između pojmova efikasnost i efektivnost, http://www.educentar.net/Vijest/11447/Znate-li-razliku-izmedju-pojmova-efikasnost-i
5. Finextra (2017): The force awakens: big data in banking: https://www.finextra.com/newsarticle/28541/the-force-awakens-big-data-in-banking
6. HNB (2006): Smjernice za upravljanje informacijskim sustavom u cilju smanjenja operativnog rizika: http://old.hnb.hr/supervizija/h-smjernice-za-upravljanje-informacijskim-sustavom.pdf
7. Lach, J. (2011): Business intelligence for the finance and banking sector: https://www.yellowfinbi.com/blog/2011/02/yfcommunitynews-business-intelligence-for-the-finance-and-banking-sector-102389
8. Link group: Efikasnost i efektivnost: http://www.linkelearning.com/site/kursevi/lekcija/1138
9. Metode znanstvenog istraživanja : http://www.pfri.uniri.hr/~ines/MZiR/20132014%20Materijal%20za%20web/Znanstvene%20metode.pdf
10. Metodologija znanstvenog istraživanja:

http://www.pfri.uniri.hr/~ines/MZiR/20132014%20Materijal%20za%20web/Znanstvene%20metode.pdf

11. Minnesota Society of Certified Public Accountants: Excel vs. Tableau Which BI tool is right for you?: http://www.mncpa.org/publications/footnote/2015-05/excel-vs-tableau.aspx

12. Mit Software: Općenito o Business intelligence sustavima: http://www.mit-software.hr/usluge/bi/bi1/

13. Mulcahy, R.: (2007.) Business intelligence definition and solutions: http://www.cio.com/article/2439504/business-intelligence/business-intelligence-definition-and-solutions.html

14. Numeric analitycs: Tableau vs. Excel- How do you know if you need to make the switch?: http://numericanalytics.com/tableau-vs-excel-how-do-you-know-if-you-need-to-make-the-switch/

15. Qubole: Applications of Business Intelligence in Banking and Finance(2016): https://www.qubole.com/blog/big-data/business-intelligence-and-finance/

16. Sesame inspire innovate (2017) : 5 ways business intelligence software can benefit banks: https://www.sesameindia.com/blog/5-ways-business-intelligence-software-can-benefit-banks/

17. Strgačić, M.: To BI or not to BI : http://www.infotrend.hr/clanak/2012/12/to-bi-or-not-to-bi,76,984.html

18. Surjan, N.(2013): Poslovna inteligencija u digitalnoj eri : http://www.banka.hr/svijet/poslovna-inteligencija-u-digitalnoj-eri-46082

19. Infosistem: Sustav poslovne inteligencije za banke: http://www.infosistem.hr/pdf/rjesenja/BI_info.pdf

POPIS SLIKA

Slika 1: Ciklus poslovne inteligencije

Slika 2 : Magic Quadrant for Business Intelligence and Analytics Platforms

Slika 3. Shema sustava poslovne inteligencije

Slika 4: Primjena BI modela u bankama

Slika 5. Činjenična tablica: Dug

Slika 6: Dimenzijska tablica Datum

Slika 7: Dimenzijska tablica Kamatna stopa

Slika 8 : Dimenzijska tablica Klijent

Slika 9 : Dimenzijska tablica Kredit

Slika 10 : Konceptualni model

Slika 11: Model podataka u BI Lite-u

Slika 12 : Prikaz baze podataka u BI Lite-u

Slika 13 : Kreiranje strukture kocke

Slika 14: Procesuiranje kocke

Slika 15: Pet koraka

Slika 16: Izrada izvještaja o neisplaćenoj glavnici po gradovima

Slika 17: Izrada izvještaja o visini neisplaćene glavnice po broju klijenta

Slika 18: Izrada izvještaja o vrsti i visini kamatne stope po broju klijenta

Slika 19 : Importiranje baze podataka

Slika 20 : Odabir tablica za analizu

Slika 21 : Vizualizacija neisplaćene glavnice po poslovnicama

Slika 22: Vizualizacija visine kamatne stope po klijentima

POPIS KRATICA

ALM (engl. Asset & Liability Management) - upravljanje aktivom i pasivom

AST (engl. Application Solution Templates) – rješenjA čiji je glavni zadatak prilagoditi podatke za aplikacije

BST (engl. Business Solution Templates) - modeli koji su definirani kao kocke podataka od kojih svaka ima skup mjera i dimenzija koji su prilagođeni za analitičke procese

CRM (engl. costumer relationship management) – upravljanje odnosima s klijentima

DSS (engl. Decision support system) - sustavi za potporu odlučivanju

ETL (engl. extraction, transformation and loading) - alati za trasformaciju i punjenje podataka

ERP (engl. Enterprise Resource Planning) - aplikacije za cjeloviti proizvodno-poslovni informacijski sustav

HOLAP (engl. Hybrid OLAP) - hibridni OLAP

MOLAP (engl. Multidimensional OLAP) - višedimenzijski OLAP

OLAP (engl. On-Line Analytical Processing) - online analitička obrada

OLTP (engl. OnLine Tranaction Processing) – sustavi koji služe za bilježenje velikog broja transakcijskih podataka

PM (engl. Performance Management) - upravljanje performansama banke koji se odnose na procese za nadzor poslovnih rezultata

ROLAP (engl. Relational OLAP) - relacijski OLAP

SAŽETAK

U ovom radu smo se upoznali sa poslovnom inteligencijom i govorili o njenoj ulozi u dobivanju izvještaja za potrebe poslovanja. Osim teorijskog dijela, prikazan je i model podataka u nekoliko alata koji su se pokazali jako korisnima u provođenju raznih analiza i istraživanja. Na ovaj način pokali smo kako se može skratiti vrijeme obrade ogromne količine podataka i dobiti kvalitetni i vrijedni podaci. Koristeći ovako dobivene rezultate svaka kompanija ostvaruje bolju konkurentnost na tržištu. Poslovna inteligencija predstavlja rješenje za sve poslovne procese svake tvrtke pa tako i banke. Najveći bankarski problem predstavljaju rizici koje je potrebno preuzeti i pratiti. Najbolju analizu omogućuje upravo poslovna inteligencija. Pokazali smo da vizualni prikaz analize podataka daje bolji uvid u rezultate potrebne za donošenje važnih odluka. Iz tog razloga potrebno je neprestano pratiti inovacije i biti u koraku s vremenom.

Ključne riječi: Poslovna inteligencija, model podataka, poslovni procesi, rizici

SUMMARY

In this seminar, we acquainted with the concept called "Business Intelligence" and talked about its function when getting reports for business needs. Expect its theoretical part, a data model also was shown in some tools which were proved to be very useful for the implementation of different analyses and research. In this manner, shortening the time of processing was shown regarding huge amounts of data and how to get quality and valuable data. By using these received results, every company would be more competitive on the market. Business intelligence represents a decision for all business processes regarding companies and even banks. The biggest problem in banking is monitoring the risks which need to be taken. The best analysis which can be provided for this is given with the business intelligence. The visual analysis of data analysis gives a better insight into the results needed to make important decisions. For this reason, it is necessary to regularly follow new innovations and be up to date in according to take later.

Keywords: Business intelligence, data model, business processes, risks