Važnost poslovne inteligencije i njena primjena u poslovanju

Muntić, Tomislav

Undergraduate thesis / Završni 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:124:305294

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

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

ZAVRŠNI RAD

Važnost poslovne inteligencije i njena primjena u poslovanju

Mentor:

Doc. dr. sc.Ivana Bulog

Student:

Tomislav Munitić 1140736

Split, Rujan 2017.

SADRŽAJ:

1. Uvod 1

1.1. Definicija problema 1

1.2. Cilj rada 1

1.3. Metode rada 1

1.4. Struktura rada 2

2. TEORIJSKI DIO RADA 2

2.1. Podaci 2

2.1.1. Skladište podataka 3

2.1.2. Nestruktrurirani podaci 5

2.1.3 Big Data 7

2.2. Poslovna inteligencija 9

2.2.1 Poslovna inteligencija i donošenje odluka 10

2.2.2. Troškovi poslovne inteligencije 13

2.2.3. Korisnosti Poslovne inteligencije 14

2.2.4. Faktori uspjeha 18

3. EMPIRIJSKI DIO RADA 20

3.1. Razvoj Poslovne inteligencije u budućnosti 20

3.2 Usporedba dva vodeća BI rješenja 22

3.3 Case study-ji BI rješenja u svijetu 24

3.4 Case study BI rješenja u Hrvatskoj: Orbico 26

4. ZAKLJUČAK 28

5. POPIS TABLICA I SLIKA 29

6. LITERATURA 29

7. SAŽETAK 31

1. Uvod

1.1 Definicija problema

Poslovna inteligencija (eng. Business intelligence ili skraćeno BI) u modernom poslovanju predstavlja ključni alat za unaprijeđenje poslovanja. U prošlosti projekti Poslovne inteligencije su bili rezervirani za velike tvrtke sa značajnim IT budžetom, ali danas, s razvojem tehnologija, ponajviše rada u Cloudu i mogućnosti najma softvera, sve više malih tvrtki iskorištava ove mogućnosti kao pokretač novih grana svog poslovanja. 2013. godine više od polovice tvrtki sa prodajom ispod $100,000 planirale su korištenje Poslovne inteligencije u svom poslovanju.[1] U usporedbi sa 2010. godinom to je skok od 43%. Međutim treba biti oprezan, jer veliki projekti poslovne inteligencije propadaju u 70-80% slučajeva.[2]

1.2. Cilj rada

Cilj ovoga rada je definirati ključne pojmove vezane za Poslovnu inteligenciju, počevši od podataka, skladišta podataka i Big Data sve do same Poslovne inteligencije, uvjeta za uspjeh te kako ona funkcionira u stvarnom svijetu. Također cilj je sistematizirati korištenje Poslovne inteligencije u svijetu i u Hrvatskoj te povući paralele između njih. Cilj je proučiti postojeće tvrtke u Hrvatskoj i izvan nje koje koriste Poslovnu inteligenciju te vidjeti njene koristi i mogućnosti za unaprijeđenje poslovanja.

1.3. Metode rada

Metode koje su korištene za prikupljanje podataka i izradu ovog istraživanja su metode desk istraživanja, deskriptivna metoda, komparativno-opisna metoda, metode analize i sinteze te indukcije i dedukcije. Također korištena je i metoda studije slučaja kojom se želilo prikazati kretanja u Hrvatskoj i usporediti ih sa ostatkom svijeta.

[1] Oxford Economics (2013): Change Readiness Index
[2] Izvor: https://www.phocassoftware.com/business-intelligence-blog/why-business-intelligence-projects-fail (pristupljeno 21.08. 2017)

1.4. Struktura rada

Rad je podijeljen u četiri dijela:

1. Uvodni dio gdje su objašnjeni problem, cilj rada te metode korištene u njegovom stvaranju
2. Teorijski dio u kojem će biti opisani ključni procesi i varijable potrebne za funkcioniranje Poslovne inteligencije
3. Empirijski dio gdje će sa na primjeru već postojećih studija slučaja pokušati prikazati korištenje Poslovne inteligencije u stvarnom svijetu te njen razvoj
4. Zaključak u kojem će se iznijeti rezultati i spoznaje do kojih se došlom tijekom pisanja rada.

2. Teorijski dio rada

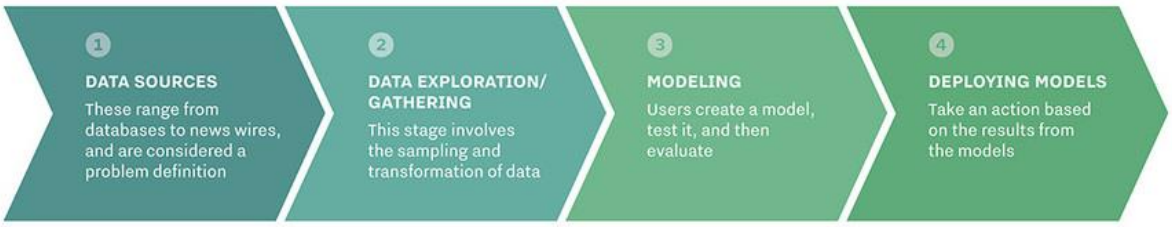
2.1 Podaci

Podaci (eng. Data) je najtočnije opisati kao informaciju koja je pretvorena u oblik prikladan prenošenju i obradi. U današnjem svijetu to znači informacija u digitalnom obliku. Način na koji vidimo podatke danas započeo je sa prvim računalima, sa bušenim karticama, zatim preko diskete do današnjih hard diskova, i već od početka uz njega usko vežemo pojmove kao procesuiranje podatka, poslije elektroničko procesuiranje podataka. Iz ovih termina nastala je grana poslovanja pod nazivom Informacijske tehnologije čiji je cilj sakupljati podatke, procesuirati ih te zadržavati one koje imaju informacijsku vrijednost.

Ljude koji rade sa podacima danas nazivamo Administratorima baza podataka i njihov je posao dizajniranje i održavanje baza podataka. Prva faza je tzv. Data mining, tj. rudarenje podataka koji podrazumijeva traženje uzoraka u podatcima i stvaranje veza među njima što omogućuje poduzećima da predvide buduće trendove.[3]

[3] Rouse, M. (svibanj 2017.) :What is data mining? – TechTarget
(dostupno na http://searchdatamanagement.techtarget.com/definition/data)

Slika 1. Četiri faze rudarenja podataka



Izvor: http://searchsqlserver.techtarget.com/definition/data-mining (pristupljeno 20.08.2017)

Sljedeći korak je osigurati kvalitetu podataka čišćenjem te transformacijom u integrirane podatke. Sve ovo može koristiti u prediktivnoj analizi koja, ako se koristi na pravi način može povećati efikasnost poduzeća i pomoći predvidjeti ponašanja kupaca. Sve se ovo radi preko naprednih algoritama koji su dizajnirani specijalno za rudaranje podataka, a drugi termin koji sve češće vezujemo sa rudaranjem je strojno učenje koje bi omogućilo da računala sama „uče“ kako prepoznati nove grupe podataka i stvoriti nove algoritme koji bi te podatke obradili. Ovo je nova grana koja je usko vezana uz umjetnu inteligenciju koja postaje sve važnija upravo zbog enormne količine podataka koja nastaje „online“ svakog dana. Više o tome u poglavlju o Big Data.

2.1.1 Skladište podataka

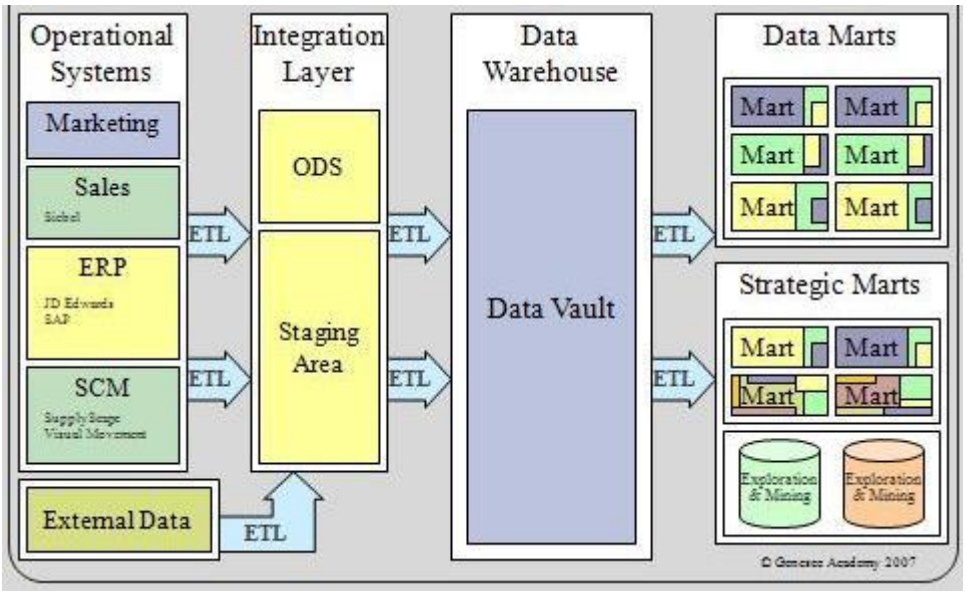
“Skladište podataka je subjetno orijetirana, inegrirana, vremenski osjetljiva i neizbrisiva kolekcija podataka koja služi za pomoć menadžmentu u procesu donošenja odluka.”[4] citat je iz knjige koja najbolje opisuje što je to skladište podataka, ali je potrebno još objasniti što svaki od ovih pojmova znači:

[4] William H. Inmon (1992.) – Building the Data Warehouse, Wiley, 1. izdanje, New York, str. 56.-57.

- Subjektno orjentirani – skladište mora imati ciljanu skupinu, kao npr. kupci, posrednici ili proizvod , na koju će se podatci odnositi
- Integrirani – podatci se skupljaju iz raznih izvora što može značiti više načina za definiranje odrađene stavke, ali unutar skladišta jedna stavka, kao npr. proizvod smije imati samo jednu definiciju
- Ovisni o vremenu – svaka informacija je aktulna samo određeni dio vremena, to može biti samo jedan trenutak ili zadani period vremena
- Neizbrisive – podatci koji su već u skladištu se nemogu brisati ili ažurirati
- Podrška donošenju odluka – podatci u skladištu moraju pomoći donijeti poslovne odluke koje bi mogle unaprijediti poslovne procese.

Uz skladište podataka postoji i tzv. Data mart[5] koji je stvoren za lakši i kontrolirani pristup podacima u skladištu. On omogućava korisnicima da pristupe samo onim podacima relevantnima za njihov posao, ako naravno imaju dozvoljen pristup istima.

Slika 2. Skladište podatka



Izvor: http://www.zentut.com/data-warehouse/what-is-data-warehouse/ (pristupljeno 20.08.2017.)

[5] Upotrijebljen izraz Data mart zbog nedostatka ekvivalenta na hrvatskom jeziku

Dva su pristupa dizajniranju skladišta podataka. Bottom up i Top down pristup. Prvi prvo stvara Data mart-ove koje se zatim integriraju u jedno sveobuhvatno skladište podataka, dok se kod drugog prvo stvara skladište koje se zatim razdvaja u martove ovisno o potrebi korisnika.

Primjer automatizacije:

Danas već postoji tvrtka koja se bavi automatizacijom skladišta podataka. WhereScape je pionirska tvrtka u DWA-u (Data warehouse automation). DWA znači: "…koristiti tehnologiju kako bi postigla efikasnost i poboljšala efektivnost u procesima spremanja podataka u skladišta. Automatizacija skladišta podataka je mnogo više od jednostavne automatizacije razvojnog proces. Ono obuhvaća sve bazne procese unutar stvaranja skladišta podatka što uključuje dizajn, razvoj, testiranje, puštanje u pogon, operacije, analizu utjecaja, i promjene u menadžmentu."[6]

Njihov proizvod omogućava brzu, efikasnu i što je najvažnije potpuno kompjuteriziranu obradu podataka što uvelike smanjuje troškove, ali i vrijeme potrebno za obradu. Koriste sustav pod nazivom Data Vault 2.0 koji je integrirani dio Poslovne inteligencije i koji omogućava paralelnu obradu podataka i automatsko izvještavanje managementa. Neki od njihovih partnera su Microsoft, Oracle i IBM dok se od kupaca ističu Tesco, Cornell University, Volkswagen, Union Bank itd.

2.1.2. Nestruktrurirani podaci

Svi podaci smješteni u bilo kakvoj bazi podataka smatraju se struktiranim podacima. Takve baze se većinom rade na primjeru nekih relacija, pa se takve baze često nazivaju i relacijske baze podataka. Sve ostalo što se smatra podacima i moguće je prikupiti pripada nestrukturirranim podacima. Oni se pojavljuju u dva oblika, tekstualnom i netekstualnom. Tekstualni su: e-mail poruke, instant web poruke, Power Point Prezentacije, Word i Excel dokumenti itd. Netekstualni su sve ostalo, kao slike, audio dokumenti i videa. Smatra se da

[6] Izvor: https://tdwi.org/Home.aspx (pristupljeno 21.08.2017)

upravo nestrukturirani podaci čine 90% svih podataka dostupnih, i ako ih se ne obrađuje, može postati jako skupo u smislu čuvanja svih tih podataka.

Zato je jako bitno koristiti alate obrade tih podataka, čime se eliminira ono nepotrebno, duplicirano, ili neupotrebljivo. Neki od njih su:

- Big data[7] alati – Softveri poput Hadoop-a imaju mogućnosti procesirati velike količine podatka, bez obzira na veličinu, kompleksnost i volatilnost, često se smatraju predanalizom
- Softveri poslovne inteligencije – nakon prikupljanja podatka iste treba obraditi, tome služi široka paleta alata za analizu, rudarenje podataka, i analitiku koji tvrtkama omogućuju da pomoću obrade podataka donose bolje poslovne odluke
- Alati integracije podataka – kao što je već rečeno baze i skladišta podataka moraju biti jednoznačno napisani, bez obzira na izvore podataka u njima, kako bi se mogli svi otvoriti sa jednom aplikacijom. Također je moguća i integracije stukturiranih i nestrukturiranih podataka.
- Sistem managementa dokumentima – alati koji omogućuju dijeljenje nestrukturiranih podataka spremljenih u obliku tekstualnih dokumenata
- Management informacija – ima cilj praćenja strukturiranih i nestrukturiranih podataka tijekom cijelog životnog ciklusa
- Alati za pretragu i indeksiranje – omogućuju pretragu dokumenata, stranica i slika po nazivu[8]

Svi ovi podaci danas nastaju na internetu, od toga većina na društvenim mrežama. Volumen kojim se oni stvaraju raste iz dana u dan, dolazi do granica kada ih se u normalnom načinu spremanja nije moguće zadržati, zato i nastaje tzv. Spremanju u Oblaku. Ti podaci koji nastaju svaki dan imaju zajednički naziv „Big Data“.

[7] Zbog velike upotrebljenosti i nedostatka istoznačne riječi na hrvatskom jeziku u radu se od sada koristi ovaj izraz

[8] Izvor: http://www.webopedia.com/TERM/U/unstructured_data.html (pristupljeno 22.08.2017)

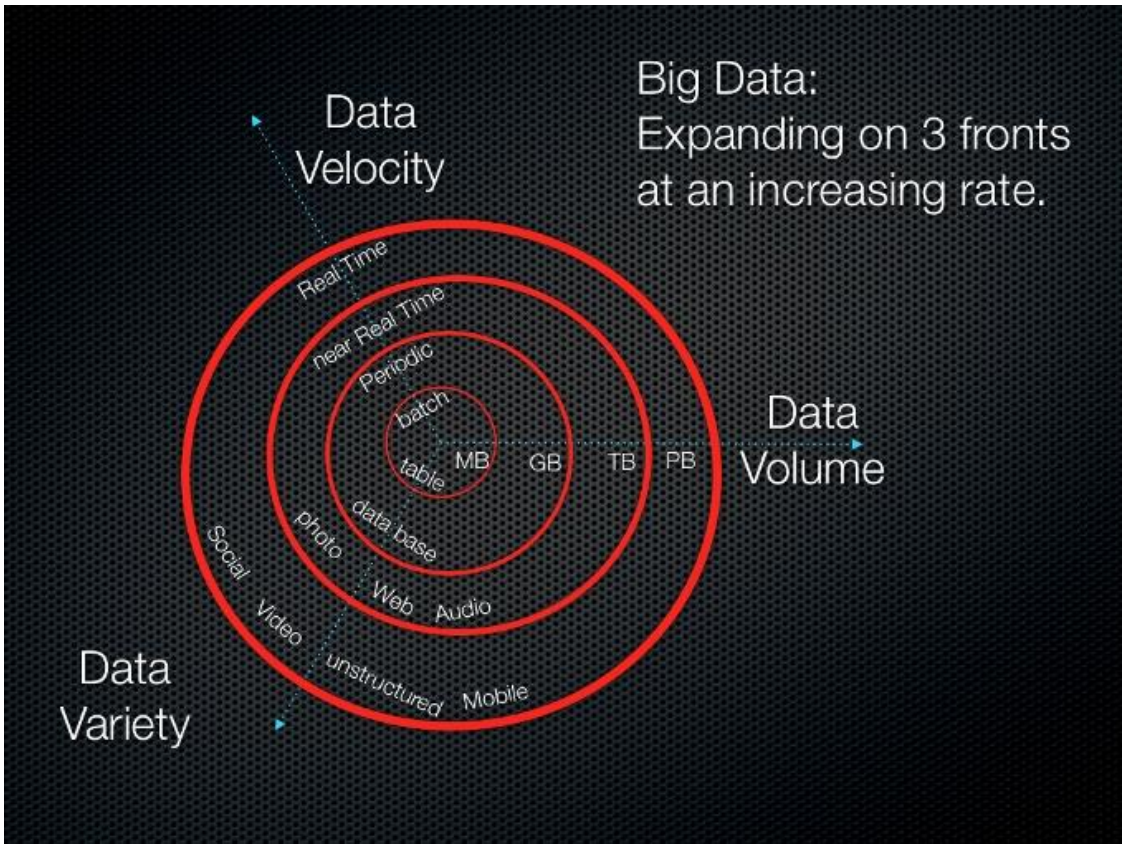
2.1.3 Big Data

„Doba viška informacija se polagano bliži kraju. Poduzeće se konačno mogu nositi sa obradom ogromnih količina podataka, sadržaja i informacija. Ritam stvaranja informacija i dalje raste, ali mogućnost infrastrukture i managementa informacija da prate taj ritam sve je bliža. Big Data se danas smatra blagoslovom, a ne prokletstvom.“[9]

Big Data je pojam za sve strukturirane, polustrukturirane i nestrukturirane podatke koji se mogu prikupiti i obraditi. Da bi shvatili što je Big Data trebamo znati što su 3V:

- Volumen podataka
- Raznolikost (variety) podataka
- Brzina (velocity) stvaranja novih podataka.

Slika 3. „3V“



Izvor:http://searchcloudcomputing.techtarget.com/definition/big-data-Big-Data (pristupljeno 22. 08.2017)

[9] Darin Stewart (01.08.2013) – Information Weekly – Big content: Taming the unstuctured side of Big data

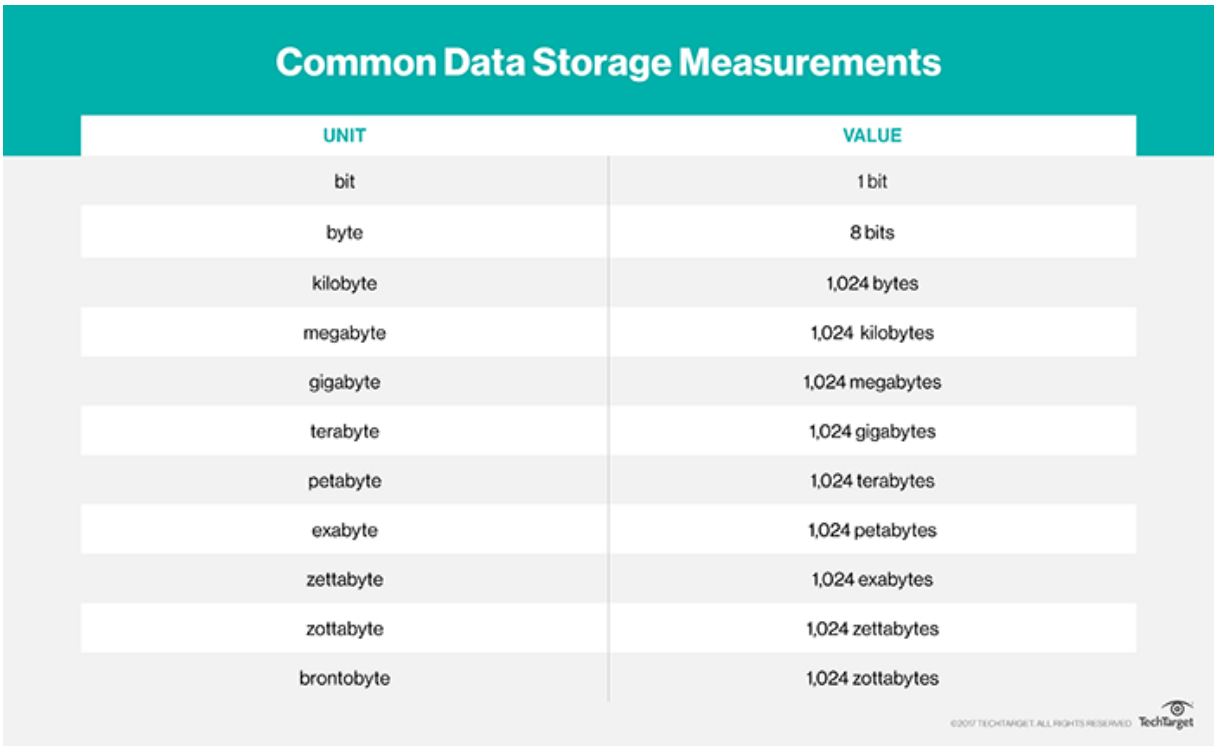
Volumen znači da podaci dolaze iz mnogih izvora, bilo da su to zapisi iz poslovnih transakcija, podaci iz istraživanja i testiranja, ili informacije preuzete sa interneta.

Raznolikost podataka odnosi se na sve od toga jesu li podaci strukturirani ili nestrukturirani, kojeg su formata (tekstualni, video, JPEG itd.)

Brzina podataka uspoređuje brzinu kojom se novi podaci stvaraju i brzinu potrebnu za obradu istih. Pregledom podataka na „listi za čekanje“ možemo lako utvrditi koja je brzina veća, tj. jesu li postojeći alati za obradu dostatni da kontroliraju količinu neobrađenih podataka. Brzina obrade podataka se ubrzava svaki dan sa razvojem strojnog učenja i umjetne inteligencije.

Količina podataka koja se danas stvara je zapravo nevjerovatna za shvatitit. Svaki dan se na internet učitaj 2.5 quintiliona bitova podataka, ili 2.5 milijuna terabajtova, dok za usporedbu prosječno kućno računalo ima kapacitet 1 terabajt.

Slika 4. Usporedba veličina jedinica za kapacitet računala



Common Data Storage Measurements

UNIT	VALUE
bit	1 bit
byte	8 bits
kilobyte	1,024 bytes
megabyte	1,024 kilobytes
gigabyte	1,024 megabytes
terabyte	1,024 gigabytes
petabyte	1,024 terabytes
exabyte	1,024 petabytes
zettabyte	1,024 exabytes
zottabyte	1,024 zettabytes
brontobyte	1,024 zottabytes

©2017 TECHTARGET. ALL RIGHTS RESERVED. TechTarget

Izvor: https://techterms.com/help/data_storage_units_of_measurement (pristupljeno 22. 08. 2017.)

Za obradu svih tih podataka potrebna je velika količina računalnih kapaciteta. Zbog velikih troškova hardvera nije moguće da jedna tvrtka posjeduje dovoljnu snagu kako bi obradila podatke, već to rade mnoge tvrtke zajedno na globalnoj razini, najčešće poznato kao rad u Oblaku (eng . Cloud).

2.2. Poslovna inteligencija

Poslovna inteligencija je kolekcija softvera koja omogućava ljudima koji rade sa znanjem da donose bolje i brže odluke. Tvrtke je koriste na način da agresivno koriste i šire svoje alate za analizu podataka koji bi trebali pokrenuti donošenje odluka i stvoriti nove funkcionalnosti kao npr. personalizirane proizvode ili usluge.

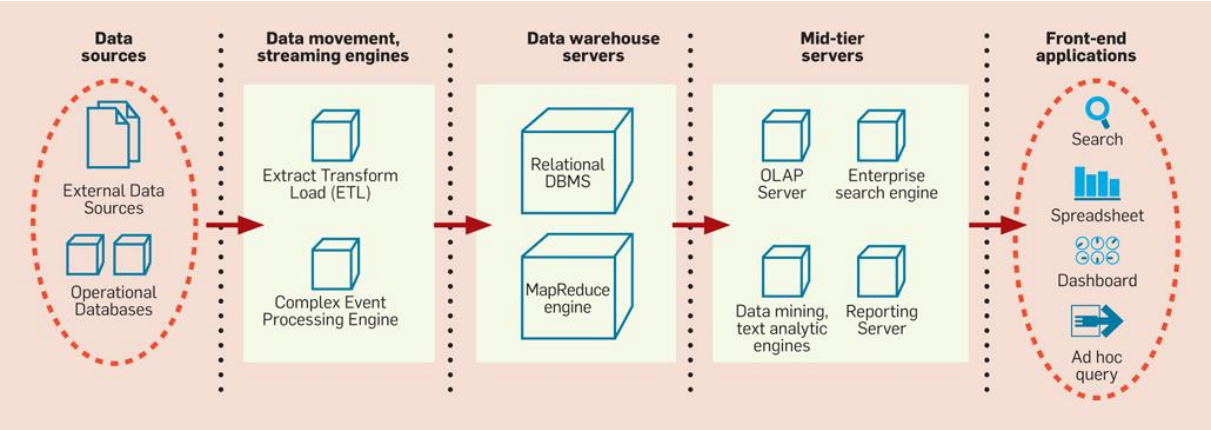
Poslovna inteligencija se koristi u proizvodnji za određivanje količine proizvodnje i za podršku kupcima, u maloprodaji za profiliranje kupaca i prilagođavanje ponude, u financijskim poslovima za analizu potraživanja i spriječavanje prijevara, u

telekomunikacijama za određivanje potreba tržišta, u komunalnim uslugama za analizu potražnje energenata itd.

Tri su najvažnije stvari koje se trenutno događaju u svijetu poslovne inteligencije:

- Troškovi nabavljanja i spremanja podataka se drastično smanjuju
- Paralelene infrastrukture i analitika ide preko dosadašnjih SQL baza podataka i OLAP sustava
- Vrijeme između nabavljanja informacije i donošenja odluke na temelju te informacije se smanjuje zahvaljujući novim tehnologijama

Slika 5. Arhitekura poslovne inteligencije



Izvor: https://cacm.acm.org/magazines/2011/8/114953-an-overview-of-business-intelligence-technology/fulltext (pristupljeno 24.08.2017)

2.2.1. Poslovna inteligencija i donošenje odluka

Termin poslovna inteligencija je relativno nov, a kada je uveden zamjenio je izraze: podrška odlukama, izvršni informacijski sustavi i management informacijskih sustava[10]

Sustavi poslovni inteligencije kombiniraju skupljanje podataka, njihovo spremanje i upravljanje kako bi sa analitičkim alatima prezentirali kompleksne interne i konkurentske informacije planerima i donositeljima odluka[11]

[10] Thomsen, E. (2003): "BI's Promised Land", Intelligent Enterprise, 2003. str. 21

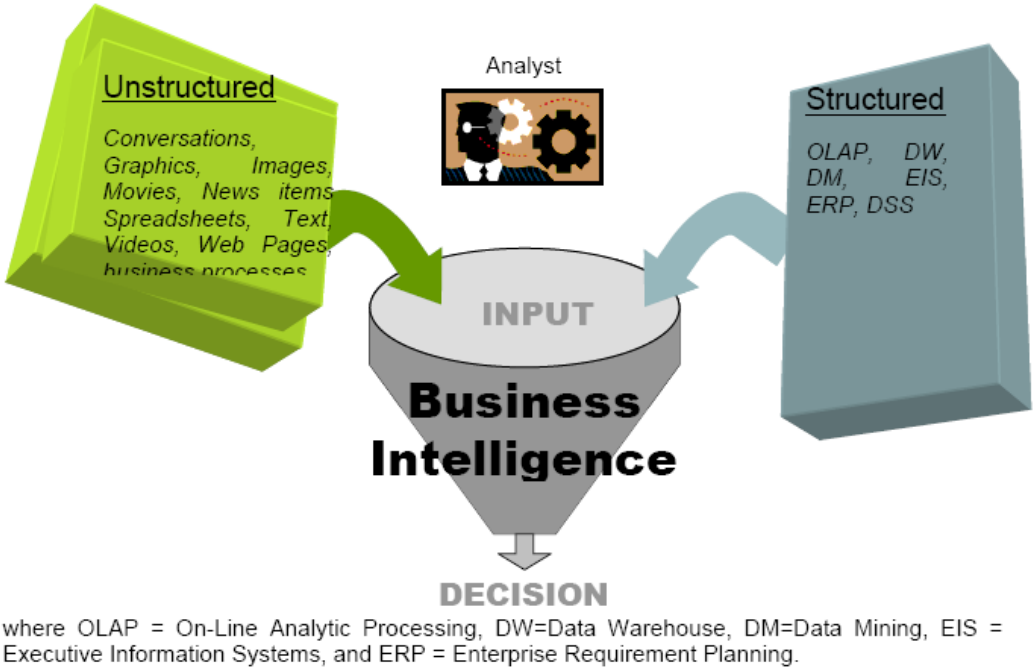
Iz ovakve definicije možemo zaključiti da je ideja Poslovne inteligencije da daje djelotvorne informacije u pravo vrijeme na pravom mjestu i u pravoj formi kako bi pomogla donošenju odluka. Jako je bitno da se sa Poslovnom inteligencijom može djelovati proaktivno tj. da je informacija dobivena na ovaj način još uvijek aktualna kada dođe do osobe koja sa njom treba donijeti odluku.

Osnovne komponenete proaktivne Poslovne inteligencije su:[12]

- Spremanje podataka u stvarnom vremenu
- Rudarenje podataka
- Automatizirani postupak detektiranja anomalija
- Proaktivno upozorenje uz automatsko određivanje primatelja
- Kontinuirani proces praćenja
- Automatsko učenje i prilagođavanje
- Geografski informacijski sustavi
- Vizualizacija podataka

[11] Ibid
[12] Langseth, J. i N. Vivatrat (2003) "Why Proactive Business Intelligence is a Hallmark of the Real-Time Enterprise: Outward Bound", Inteligente Enterprise, 5, 36. str.

Slika 6. Osnovni imputi poslovne inteligencije



Izvor: Solomon Negash (2004): Business Intelligence

Kao što je prikazano na slici Poslovna inteligencija je alat koji kroz analizu svih vrsta podataka, od strukturiranih kao onih iz OLAP ili ERP sustava pa sve do nestrukturiranih kao slika i poslovnih procesa, nalazi najbolja rješenja za razne probleme i pomaže u donošenju odluka.

2.2.1.1. Što radi Poslovna inteligencija?

Poslovna inteligencija pretvara podatke u informacije, a zatim kroz ljudsku obradu u znanje. Neki od načina za to postići su:

- Stvaranje pretpostavki baziranih na povijesnim podacima, prošlim i sadašnjim rezultatima i procjenama budućnosti
- „What if“ analizom utjecaja promjena i stvaranja alternativnih scenarija
- Ad hoc pristupom podacima kako bi se odgovorilo na nerutinska pitanja
- Strateški uvid

Primjeri strateškog uvida:

1. Kompanija koja se bavi prirodnim plinom uvela je aplikaciju koja omogućuje praćenje tekućih poslova i donošenje odluka u stvarnom vremenu. To je smanjilo broj duplih poziva za isti posao što je rezultiralo uštedom od $1.3 milijuna.
2. Sustav poslovne inteligencije omogućio je da lanac prodavaonica alata analizira potražnju, ali i uspoređuje performanse jedne trgovine sa drugom, što je smanjilo količinu robe u otpisu sa $60 milijuna na $10 milijuna
3. Kreditna unija u Dallasu je širila svoje poslovanje. Prije toga upitali su sustav Poslovne inteligencije dva pitanja. Tko su nam najbolji klijenti? i Koliko su voljni voziti da dođu do naše poslovnice? Nakon što su dobili odgovore na ta pitanja mogli su sa sigurnošću odabrati lokacije koje su idealne za pridobiti nove klijente[13]

Poslovna inteligencija podržava strateško i operacijsko donošenje odluka. Njezina uporaba se može rangirati na sljedeći način:[14]

- Korporativni management performanci
- Optimiziranje odnosa sa kupcima, promatranje poslovnih aktivnosti i tradicionalna podrška odlučivanju
- Aplikacije poslovne inteligencije za specifične operacije i/ili strategije
- Menadžersko izvještavanje

[13] Solomon Negash (velječa 2004): Business Intelligence, vol 13, članak 15 „Communications of the Association for Information Systems“,
[14] Willen, C. (2002): “Airborne Opportunities”, Intelligent Enterprise 11-12

2.2.2. Troškovi poslovne inteligencije

Kako bi tvrtka mogla reći da posjeduje kompletni sustav Poslovne inteligencije mora uložiti određenu količinu novca. Neki od troškova su:

- Trošak hardvera zavisi o postojećem sustavu unutar tvrtke, ali za Poslovnu inteligenciju mora postojati skladište podataka sa pripadajućim Data Mart-ovima, kao i potpuni intranet i extranet sustav
- Trošak softvera većinom je danas u obliku pretplate koju treba plaćati na godišnjoj bazi. To znači da kupac može biti siguran da ima suvremeni sustav koji je u koraku sa vremenom dok za pružatelja usluga to znači neiscrpan izvor prihoda koje može ulagati za unaprijeđenje sustava ili u sasvim novi
- Troškovi implementacije podrazumijevaju i troškove instalacije računalnog sustava i troškove obuke postojećih radnika za rad u novom sustavu
- Troškovi ljudstva nastaju ako želimo zaposliti radnike koji će biti zaduženi isključivo za obradu informacija nastalih radom računalnog sustava, ovaj trošak je danas nužnost jer nema smisla ulagati u sustav ako nitko neće obrađivati nastale informacije

2.2.3. Korisnosti Poslovne inteligencije

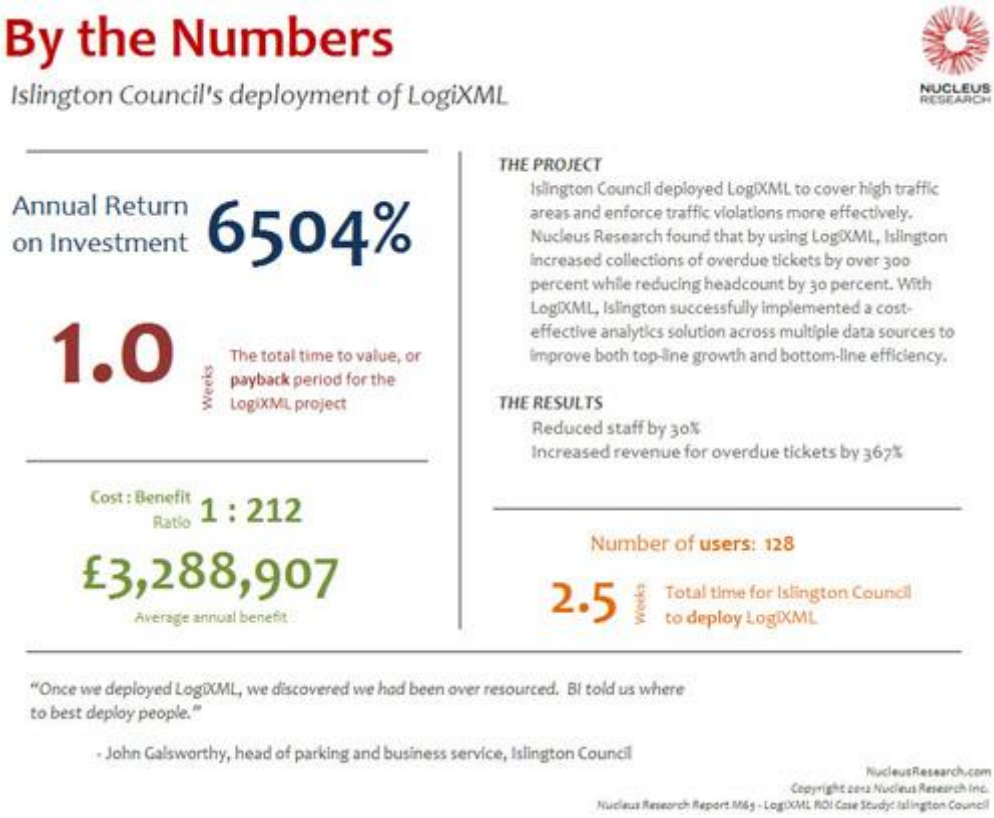
Korisnosti Poslovne inteligencije nije lako vidjeti jer oni nemaju klasičan povrat kao druga ulaganja. Naime većina povrata na ulaganja u ovakve sustave se dogodi sa jednim velikim projektom ili odlukom donesenom na račun podataka iz njega. Neki od primjera su:

- Texas Instruments zaradili su $100 milijuna sa akvizicijom bazirom na analizi koliko će konkurencija ponuditi za isto
- Merck & Company su stvorili konkurentni proizvod kao reakciju na novi proizvod konkurencije čime su uštedjeli $200 milijuna

Analiza ROI na 5 godina pokazala je da se povrat kreće od 17% do 2000% sa prosjekom od 457%. Međutim nemoguće je odrediti ROI prije ulaganja, samo retrospektivno. Također nema veze između veličine ulaganja i ROI.[15]

[15] Solomon Negash (veljača 2004): Business Intelligence

Slika 7. ROI sustava LogiXML u 2012. godini



Izvor: http://www.itbriefcase.net/how-big-is-your-bi-roi (pristupljeno 25.08.2017)

2.2.3.1 Kompetitivna analiza

Kompetitivna analiza je proces osiguravanja vlasite kompetitivnosti na tržištu kroz bolje poznavanje konkurencije i cijele konkurentske okoline. Podataka ima i previše, upravo zbog velikog izvora podataka dostupnih svima kao:

- Online baze podataka
- Mediji i portali
- Grupe specijalnih interesa (akademici, trgovačka društva itd.)
- Privatni sektor[16]

[16] Imhoff, C. (2003): "Keep your Friends Close, and your Enemies Closer", DM review (dostupno na: http://www.intelsols.com/documents/Imhoff_04-03.pdf)

Jedino što treba napraviti je znati diferencirati korisno od nekorisnog kao i adekvatno zaštiti sebe i svoje podatke od istog načina preuzimanja informacija. Primjeri kompetitivne analize su dati i prošlom poglavlju.

2.2.4. Faktori uspjeha

Postoje 3 kritična područja koji uvjetuju faktore uspjeha projekta Poslovne inteligencije:

1. Razina predanosti i ulaganja u projekt od top managementa
2. Razina poslovne potrebe za uvođenjem Poslovne inteligencije
3. Količina i kvaliteta dostupnih poslovnih podataka[17]

1. Jako je bitno da podrška vrha tvrtke ne izostane, jer ni jedan projekt, koliko god inovativan neće uspjeti bez podrške. Također ta podrška treba biti zahtjevna, ali i realistična kako se nebi obeshrabrilo ljude koji rade na projektu. Isto tako idealno je imati više ljudi u vrhu koji podržavaju projekt kako bi osigurali da on ne propadne ako jedna osoba odustane

2. Mora postojati poslovna potrebna za sustavom da bi se on krenuo implementirati u poslovanje. Ako menadžeri smatraju da im on nije potreban, onda projekt neće uspjeti. Najlakši način je pokazati ljudima sve prednosti korištenja ovakvog sustava što samo od sebe može stvoriti potrebu za istim

3. Treba vidjeti koji su sve izvori informacija dostupni za korištenje i koje se dodatne potencijalne može angažirat jer bez dovoljne velike baze podataka i izvora budućih nema smisla pokrenuti projekt obrade istih.

[17] Ralph Kimball et al.(2008): "The Data warehouse Lifecycle Toolkit", Wiley, New York, drugo izdanje

Slika 8. Faktori uspjeha



Izvor:http://www.ventera.com/news/insight/white-paper-sensible-approach-successful-business-intelligence-bi-implementation (pristupljeno 26.08.2017)

3. Empirijski dio rada

3.1. Razvoj Poslovne inteligencije u budućnosti

Internet stvari (eng Internet of things, od sada IoT) je najnoviji trend u razvoju Poslovne inteligencije i dio nje koji se najbrže razvija. IoT se promatra kao 3 sektora:

- Poslovni
- Dom
- Vlada

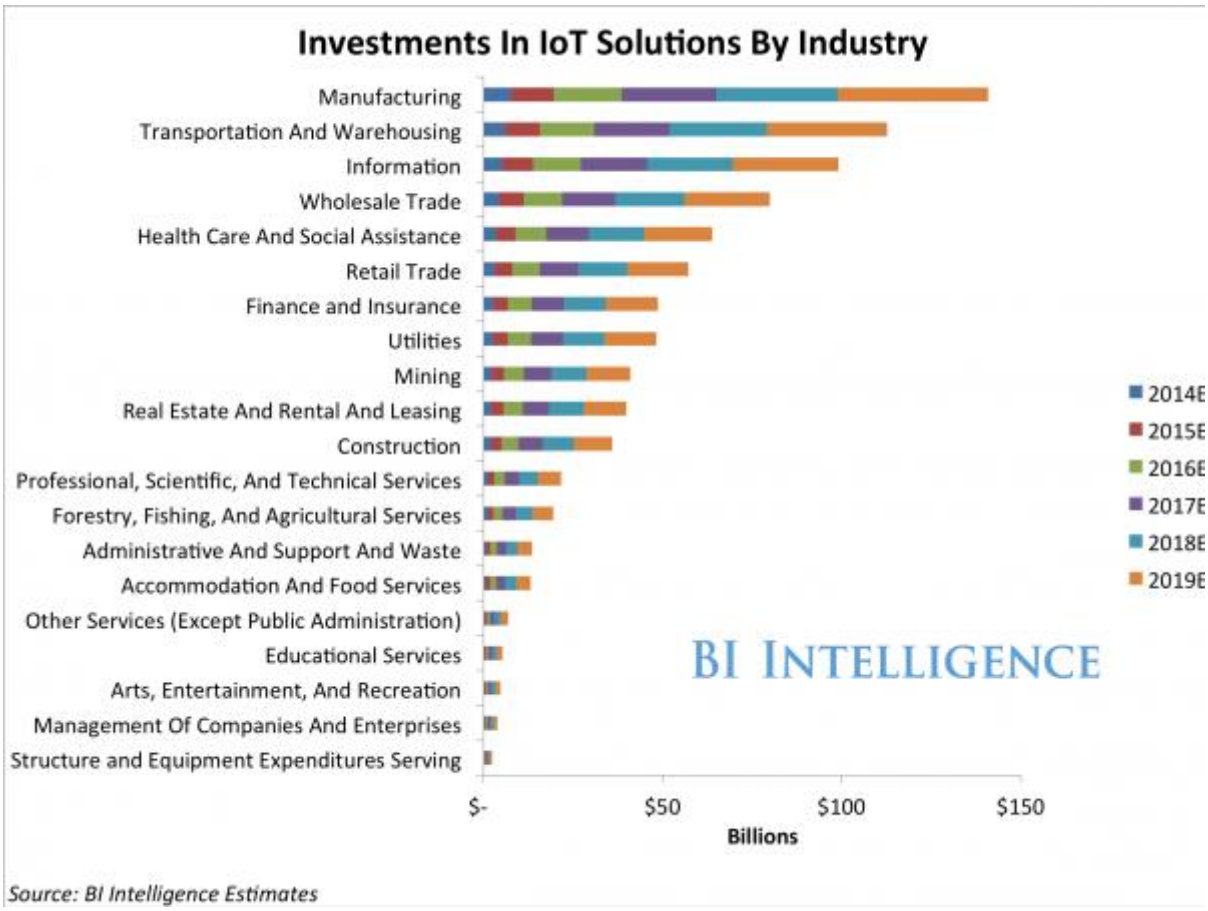
Uređaji koji se koriste za skupljanje podataka iz IoT-a su sve od malih sofisticiranih robota do čipova koji korisniku omogućuju ili da kontrolira uređaj na koji su spojeni ili da samo sa njega skuplja podatke.

Od ova tri sektora najveći je poslovni, i to pokazuju brojke[18]:

- Ukupno će na IoT do 2019. godine biti spojeno 23.3 milijarde uređaja
- Od toga 40% ili 9.1 milijarda uređaja pripadat će poslovnom sektoru
- Jednako veliko će biti i tržište mobilnih uređaja, sa procjenom da će broj pametnih telefona i tableta u 2019. godini iznositi 6 milijardi

[18] John Greenough (25. Veljače 2015.): Business insider, „The enterprise Internet of things report“ Dostupno na (http://www.businessinsider.com/the-enterprise-internet-of-things-market-2014-12)

Slika 9. Ulaganja u IoT



Izvor: http://www.businessinsider.com/the-enterprise-internet-of-things-market-2014-12 (pristupljeno 27.08.2017)

Daljne procjene za kretanje tržišta IoT-a:

- Potrošnja na proizvode i usluge poslovnog sektora iznosit će $255 milijardi godišnje do 2019. (u 2014. taj broj je bio $46.2 milijarde, što znači godišnju stopu rasta od 40% u idućih 5 godina)
- Softveri i usluge u poslovnom sektoru su uvjerljivo najisplativiji, sa godinšnjom prodajom od $43.9 milijardi, dok se hardver može pohvaliti prihodima od samo $2.3 milijarde
- Proizvodnja, prijevoz i sladištenje su 3 industrije koje će najviše ulagati u IoT do 2019. sa procjenjenim ulaganjem za proizvodnju od $140 milijardi
- Trenutno najveća kočnica ulaganjima u IoT su veliki troškovi instalacije kao i strah od cyber napada.

3.2 Usporedba dva vodeća BI rješenja

Poslovna inteligencija je jedan od najbrže rastućih sektora, ulaganja u sektor je broje u milijardama dolara svake godine, a sve se više direktora velikih tvrtki okreće ovoj grani kao izvoru informacija. Istraživanje KPMG-a 2017. godine pokazalo je da od 400 direktora u američkim tvrkama:

- 51% koristi analitiku za razvoj novih usluga i proizvoda
- 50% je koritsti kako bi unaprijedila poslovne procese i smanjila troškove
- 49% za pronalaženje novih kupaca
- 48% za reviziju strategije
- 46% za upravljanje rizikom
- 44% koristi podatke i analitiku za analiziranje potreba kupaca, njihovu vrijednost, profitabilnost i vjernost

Slika 10. Ulaganja u razne sektore Poslovne inteligencije do 2021. godine



Izvor: https://financesonline.com/comparison-looker-tableau-two-leading-business-intelligence-solutions/ (pristupljeno 27.08.2017)

Poslovna inteligencija danas ima tri važne komponenete koje moraju funkcionirati kako bi se pronašle sve važne informacije iz kojih se mogu izvući znanja koja zatim pomažu donositi odluke:

- Analitika
- Izvještavanje
- Vizualizacija

Dva su softvera preuzela glavnu ulogu na tržištu Poslovne inteligencije, Looker i Tableau.

Looker danas koristi preko 700 tvrtki diljem svijeta. Njihov jednostavni, web bazirani sustav služi za istraživanje podataka, izradu izvještaja, te može analizirati web pdoatke kao i SQL baze. On služi u slijedećim područjima:

1. Marketing
2. Prodaja
3. Upravljanje računima
4. Poslovni procesi
5. Podrška
6. Razvoj proizvoda
7. Web analitika

Tableau služi za povezivanje i vizualizaciju podataka. Baziran je na spremanje, sortiranje i podjelu informacija kao i za stvaranje vizualnih prezentacija, grafova i tablica. Tableau je najbolji u područjima:

- IT-a
- Analitike prodaje
- Društvenih medija
- Financija
- Ljudskih resursa

Cijena naravno zavisi o kompleksnosti rada i količini usluga koju koristimo. Kod oba se radi o mjesečnoj pretplati koja kod Lookera iznosi $3000 - $5000 mjesečno za 10 korisnika, a kod Tableau-a $50 - $350 mjesećno po osobi.

Tablica 1. Prednosti i nedostaci vodećih BI softvera

Pros & Cons		
	Pros	**Cons**
Looker	○ Jako SQL modeliranje ○ Ukomponirani SQL sa Big Data managementom ○ Lako za korištenje	○ Velika investicija ○ Preskup za male tvrtke
Tableau	○ Široki izvor podataka ○ Veliki izbor vizualnih pomagala ○ Brza obrada podataka	○ Potrebna velika količina znanja za korištenje ○ Spor kod velikih baza podataka

Izvor: https://financesonline.com/comparison-looker-tableau-two-leading-business-intelligence-solutions/ (pristupljeno 27.08.2017)

3.3 Case study-ji BI rješenja u svijetu[19]

Case study 1. Područje rada: Marketing

Klijent: SM Marketing Convergence Inc. (nadalje SM-MCI)

Pružatelj usluge: SAS

SM-MCI je velika marketinška kompanija vezana za maloprodaju. Velika količina podataka koju su primali, koja je brojila oko milijardu transakcija godišnje pokazala se previše te su se odlučili za BI rješenje.

U prvoj godini korištenja obrađeno je preko 200 milijuna transakcija iz preko 500 trgovina te je prema tim podacima napravljena nova kampalja koja je ciljala na određeni segment tržišta i pokazala se jako uspješnom. Prodaja je rasla, kao i zadovoljstvo kupaca, a količi robe na povratu se smanjila.

[19] Izvor: https://www.betterbuys.com/bi/definitive-guide-bi/bi-use-cases/ (pristupljeno 28.08.2017)

Case study 2. Područje rada: Prodaja

Klijent: Mama's & Papa's

Pružatelj usluge: Strategy companion

Mama's & Papa's je lanac prodavaonica za dječju odjeću u Ujedinjenom Kraljevstvu. Kako je posao rastao menadžment tvrtke je primjetio da su podaci o prodaji koje dobivaju često nepotpuni ili potpuno pogrešni. Problem su rješili sa alatom iz portfelja Strategy companion-a koji im je omogućio stvaranje točnih dnevnih i tjednih podataka o prodaji, prema kojima se dalje razvijaju strategije prodaje.

Sve je to olakšalo pratiti potražnju za određenim proizvodima po poslovnici i uveliko poboljšalo sustav dostave nove robe. Sljedeći korak tvrtke je iskoristiti nove informacije kako bi lakše odredili lokacije novih poslovnica, bazirano na prodaji po glavi po poštanskim brojevima.

Case study 3. Područje rada: Financije, javni sektor

Klijent: Ministarstvo sporta i turizma Republike Poljske

Pružatelj usluge: Panorama i drugi

Ministarstvo sporta i turizma Republike Poljske zaduženo je za alokaciju resursa za građenje i obnovu sportskih objekata i organizaciju događanja. Trebao im je sustav koji bi automatski označavao projekte sa nepotpunom dokumentacijom kao i one koji nisu realni za izvedbu. Također su željeli sustav koji bi davao pretpostavku uspjeha svakog obrađenog projekta.

Iskoristili su tri platforme na kojima su bazirali svoj projekt. MS Windows Azure, AMODIT i Panoramin Necto. Windows je dao infrastrukturu, AMODIT je organizirao proces predaje projekata, a Necto je služio za analizu.

Sustav je olakšao ministarstvu da prepozna probleme, te alocira potrebne resurse upravo u ta područja.

Case study 4. Područje rada: Ljudski resursi

Klijent: Intemountain Healthcare

Pružatelj usluge: Tableau

Sa 33,000 zaposlenih odjelu ljudskih resursa unutar Intemountain Healthcare trebala je pomoć kako bi lakše obrađivali zahtjeve i bolje upravljali ljudskim resursima.

To su uspjeli kroz softvare Tableau-a koji je management tvrtke shvatio kao nužan trošak za daljne poslovanje. Pomoću softvera uspjeli su prikupiti sve podatke o zaposlenima na jedno mjesto i analizirati poslovne procese i njihove troškove. Sada prije svakog projekta proučavaju se podaci iz baze podataka.

Također je olakšan i pregled potreba za novim kadrom i sada odjel puno lakše vidi kada raspisati natječaj za nove zaposlenike, na koja radna mjesta, kao i potrebne kvalifikacije za kvalitetno odrađivanje radnih zadataka.

3.4 Case study BI rješenja u Hrvatskoj: Orbico

Orbico grupa je vodeći distributer velikog broja globalno zastupljenih robnih marki vrhunske kvalitete, koje obuhvaćaju širok asortiman, od proizvoda za njegu i ljepotu, preko prehrambenih i neprehrambenih proizvoda, tehničkih i električnih uređaja do farmaceutskih proizvoda, igračaka, tekstila, cigareta, kao i motornih ulja. Takav opsežan i raznolik asortiman robnih marki i proizvoda zahtijeva visok stupanj fleksibilnosti, otvorenost prema stalnim promjenama, fleksibilnu i prilagodljivu organizaciju te ulaganja u razvoj ljudi i robnih marki.[20]

Tvrtka je osnovana 1987. u Hrvatskoj te danas zapošljava preko 3100 ljudi u 17 zemalja. Kada su krenuli širiti posao shvatili su da prisutnost na 15 tržišta u Europi i rad sa preko 20 tvrtki stvara veliku količinu podataka koju oni nemogu i neznaju obraditi. Bili su svjesni prisutnosti velike količine podataka i da se u njima kriju potencijalne nove prilike i odlučili nešto poduzeti po tom pitanju. Željeli su da tvrtka nastavi rast i da su svi njihovi klijenti dobiju prave proizvode u pravo vrijeme.

[20]Izvor: http://www.orbico.hr/hr/orbico (pristupljeno 28.08.2017)

Započeli su suradnju sa tvrtkom Poslovna Inteligencija koja koristi IBM-ove alate i stavili u pogon IBM® InfoSphere® DataStage®, koji je integrirao sve podatke sa svih sistema u tvrtki i omogućio svim zaposlenicima, na svim razinama pristup konzistentnim, svježim informacijama.

Sljedeći korak je bio uvođenje IBM Cognos ® Business Intelligence sustava koji je analizirao financije, prodaju i prihode kako bi unaprijedio poslovanje. U Orbicu kažu kako im je upravo ovaj sustav pomogao da zatvore financijsku strukturu, konsolidiraju troškove te povećaju svoje profite.

Kroz ovaj sustav Orbico je lakše pratio stanje na tržištima, što im je omogućio da uvijek budu korak ispred potreba na velikim i volatilnim tržišta Europe, a analitika je olakšala da Orbico zadrži bolji rejting kod financijskih institucija te kroz jeftine kredite širi poslovanje.

Romina Orešković. Financijska direktorica Orbico grupe rekla je: „IBM-ovi analitički alati olakšali su nam ciljati prilike koje štede vrijeme i novac, i brže reagirati na uvijek promjenjive zatjeve, što je ključna prednost u dinamičkoj industriji kao što je dostava.[21]

[21] Izvor: https://www-01.ibm.com/common/ssi/cgi-bin/ssialias?subtype=AB&infotype=PM&htmlfid=YTC04067USEN&attachment=YTC04067USEN.PDF

4. ZAKLJUČAK

Cilj ovoga rada je bio objasniti što je Poslovna inteligencija, koje poslove podrazumijeva te kako se primjenjuje danas kroz razne case study-je koji su obrađeni. Iz cijelog rada može se zaključiti da je Poslovna inteligencija grana poslovanja budućnosti.

Kompetitivnost raste iz godine u godinu kao i ulaganja u istraživanja koja iznose milijarde dolara na godišnjoj razini. Sve je više velikih tvrtki koje shvaćaju važnost nestrukturiranih podataka te žele način za zaraditi od toga, bilo kao pružatelj usluga ili kao korisnik. Ubrzani razvoj IT sektora u potpunosti prati i sve veću količinu podataka koja nastaje svaki dan. Današnjim generacijama je normalno biti „online“ cijelo vrijeme te učitavati, ali i skidati sadržaj sa interneta. Sve te transakcije stvaraju podatke koji se mogu obraditi i pomoći stvoriti bolji, kvalitetniji ili poželjnjiji proizvod i uslugu.

Trenutno smo u trendu gdje još uvijek količina informacija nadmašuje mogućnosti obrade ali kroz nekoliko godina i to će se promjeniti te će se sve informacije moći obraditi da se izvuć maksimalna korist iz njih. Nakon tog trenutka za očekivati je pad cijena usluga Poslovne inteligencije jer će doći do zasićenja tržišta ali ne za previše, jer će cijena računalnih sistema i dalje držati na vrijednosti kako se tvrtke sve više nauče i vežu za ovaj izvor podataka.

I u Hrvatskoj vidimo trend rasta upotrebe Poslovne inteligencije, kako i sve ostalo to je vidljivo u turizmu, gdje je jasno da ozbiljne tvrtke proučavaju podatke sa društvenih mreža kako bi saznali što gostima u Hrvatskoj nedostaje, te kako zadovoljiti taj segment tržišta.

Za očekivati je nastavak ovakvoga trenda jer informacije polako postaju valuta budućnosti bez koje će vođenje poslovanja biti nezamislivo.

5. POPIS TABLICA I SLIKA

Popis tablica:

Tablica 1. Prednosti i nedostaci vodećih BI softvera 24

Popis slika:

Slika 1. 4 faze rudarenja podataka 3
Slika 2. 4 Skladište podataka 4
Slika 3. „3V“ 7
Slika 4. Usporedba veličina jedinica za kapacitet računala 9
Slika 5. Arhitekura poslovne inteligencije 10
Slika 6. Osnovni imputi poslovne inteligencije 12
Slika 7. ROI sustava LogiXML u 2012. godini 15
Slika 8. Faktori uspjeha 17
Slika 9. Ulaganja u IoT 19
Slika 10. Ulaganja u razne sektore Poslovne inteligencije do 2021. godine 20

6. LITERATURA

1. Darin Stewart (01.08.2013) – Information Weekly – Big content: Taming the unstuctured side of Big data

2. Imhoff, C. (2003): “Keep your Friends Close, and your Enemies Closer“, DM review

(dostupno na: http://www.intelsols.com/documents/Imhoff_04-03.pdf)

3. John Greenough (25. Veljače 2015.): Business insider, „The enterprise Internet of things report“

(dostupno na: http://www.businessinsider.com/the-enterprise-internet-of-things-market-2014-12)

4. Langseth, J. i N. Vivatrat (2003) “Why Proactive Business Intelligence is a Hallmark of the Real-Time Enterprise: Outward Bound”, Inteligente Enterprise, 5“

5. Orbico grupa dostupno na : http://www.orbico.hr/hr/orbico

6. O skladištu podataka: http://www.zentut.com

7. Oxford Economics (2013): Change Readiness Index

8. Phocas business intelligence: https://www.phocassoftware.com/business-intelligence-blog/why-business-intelligence-projects-fail

9. Ralph Kimball et al.(2008): "The Data warehouse Lifecycle Toolkit", Wiley, New York, drugo izdanje

10. Rouse, M. (svibanj 2017.) :What is data mining? – TechTarget

(dostupno na http://searchdatamanagement.techtarget.com/definition/data)

11. Solomon Negash (velječa 2004): Business Intelligence, vol 13, članak 15 „Communications of the Association for Information Systems“,

12. TDWI online učenje, dostupno na https://tdwi.org/Home.aspx

13. Thomsen, E. (2003): “BI’s Promised Land”, Intelligent Enterprise, 2003.

14. William H. Inmon (1992.) – Building the Data Warehouse, Wiley, 1. izdanje, New York

15. Willen, C. (2002): “Airborne Opportunities”, Intelligent Enterprise

7. Sažetak

Ovo teorijsko istraživanje bavi se pojmom Poslovne inteligencije i njezine primjene u modernom poslovanju sa naglaskom na specifične studije slučaja. Opisuje sve prednosti i nedostatke korištenja sustava Poslovne inteligencije u obradi nestrukturiranih podataka, kao i korištenje baza podataka za unaprijeđenje poslovanja. Na temelju gotovih studija slučaja prikazuje kako su stvarne tvrtke iskoristile vlastite i javno dostupne podatke na internetu da otkriju prilike na tržištu i iskoriste ih za unaprijeđenje svog poslovanja kao i kako su uz te iste informacije, reagirali na prijetnje od strane konkurencije te uspješno reagirali kako bi zadržali svoje mjesto na tržištu, nešto što bez obrade nestrukturiranih podataka nebi bilo moguće.

Ključne riječi: Poslovna inteligencija, nestrukturirani podaci, internet

7. Summary

This theoretical research deals with the definition of Business intelligence and its application in the modern business with the emphasis on specific case studies. It describes all the advantages and disadvantages of using BI systems in processing unstructured data, as well as using databases for improving business. Based on finished case studies it shows how real companies used their own as well as public data online to discover opportunities in the market and use them to improve their business and how they used that same information to react to the threats from the competition and successfully reacted to keep their share of the market, something that without processing unstructured data would not be possible.

Key words: Business intelligence, unstructured data, internet