

MARIJAN MAČEK

UVOĐENJE SUSTAVA
POSLOVNE INTELIGENCIJE
U PROIZVODNOM
PODUZEĆU

DIPLOMSKI RAD

Marijan Maček

Uvođenje sustava poslovne inteligencije u proizvodnom poduzeću

DIPLOMSKI RAD

Sveučilište u Zagrebu
Ekonomski fakultet – Zagreb

Kolegij: Upravljanje podacima
Mentor: Prof. dr. sc. Katarina Ćurko
Broj indeksa autora: 0067474660

Zagreb, rujan 2019.

MARIJAN MAČEK
Ime i prezime studenta/ice

IZJAVA O AKADEMSKOJ ČESTITOSTI

Izjavljujem i svojim potpisom potvrđujem da je DIPLOMSKI RADA
(vrsta rada)
isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu, a što pokazuju korištene bilješke i bibliografija. Izjavljujem da nijedan dio rada nije napisan na nedozvoljen način, odnosno da je prepisan iz necitiranog rada, te da nijedan dio rada ne krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Student/ica:

U Zagrebu, 13. 07. 2019

Marijan Maček
(potpis)

Poslovna inteligencija uzdiže informacije i znanje na višu razinu unutar poduzeća. Podaci i informacije postaju bit poslovanja u 21. stoljeću. Informacije su na dohvat ruke. Na temelju njih, i uz njihovu pomoć, ljudi donose odluke, usmjeravaju svoje aktivnosti, obavljaju svakodnevne poslove i zadatke, planiraju budućnost i rješavaju probleme. Informacije pretvorene u znanje nužne su i nezamjenjive na svakom području ljudskog života. Inteligentno poduzeće je ono koje brže donosi kvalitetnije odluke i nadmudruje svoje konkurente. Znači, cilj je biti brži i mudriji od konkurenta. Količina podataka i informacija se udvostručuje svake dvije godine i potrebno je znati dobro iskoristiti to na dinamičnom tržištu koje stalno traži promjene. Poslovna inteligencija postaje osnovno strateško usmjerenje poduzeća. Nove inovacije na tržištu poslovne inteligencije su pokazatelj koliko je poduzećima potrebna pomoć oko poslovanja. Ključ uspjeha u poslovanju poduzeća su suvremene informacijske tehnologije, poslovni informacijski sustavi te čovjek koji će uz njihovu pomoć odnositi odluke.

Ključne riječi: poslovna inteligencija; informacije; skladište podataka; upravljanje znanjem.

Business intelligence takes information and knowledge to a higher level within the enterprise. Data and information are becoming the essence of business in the 21st century. The information is at your fingertips. Based on them and with their help, people make decisions, direct their activities, perform daily tasks and tasks, plan for the future and solve problems. Information transformed into knowledge is necessary and irreplaceable in every area of human life. An intelligent company is one that makes better decisions faster and outperforms its competitors. So the goal is to be faster and wiser than your competitor. The amount of data and information doubles every two years and you need to be able to make good use of it in a dynamic market that is constantly looking for change. Business intelligence is becoming a core strategic focus of businesses. New innovations in the business intelligence market are an indicator of how much business needs help with businesses. The key to success in business is modern information technology, business information systems and the person who will help them make decisions.

Key words: business intelligence; information; data warehouse; knowledge management.

Sadržaj

1. Uvod	1
1.1. Predmet i cilj rada	1
1.2. Izvori podataka i metode prikupljanja.....	1
1.3. Sadržaj i struktura rada	1
2. Upravljanje podacima i skladište podataka.....	3
2.1. Podaci i informacije	3
2.2. Baza podataka i skladište podataka	9
2.3. Obrada podataka.....	13
2.4. Zaštita podataka	16
3. Poslovna inteligencija.....	19
3.1. Objašnjenje pojma poslovna inteligencija.....	19
3.2. Ciljevi i koristi primjene sustava poslovne inteligencije	21
3.3. Razlozi primjene sustava poslovne inteligencije	25
3.4. Uvođenje sustava poslovne inteligencije	31
4. Uvođenje novog sustava poslovne inteligencije u proizvodno poduzeće.....	36
4.1. Prikaz problema prije uvođenja novog sustava poslovne inteligencije	36
4.2. Izbor i implementacija novog rješenja	37
4.3. Prednosti i koristi novog sustava poslovne inteligencije.....	43
5. Zaključak.....	46
LITERATURA:.....	50

1. Uvod

1.1. Predmet i cilj rada

Predmet ovog diplomskog rada je poslovna inteligencija i važnost njezine primjene za poduzeća. Podaci danas igraju sve važniju ulogu u svim poduzećima, i koriste se u svim evidencijama, od prodaje i plaća radnika, financijskih stanja, stanja zaliha i drugih. Podaci su s vremenom sve veći i sve su raznovrsniji, te je njihovo spremanje, analiza i pretraživanje sve kompleksnije. Zato menadžerima danas trebaju dobar i brz sustav koji im omogućavaju brže i djelotvornije donošenje odluka, odnosno trebaju sustav poslovne inteligencije.

Cilj rada je definirati ključne pojmove vezane za poslovnu inteligenciju, počevši od podataka, skladišta podataka pa do poslovne inteligencije te prikazati važnost uvođenja poslovne inteligencije u poslovanje poduzeća. Uvođenja novog sustava je dugotrajan i skup proces te često nailazi na otpor pojedinaca koji ne žele promjene načina rada. Cilj ovog rada je i prikazati prednosti koje donosi uvođenje novog sustav poslovne inteligencije u poslovanje.

1.2. Izvori podataka i metode prikupljanja

Izvori prikupljenih podataka su sekundarne prirode, odnosno, udžbenici, knjige, znanstveni i stručni članci prikupljeni na internetskim stranicama, te same internetske stranice koje istražuju i obrađuju ovu temu i problematiku te studija slučaja.

1.3. Sadržaj i struktura rada

Sadržaj i struktura rada sastoji se od 5 poglavlja. Nakon uvoda, govori se o teorijskoj podlozi o podacima, informacijama, bazama podataka, skladištenju podataka i upravljanju podacima općenito.

U sljedećem poglavlju objašnjen je pojam poslovne inteligencije, njezin razvoj kroz vrijeme te potrebe za uvođenjem u poduzeća i prednosti koje ona donosi.

Četvrto poglavlje odnosi se na uvođenje novijeg, suvremenijeg i sofisticiranijeg sustava, a nastavno na rast poduzeća. Prikazan je proces uvođenja i prednosti koje on donosi u odnosu na postojeći, zastarjeli, sustav koje poduzeće koristi.

Posljednje poglavlje je zaključak, u kojem su izneseni prednosti i koristi koje koncept poslovne inteligencije omogućava poduzećima, a poduzeća ovise sama o sebi u kojoj mjeri će uspjeti iskoristiti prednosti.

2. Upravljanje podacima i skladište podataka

U današnje suvremeno doba podaci i informacije su jako važni za svako poduzeće i predstavljaju strateški resurs poduzeća. Svakome poduzeću bitno je što bolje, brže i efikasnije koristiti podatke i informacije i predočiti ih u koristi i prednosti u odnosu na konkurenciju. Svakim danom sve je veći broj podataka i informacija koje su u većoj ili manjoj mjeri bitni za poduzeće. Poduzeća sve te podatke i informacije spremaju za daljnju i/ili ponovnu upotrebu i to iziskuje velika skladišta podataka.

Današnje poslovno okruženje brzo se mijenja, ekonomija poprima sasvim nove dimenzije i obrise, a jedino što je konstantno i stalno jest upotreba resursa u poslovanju. Pravodobna i točna informacija i znanje koje nastaje na temelju takvih informacija danas su kompanijama osnovni resurs poslovanja. Naime, informacije o prošlogodišnjem poslovanju mogu poslužiti za dobru analizu, dok su nove i svježije informacije bitne za donošenje budućih poslovnih odluka. Informacija nema samo obavještajnu funkciju, nego donosi novost koja može činiti buduću korist.¹

2.1. Podaci i informacije

Podatak je činjenica predočena u formaliziranom obliku, npr. kao broj, riječ ili slika. Podatak (engl. datum za jedninu, data za množinu) predstavlja simbolički i formaliziran prikaz činjenica, pojmova i instrukcija, pogodan za komuniciranje, interpretaciju i obradu uz pomoć ljudi ili strojeva.

Podatak je u osnovi poruka koja se može i ne mora iskoristiti. Ako postoji i najmanja vjerojatnost da se poruka jednoznačno i točno iskoristi, te predstavlja neospornu činjenicu, tada predstavlja informaciju. Svojstva objekata i njihovih odnosa u prostoru i vremenu izražavamo podacima. Podatak je u suštini nesupstancijalne naravi, i primarno postoji kao misaoni objekt.

¹ Srića, V. , Spremić, M.: Informacijskom tehnologijom do poslovnog uspjeha, Sinergija, Zagreb, 2000.

Pridružen je nekom konceptu, odnosno značenju kojim opisujemo svojstva. Podatak se može shvatiti kao apstraktna struktura sastavljena od: značenja, vrijednosti i vremena.²

Riječ podatak potječe od mn. lat. datum što znači dio informacije. Podatak je jednostavna neobrađena izolirana misaona činjenica koja ima neko značenje. Podaci (eng. Data) su znakovni prikaz činjenica i pojmova koji opisuju svojstva objekata i njihovih odnosa u prostoru i vremenu. Podatak je nematerijalne prirode, on jednostavno postoji u našim mislima i nema značenje unutar ili izvan svog postojanja ili o samom sebi pa se pridružuje značenju kojim opisujemo svojstva objekata. Može postojati u bilo kojem obliku bio upotrebljiv ili ne. Oblici podataka su zvučni, slikovni, broježani i tekstualni. Bilježe se na njima sukladne načine.

Podaci služe da bismo razumjeli pojmove i zapisali ih na nekom prenosivom mediju poput papira, filma, magnetskog medija ili elektroničkih medija. Prilikom zapisivanja podataka upotrebljava se niz znakova i skupova znakova, koji predstavljaju tehničko sredstvo zapisa podataka. Kao sredstva zapisa podataka koriste se znakovi abecede, prometni znakovi, specifični znakovi i drugi simboli i znakovi. Stoga možemo reći da je podatak skup prepoznatljivih znakova ili simbola zapisanih na nekom mediju. Mediji na kojima se zapisuju podaci mogu biti papir, film, magnetski disk ili neki drugi medij, odnosno zapis može biti u materijalnom ili u digitalnom obliku.³

Željko Panian i Goran Klepac u knjizi "Poslovna inteligencija"⁴ navode četiri osnovne kategorije kvalitete podataka koje izravno utječu na donošenje poslovnih odluka u poduzeću:

1. Standardiziranost

Različita interpretacija istih pojmova može dovesti do toga da se podatke prilikom unošenja u bazu podataka ne prepozna kao identične, već ih kompjutor shvati kao različite (primjer izraz "cijena proizvodnje" i "proizvodna cijena"). Tako dolazi do inkonzistencije u sadržaju baze podataka, koje zatim onemogućuju pravilno odgovaranje sustava baze podataka na korisničke upite i poduzimanje drugih složenijih operacija nad podacima u bazi (npr. agregacije, generalizacije, klasifikacije podataka i sl.). Da bi se izbjegle takve pogreške, preporučuje se zahvaćanje podataka u standardnim ujednačenim formatima i njihova dosljedna primjena te provođenje standardizacije poslovnih dokumenata i drugih izvora podataka. Time se ujedno

² <https://hr.wikipedia.org/wiki/Podatak> (29.08.2019.)

³ Varga, M. 2012.; Upravljanje podacima, Element, Zagreb, 2000.

⁴ Panian Ž., Klepac G., "Poslovna inteligencija", Masmedia, Zagreb, 2003.

omogućuje i jednostavnije pronalaženje sadržaja u bazi podataka, usporedba, klasifikacija i ostale logičke i analitičke operacije nad podacima.

2. Podudarnost

U praksi prikupljanja podataka često se javlja problem neplaniranog udvostručavanja ili umnožavanja slogova u bazi podataka. Do te pojave dolazi zbog malih varijacija prilikom registriranja određenih podataka, primjerice imena, prezimena i adrese kupca kojem se želi poslati katalog proizvoda. Standardni računalni programi te male varijacije ne prepoznaju kao identične, već ih pohranjuju u bazi podataka kao tri sloga, kao da se radi o tri različita kupca, čime se stvara pogrešan privid da su npr. novim katalogom upoznata tri kupca. Pomoću koncepta poslovne inteligencije moguće je primjenom suvremenih softverskih alata uočiti podudarnosti između nejednakih, a vrlo sličnih podataka i apstrahirati bitne od nebitnih pojedinosti.

3. Verificiranost

Postupkom verifikacije ili usporedbe utvrđuje se podudarnost bilo kojeg podatka s nekim poznatim izvorom koji služi kao predložak ili etalon. Verifikacija se odnosi na sve tipove podataka, tekstualne, brojčane, uzorke zvuka, slike digitaliziranih potpisa, multimedijских podataka itd. Postupak verifikacije poduzima se radi osiguranja točnosti podataka u repozitorijima poduzeća, a u cilju izvođenja pravilnih zaključaka odnosno donošenja kvalitetnih poslovnih odluka.

4. Proširivost

Upotrebom sofisticirane informacijske tehnologije danas je moguće dodavati nove podatke postojećem skupu podataka kao i mijenjati vrijednost postojećih podataka na način da ih se učini korisnijima za odgovarajuće primjene. Za te svrhe danas je moguće koristiti tehnologiju Web usluge kao aplikacijsko-komunikacijski servis koji omogućuje svim korisnicima direktnu

ugradnju podataka iz vanjskih izvora, putem Web usluge, u vlastito spremište ili skladište podataka.

S ljudskog su stajališta važni u prvom redu tipovi podataka, što se računalom obrađuju. Među najvažnije tipove podataka spadaju:

- Alfabetски (slovni) podaci, kao jednodimenzionalni prostorni podaci koji se sastoje samo od slova neke abecede
- Numerički (brojčani) podaci, kao jednodimenzionalni prostorni podaci koji se sastoje samo od brojeva nekog brojevnog sustava
- Alfaničerički (slovno-brojčani) podaci, kao jednodimenzionalni prostorni podaci koji se sastoje od slova, brojeva i posebnih znakova (na primjer znakova interpunkcije, matematički operatora itd.)
- Grafički podaci, kao dvodimenzionalni prostorni podaci koji se sastoje od bilo kakvih znakova rasoređeni u dvije prostorne dimenzije.⁵

Podaci u kontekstu i kombinirani unutar strukture čine informaciju. Obrada podataka je proces pretvorbe podataka u informacije. Da bi podatak postao informacija mora imati značenje novosti za primatelja, odnosno mora utjecati na povećanje razine znanja primatelja. Provođenje različitih postupaka: računskih (zbrajanje, oduzimanje) i logičkih (usporedba, manji, veći).

Riječ informacija potječe od lat. *informare* što znači informiranje, obavještanje. Informacija (eng. *Information*) je rezultat analize i organizacije podataka na način da daje novo znanje primatelju. Informacija je raznolikost poruka od pošiljatelja do primatelja. Ona postaje znanje kad je interpretirana, odnosno stavljena u kontekst ili kad joj je dodano značenje. Informaciju čine podaci kojima je dano značenje putem relacijskih veza, odnosno organizirani podaci koji su uređeni za bolje shvaćanje i razumijevanje. Značenje informacije može biti korisno, ali i ne mora.

⁵ Panian, Ž.: Poslovna informatika za ekonomiste, Masmedia, Zagreb, 2005.

Prema Bernardu Liautaudu, vrijednost određene informacije raste razmjerno s kvadratom broja korisnika koji imaju pristup toj informaciji pomnoženo s brojem poslovnih područja u kojima ti korisnici rade.⁶

Menadžeri rabe informaciju kao resurs, imovinu ili potrošnu robu.

Informacija kao resurs. Poput novca, sirovina ili strojeva, informacija može služiti kao resurs, odnosno kao input pri proizvodnji izlazne vrijednosti. Informacije su nezamjenjiv resurs pri pružanju usluga kupcima ili partnerima. Menadžerima informacije često služe kao zamjena za kapital ili radnu snagu uz istodobno snižavanje troškova.

Informacija kao imovina. Informacija može služiti kao imovina, vlasništvo osobe ili organizacije kojom se pridonosi stvaranju izlazne vrijednosti. U tom smislu informacija sličići opremi, postrojenjima, goodwillu ili ostalim tradicionalnim oblicima imovine neke organizacije. Menadžeri bi trebali informaciju tretirati strategijskim oružjem pomoću kojega mogu ostvariti prednost nad konkurentima.

Informacija kao potrošna roba. Kompanije kupuju i prodaju informacije, čime one postaju potrošna roba, kao što su automobili, kozmetika, odjeća ili perilice rublja. Moderna ekonomija je sve više uslužnog tipa, pa mnoge kompanije prave sve manju razliku između proizvoda i usluga i dodaju informaciju proizvodima stvarajući novu vrijednost.⁷

Znanje je odgovarajuća zbirka informacija kojoj je namjera da bude korisna. Znanje čine organizirane informacije koje se mogu koristiti za stvaranje novih značenja i podataka. Znanje je ljudska sposobnost poduzeti učinkovite postupke u raznolikim i neizvjesnim situacijama. Znanje je predodređen proces. Kada netko memorira informacije tada on skuplja, odnosno gomila znanje. To znanje ima korisno značenje njemu, ali ne osigurava samo po sebi uklapanje, odnosno integraciju kao što bi rezultiralo ili zaključilo daljnje znanje. Znanje čine činjenice koje postoje unutar psihičke strukture koju svijest može obraditi. Ljudski um koristi to znanje za biranje između mogućnosti, a time reagiranje i ponašanje postaje inteligentnije. Kada vrijednosti i obveze vode inteligentno ponašanje, ono je zapravo temeljeno na mudrosti. Mudrost je imanje iskustva, znanja, razumijevanja uz moć primjenjivanja sveg

⁶ Liautaud, Bernard, "e-Business Intelligence: Turning Information into Knowledge into Profit" McGraw-Hill, New York, NY, 2001.

⁷ Srića, V. , Spremić, M.: Informacijskom tehnologijom do poslovnog uspjeha, Sinergija, Zagreb, 2000.

troje sa razboritošću, praktičnošću, diskretnošću i zdravim razumom, odnosno mudrost je sposobnost donošenja ispravnih odluka.

DIKW (engl. Data, Information, Knowledge, Wisdom) je prijedlog strukturiranja podataka, informacija, znanja i mudrosti u jednu informacijsku hijerarhiju gdje svaka razina dodaje određena svojstva iznad i ispod one prethodne. Podatak je najosnovnija razina, informacija dodaje kontekst, znanje dodaje kako ga upotrijebiti, a mudrost dodaje kada i zašto ga upotrijebiti. DIKW model se temelji na pretpostavljanju sljedećeg niza postupaka: podatak dolazi u obliku neobrađenih zapažanja i dimenzija, informacija se oblikuje analiziranjem veza i odnosa između podataka, znanje se oblikuje koristeći informaciju za djelovanje, mudrost se oblikuje kroz upotrebu znanja, kroz komunikaciju korisnika znanja i kroz razmišljanja. Općenita je misao da je podatak manji od informacije, a informacija je manja od znanja, odnosno, da bi se kreirala informacija potreban je podatak i samo kada postoji informacija znanje može izaći na vidjelo.

Sadržaj ljudskog uma (prema Russellu Ackoffu) čine: podatak, informacija, znanje, razumijevanje (spoznajni i analitički proces koji odgovara na pitanje zašto) i mudrost. Ackoff pritom upozorava da se prve četiri kategorije odnose na prošlost i bave se onim što je bilo ili onim što je poznato. Samo se peta kategorija, mudrost, bavi budućim vremenom jer sadržava maštovitost, pronicljivost i kreativnost. Do mudrosti se ne dolazi lagano i jednostavno, najprije se mora uspješno proći kroz sve prethodne kategorije. S pomoću razumijevanja se može postojećim znanje stvarati novo, odnosno, ljudi koji imaju razumijevanje mogu poduzimati korisne aktivnosti zato što mogu sastaviti novo znanje ili barem nove informacije na temelju već postojećeg znanja. Razlika između znanja i razumijevanja je kao i između učenja i memoriranja.

Iako su naše koncepcije podatka, informacije i znanja napredovale tijekom vremena u potpunosti je jasno da je T. S. Eliot bio sposoban da se bavi time i definira neke vrlo ozbiljne odnose koji su nastavili utirati put našem današnjem poimanju svijeta. Ono što možemo izvesti kao zaključak iz ovog teksta, a ujedno i povezati sa modernim načinom života jest sljedeće: Znanje je rezultat učenja.⁸

Povećanje razine znanja dovodi do boljeg odlučivanja i omogućuje bolje i brže djelovanje u užurbanom i dinamičnom poslovnom okruženju. Nove tehnologije svakodnevno dovode do

⁸ https://hr.wikipedia.org/wiki/Podatak,_informacija,_znanje,_mudrost#Podatak (29.08.2019.)

ubrzanja stvaranja i sve većih količina podataka i informacija. Informacija na tržištu gubi vrijednost ukoliko je opće poznata.

2.2. Baza podataka i skladište podataka

Danas, više nego ikad, menadžerima su potrebni lako dostupni i konzistentni podaci predstavljeni tako da u isto vrijeme, precizno i sažeto daju prikaz organizacije u cjelini kao i njenog okruženja. Međutim složeni uvjeti poslovanja generiraju svakim danom sve veći broj poslovnih događaja u okviru preduzeća i izvan njega, a dobiveni podaci najčešće su pohranjeni u operativnim bazama podataka.

Uvjeti konkurencije na svjetskom tržištu, velika kompleksnost i dinamičnost poduzeća i njegova okruženja zahtjeva učinkovito upravljanje i djelotvorno odlučivanje. Brze, agregirane i vizualno pristupačne informacije postaju važan upravljački resurs na svim razinama odlučivanja i upravljanja i uglavnom ovise o sposobnosti i znanju korištenja moderne informacijske tehnologije.⁹

Baza podataka je softverska konstrukcija namjenjena za pohranjivanje, analizu i pretraživanje grupe srodnih i povezanih podataka, kao što su podaci o kupcima, pacijentima, telefonskim brojevima, proizvodima i sl. Baza podataka sastoji se od jedne ili više (dvodimenzionalnih) tablica koje međusobno mogu biti povezane. Svaka tablica čuva istovrsne podatke (npr. podatke o nekoj osobi, predmetu i sl.). Svaki red u tablici predstavlja jedan slog u tablici (najmanja grupa podataka u bazi koja u potpunosti opisuje neki od koncepta koje baza modelira), svaka kolona jedno od polja unutar tog sloga. Dakle, slog može biti grupa podataka koja opisuje npr. neku osobu, a polja unutar tog sloga mogu sadržavati ime, prezime, adresu stanovanja ili datum rođenja te osobe. Slog se u literaturi još ponegdje naziva i entitet, a polje se naziva atribut.

Jedna od mogućih definicija baze podataka glasi da je to zbirka zapisa pohranjenih u računalu na sustavni način, takav da joj se računalni program može obratiti prilikom odgovaranja na problem.

DBMS (engl. Data Base Management System) – sustav za upravljanje bazom podataka. To je softversko – hardverski paket koji omogućava da baza podataka bude lako dostupna svim

⁹ Ćurko, K., Kezan, Š.M.: Skladištenje podataka – Put do znanja i poslovne inteligencije, Ekonomski fakultet – Zagreb, Zagreb, 2016.

korisnicima. Softverski dio DBMS, služi kao veza između korisnika i baze podataka. On osigurava softverske alate potrebne za kreiranje, primjenu, pristupanje i ažuriranje baze podataka. Također upravlja ulazno – izlaznim operacijama, a na većim sustavima vodi računa o tajnosti i problemima istovrsnih korisnika. Ukratko, dobro projektiran DBMS će osigurati sustav koji omogućava korisniku da lako komunicira sa bazom podataka i brzo nađe potrebne podatke i informacije.

Prvi sustavi upravljanja bazom podataka razvijeni su u 1960-ima. Začetnik u tom polju bio je Charles Bachman. Bachmanovi rani radovi pokazuju da je njegov cilj bio stvaranje djelotvornije upotrebe novih uređaja s izravnim pristupom pohrane koji su postali dostupni: do tada se obrada podataka temeljila na bušenim karticama i magnetskoj vrpci, pa je tako serijska obrada bila dominantna aktivnost.¹⁰

Baze podataka se koriste u mnogim aplikacijama, protežući se na stvarno čitav opseg računalnog softvera. Baze podataka su poželjna metoda spremanja velikih multikorisničkih aplikacija gdje je potrebna koordinacija između mnogih korisnika.

Baze podataka do danas su najkompleksniji način organiziranja i korištenja pohranjenih podataka. Napredni sustavi za upravljanje bazom podataka kontroliraju složene strukture podataka i integriraju ih u jedinstveni sustav. Svrha sustava baze podataka jest pretvaranje niza podataka u korisne informacije prikazane u obliku pogodnom za korisnika.

Skladište podataka (engl. data warehouse) skup je podataka organizacije na kojem se temelji sustav potpore odlučivanju. Iz svrhe proizlazi da skladište podataka treba podacima potpuno "pokriti" jedno ili više poslovnih područja (npr. nabave, prodaje), da podaci u skladištu trebaju biti sveobuhvatni, tj. "integrirani" od unutarnjih podataka organizacije, ali i podataka iz njenog okruženja. Podaci moraju obuhvatiti duži vremenski period (pet, deset ili više godina), jer su vremenske analize poslovno vrlo značajne. Orijentiranost prema poslovnim analizama ne zahtijeva od skladišta da se podaci promptno ažuriraju kao u bazi podataka.¹¹ Manje skladište podataka koje obuhvaća podatke samo jednog poslovnog područja naziva se područnim skladištem podataka (engl. data mart). Skladište podataka namijenjeno je menadžerima, ali i svima koji u svom poslu obavljaju različite analitičke zadatke, kao što su poslovi praćenja i izvještavanja, koji se temelje na primjeni različitih poslovnih pravila, a obavljaju se postavljanjem usmjerenih upita i analizom dobivenih rezultata; poslovi analize i

¹⁰ https://hr.wikipedia.org/wiki/Baza_podataka (13.08.2019.)

¹¹ Inmon W.H., Building the Data Warehouse, John Wiley & Sons, Inc. New York, 1992.

dijagnosticiranja, koji se temelje na umješnosti, a obavljaju se iterativnim pronalaženjem i analizom dobivenih informacija; i poslovi planiranja i simulacije, koji se temelje na znanju, a obavljaju se modeliranjem i izvršenjem izrađenog modela.¹²

Skladište podataka sadrži podatke prikupljene iz različitih izvora, povijesne o poslovanju poduzeća kao i podatke iz vanjskog okruženja, a dizajnirano je tako da omogućava pretraživanje podataka, on-line analitičku obradu, izvještavanje i podržavanje procesa donošenja odluka.

Prema definiciji koju je postavio William H. Inmon, skladište podataka predstavlja subjektivno usmjeren (Engl. subject-oriented), integriran (Engl. integrated), vezan na vrijeme (Engl. time-variant) i sadržajno nepromjenjiv (Engl. non-volatile) skup podataka, a krajnji cilj mu je pomoć menadžmentu pri donošenju odluka.¹³

Osnovna funkcija skladišta podataka je skupljanje podataka i stvaranje logički integriranih i predmetno usmjerenih informacija. Treba ga oblikovati na način da se može na jednostavan način i brzo prilagođavati svim promjenama i zahtjevima poslovnog okruženja.

Glavni cilj skladišta podataka je osloboditi informacije koje su "zaključane" u bazama podataka i "pomiješati" ih s informacijama iz ostalih, u pravilu vanjskih izvora podataka. Velike organizacije danas sve više traže dodatne podatke iz vanjskih izvora, kao što su npr. podaci o konkurenciji, demografski trendovi, prodajni trendovi i sl.

Sam pojam "skladište podataka" (engl. Data Warehouse) podrazumijeva zbirku podataka izoliranih iz operativnih baza i spremljenih u posebne baze. Glavna karakteristika koja određuje skladište podataka odnosi se na njegovu svrhu. U skladištu podataka podaci se skupljaju i organiziraju na način da budu lako dostupni da bi ih menadžment mogao na brz i jednostavan način koristiti za potrebe analize svog poslovanja.

Uspostavljanjem skladišta podataka, operativne baze podataka rasterećuju se složenih upita pa dolazi do unapređenja njihovih operativnih funkcija. Iz operativnih baza time je uklonjena ogromna masa najčešće povijesnih podataka i preseljena je u skladište podataka. Informacijski sustav sastoji se sada od dva dijela, operativnog dijela i skladišta podataka. Budući da se tako lakše kontrolira i restrukturira on postaje puno produktivniji.

¹² Varga, M.; Baze podataka, Konceptualno, logičko i fizičko modeliranje podataka, Društvo za razvoj informacijske pismenosti (DRIP), Zagreb, 1994.

¹³ "The Business Intelligence and Data Warehousing Glossary", dostupno na: <http://www.sdgcomputing.com/glossary.htm> (30.08.2019.)

Skladište podataka (Engl. data warehouse) nova je generacija računalnog sustava za potporu odlučivanju. Pojednostavnjeno rečeno, ideja skladištenja podataka je ovakva: potrebno je podatke iz operativne baze (ili više njih) izdvojiti i spremati u posebne baze (skladište podataka) i pripremiti za zahtjevne analize, za "prekopavanje" podataka i pronalaženje informacija za učinkovito odlučivanje.

Skladištenje podataka je važan koncept učinkovitog sustava potpore odlučivanju, koji se intenzivno razvija posljednjih godina. Donosi ideju aktivnog pronalaženja i nuđenja informacija menadžeru, potrebnih u procesu odlučivanja. Koristi se postupcima analitičke obrade, rudarenje podataka i otkrivanja znanja iz podataka. Spomenutim se konceptima i metodama na temeljima informacijske tehnologije želi postići "inteligentno" poslovanje poduzeća u kompleksnim tržišnim uvjetima. Za to se već uvriježio naziv poslovna inteligencija. U doba internetske ekonomije poslovna inteligencija počiva na podacima, koji se transformiraju u informacije potrebne za odlučivanje i upravljanje.¹⁴

Odvajanjem baze i skladišta podataka, u bazi podataka zadržava se učinkovitost transakcijske obrade, a u skladištu podataka ostvaruje mogućnost dobre analitičke obrade. Međutim, danas je, uz korištenje jačih sustava za upravljanje bazom podataka, moguće transakcijske podatke baze podataka i analitičke podatke skladišta podataka držati u jednoj fizičkoj bazi podataka. U takvoj su bazi podataka transakcijski i analitički podaci razdvojeni, a sustav za upravljanje bazom podataka sposoban je istovremeno izvršavati transakcijske i analitičke obrade podataka.¹⁵

Podaci se skupljaju u bazu podataka iz različitih izvora i pohranjuju uvijek u istom formatu, te su konzistentni i prikazuju se na dosljedan način.

Postupak skladištenja podataka predstavlja kontinuiran proces planiranja, građenja, i prikupljanja podataka iz različitih izvora te njegovog korištenja, održavanja upravljanja i stalnog unaprjeđenja. Među mnogim koracima u tom kompleksnom kontinuiranom procesu bitno je naglasiti važnost posjedovanja vizije o tome što se želi postići kreiranjem skladišta podataka. Jedna od uloga skladišta je primjerice razvijanje i korištenje znanja zasnovanog na podacima (engl. data-based knowledge).

¹⁴ Varga, M.; Baze podataka, Konceptualno, logičko i fizičko modeliranje podataka, Društvo za razvoj informacijske pismenosti (DRIP), Zagreb, 1994.

¹⁵ Varga, M.; Baze podataka, Konceptualno, logičko i fizičko modeliranje podataka, Društvo za razvoj informacijske pismenosti (DRIP), Zagreb, 1994.

Skladište podataka treba biti izvor stabilnih podataka, nezavisnih od eventualnih promjena u poslovnim procesima. Iz tog razloga potrebno je koristiti model neosjetljiv na utjecaje operativnih procesa koji kreiraju većinu podataka. Oslobođeno operativnih obrada, skladište podataka osigurava unapređenje procesa generiranja informacija, a kroz tehnike otkrivanja znanja osigurava stalno pronalaženje novih informacija.

2.3. Obrada podataka

Dobivanje informacija u poslovnom svijetu vrlo je važno i ono predstavlja mogućnost stvaranja nadmoći i prednosti nad onima koji ih ne posjeduju. Opće poznate informacije dostupne svima nemaju veliku važnost i vrijednost. Informacije o novim trendovima, tržiština ili inovacijama puno su vrijednije i lako ih je iskoristiti za očuvanje ili stjecanje prednosti pred konkurentima.

Obrade podataka u funkciji poslovne inteligencije temelje se:

- na pravilima – To su poslovi izvještavanja i praćenja koji se obavljaju pretraživanjem podataka tako da se bazi podataka uputi standardiziran upit ili zahtjev za obradom podataka, koji rezultiraju standardnim izvještajem. Ovi poslovi pripadaju operativnoj analizi, a obavljaju se u okviru transakcijskog podsustava.
- na umješnosti – To su poslovi analize i dijagnosticiranja koji se obavljaju iterativnim pronalaženjem informacija tako da analitičar postavlja upite bazi podataka, analizira dobivene rezultate i ovisno o njihovom ishodu postavlja nove upite te tako postepeno napreduje u postupku analize i dijagnosticiranja. Ovi poslovi pripadaju taktičkoj analizi, a obavljaju se u okviru podsustava za potporu odlučivanju analitičkom obradom dimenzijskih podataka.
- na znanju – To su poslovi planiranja i simulacije koji se obavljaju izradom i izvršavanjem modela tako da analitičar najprije izradi model plana ili simulacije, a zatim ga upućuje bazi podataka na izvršenje. Takvi se poslovi obavljaju pri strateškoj analizi.

Ovdje možemo ubrojiti metode otkrivanja znanja (rudarenje podataka), simulacijske metode, ekspertne sustave.¹⁶

1. Transakcijska obrada

Transakcijski (operativni) podsustav pruža potporu tekućem izvođenju poslovnog procesa izvršenjem brojnih transakcija. Bitno je da su pojedini dijelovi podsustava podatkovno dobro povezani unutar poduzeća. U poduzećima se razvijaju integrirani sustavi ili se aplikacije integriraju s namjerom da funkcioniraju kao cjelina i omogućuju bolju suradnju među njima.

Transakcijski podsustav omogućava olakšano donošenje odluka. Dio poslovnog odlučivanja, strukturiranog, može se ugraditi u transakcijske obrade i sustav tada može samostalno donositi odluke. U skladišnom poslovanju, uz određene parametre sustav može sam odlučiti kada je potrebno naručiti novu pošiljku robe, tj. kada stanje robe bude ispod zadanog parametra automatski dojavljuje ili sam donosi odluku.

2. Analitička obrada podataka

Analitičke obrade podataka vezane su uz skladište podataka i dimenzijski organizirane podatke u skladištu. Dimenzija je atribut (u statistici se naziva varijablom) kroz koju se prati poslovanje. Elementi dimenzije su pozicije ili članovi (u statistici to su modaliteti varijable). Dimenzije pripadaju kategorijalnim (kvalitativnim) atributima, jer njihovi podaci (pozicije) pripadaju nominalnoj ili ordinalnoj skali. One se mogu kategorizirati i u nadređene pozicije. Hijerarhijsko uređenje pozicija jedne dimenzije omogućuje da se neka poslovna pojava prati detaljizirano (analitički) ili agregirano (sintetički). Postupak silaženja u područje detaljnih podataka (detaljiziranje) je «svrdlanje prema dolje» (engl. drill down), a obrnut postupak (agregiranje) «svrdlanje prema gore» (engl. drill up). Vrijednost ili mjera je kvantitativni atribut čiji podaci pripadaju intervalnoj ili omjernoj skali (numerički, diskretni ili kontinuirani atribut). Broj

¹⁶ Varga, M.: Poslovna inteligencija: ciljevi i metode, Ekonomski fakultet – Zagreb, 2004.
dostupno na: https://bib.irb.hr/datoteka/166465.Poslovna_inteligencija_HrOUG_2004.pdf (13.08.2019.)

prodanih primjeraka i iznos prodaje primjeri su dviju mjera. Podaci mjera su zbrojivi. Međutim, to ne vrijedi za dimenzijske atribute koji su nezbrojivi. Dimenzijski je prikaz podataka u mnogim primjenama «vizualniji» od tabličnog, a tako prikazani podaci lakše se interpretiraju. Dakle, dimenzijski je prikaz pogodniji ako nas zanima i međuodnos «dimenzijskih» atributa.¹⁷

Veći broj međuodnosa među atributima dovodi do veće vjerojatnosti da će dimenzijska analiza donijeti vrijedne poslovne informacije. Iskusni menadžer uvidjet će u međuodnosima među atributima velik broj korisnih informacija i znat će ih iskoristiti na najbolji način da pridonese poduzeću te da si olakša donošenje odluka.

Pri obradi dimenzijskih podataka susrećemo specifične operacije: rotiranje, selektiranje te detaljiziranje. Rotacija je promjena orijentacije dimenzija, tj. određivanje redoslijeda dimenzija u prikazu. Selekcija je izbor pozicija jedne dimenzije. Detaljiziranje i agregiranje odnosno silaženje i uzlaženje po hijerarhiji pozicija jedne dimenzije također se smatra operacijom specifičnom za dimenzijsku bazu podataka. Spomenute operacije međutim nisu dovoljne, pa skladište podataka mora imati šire mogućnosti obrade podataka. Skupno ih nazivamo analitičkom obradom podataka (engl. On-Line Analytic Processing – OLAP). Ona omogućava korisniku dimenzijske baze podataka da s lakoćom obavi analitičke upite odnosno obrade, kao što su modeliranje i proračunavanje dimenzijskih podataka, analizu vremenskih serija, pronalaženje izuzetaka, detaljiziranje ili agregiranje promatranih pojava, izradu izvješća za potrebe internih i eksternih korisnika.

3. Obrada polustrukturiranih sadržaja

Treća vrsta obrada obuhvaća različite slabo strukturirane podatke (tekstove, slike, zvučne i video sekvence) koje poduzeća sve češće tretiraju kao poslovne podatke. Podatke ovog tipa čine različiti poslovni dokumenti, dokumentacija, poruke el. pošte, slikovni dokumenti, video dokumenti itd. Internetske tehnologije (HTML, XML, portalne tehnologije) omogućuju znatno lakši pristup i obradu takvih podataka, a programski sustavi namijenjeni upravljanju njihovim sadržajem omogućuju obradu tijekom čitavog životnog ciklusa sadržaja. Ciklus uključuje stvaranje «kućnog» sadržaja, prihvaćanje vanjskog sadržaja, stvaranje veze među tim sadržajima, prilagođivanje sadržaja, davanje dodatnih atributa sadržajima, definiranje prava i

¹⁷ Varga, M.: Poslovna inteligencija: ciljevi i metode, Ekonomski fakultet – Zagreb, 2004.
dostupno na: https://bib.irb.hr/datoteka/166465.Poslovna_inteligencija_HrOUG_2004.pdf (13.08.2019.)

davanje dozvola korištenja, objava sadržaja, arhiviranje i brisanje. Sadržaji su smješteni u bazama dokumenata (ili bazama podataka koje prihvaćaju polustrukturirane sadržaje), a sve rjeđe u skupovima datoteka. Ovdje možemo ubrojiti i «suradničke» sustave, koji omogućuju komunikaciju i suradnju pojedinaca ili skupina ljudi.

2.4. Zaštita podataka

Podaci i informacije danas predstavljaju najveću vrijednost u poslovanju, pa je stoga njihova adekvatna zaštita od primarnog interesa za svaku tvrtku. Gubitak ili krađa informacija predstavlja mjerljiv materijalni gubitak za organizaciju. Adekvatna zaštita zahtijevana je brojnim zakonima, regulativama i standardima (Zakon o tajnosti podataka, Zakon o zaštiti osobnih podataka, Odluka HNB o primjerenom upravljanju informacijskim sustavom, Zakon o informacijskoj sigurnosti,...).

Zbog raznih prijetnji sigurnosti podataka, kako “izvana”, tako i “iznutra”, povjerljive podatke danas je sve teže zaštititi. Unatoč brojnim sigurnosnim mjerama i mehanizmima koji onemogućavaju pristup podacima izvan korporativnog informatičkog sustava, kao i onima koji onemogućavaju legitimne korisnike da dođu do istih, sve češće se susrećemo s vijestima o gubitku povjerljivih informacija. Gubitak laptop računala, presretanje elektroničke pošte s povjerljivim informacijama, nedovoljan uvid u pristup pojedinim podacima ili datotekama, a vrlo često i neznanje da takvi podaci postoje, samo su neki od uzroka gubitka informacija.

Enkripcija omogućava zaštitu podataka izmjenama samih informacija, tako da originalni sadržaj može vidjeti samo osoba koja posjeduje ključ za dekripciju. Na taj način osigurava se i sigurna razmjena informacija. Sustav za enkripciju treba podržavati mogućnost centraliziranog upravljanja korisnicima i ključevima i mogućnost jednostavnog dijeljenja ključeva. Tipični scenariji enkripcije uključuju:

- zaštitu PC računala i laptopa enkripcijom cijelog diska
- zaštitu prijenosnih uređaja za pohranu (USB diskovi i memorije)
- zaštitu korporativnih komunikacija enkripcijom osjetljivih e-mailova, ili e-mailova pojedinih korisnika
- zaštitu e-mail komunikacije na Blackberry i Windows Mobile uređajima
- zaštitu osjetljivih datoteka i direktorija i njihovu sigurnu razmjenu

- sigurnu razmjenu datoteka između različitih tvrtki ili različitih sustava

Suvremene mogućnosti komunikacije predstavljaju problem kad je u pitanju mogućnost neovlaštenog širenja povjerljivih informacija. Internet, mobilni uređaji, prenosivi uređaji za pohranu podataka koriste se u svakodnevnom poslovanju, pa tvrtke trebaju voditi računa o tome koje osjetljive podatke posjeduju, gdje se oni nalaze i tko im smije pristupiti, te kako spriječiti “curenje informacija”. Problem nadzora pristupa informacijama prepoznat je i reguliran brojnim zakonima i regulativama. Suvremena informatička rješenja za sprečavanje gubitka informacija temelje se na sljedećim načelima:

- Opisivanje (Engl. Describing) – Štite strukturirane i nestrukturirane podatke tražeći sadržaj koji odgovara ključnim riječima, izrazima, uzorcima ili „potpisima“.
- Identifikacija (Engl. Fingerprinting) – Štite strukturirane i nestrukturirane podatke tražeći točno ili djelomično podudaranje sa sadržajima u indeksiranim izvorima podataka i dokumenata.
- Učenje (Engl. Learning) – Štite nestrukturirane tekstualne podatke izgrađujući statistički model koristeći ogledne dokumente i kalkuirajući sličnosti sadržaja.¹⁸

Računalni kriminalitet obuhvaća kriminalne radnje pomoću i na računalu. Na računalu: spada neovlašteni pristup u cilju brisanja ili mijenjanja programa radi onesposobljavanja ili stjecanja imovinske koristi i u svrhu industrijske šijunaže. Pomoću računala: računalo se rabi kao sredstvo, za stjecanje imovinske koristi kao rezultat prijevare učinjene putem računala. Kriminalci posjeduju puno kompjuterskog znanja – manipulacijama dolaze do broja kreditnih kartica, bankovnih računa itd. Preventiva se provodi posebnim tehnikama (prvenstveno bazirane na kriptografskim tehnikama).

Kompjuterski kriminalci koriste trikove da pronađu prečac za nedopušteni ulaz u računalni sustav. Mogu koristiti ovaj ulaz za ilegalne ili destruktivne svrhe, ili jednostavno mogu testirati vlastitu vještinu da vide jesu li sposobni za takav ulaz u sustav. Većini kompjuterskih kriminalaca je glavni motiv napada znatiželja ili višak slobodnog vremena, pa je velika

¹⁸ Enkripcija i zaštita podataka, dostupno na: <http://www.itsistemi.com/hr/rjesenja/sigurnosna-rjesenja/enkripcija-i-zastita-podataka/> (26.08.2019.)

vjerojatnost da će u jednom trenutku, nakon bezbrojnih pokušaja, pronaći naprednu metodu napada i ući i u najbolje čuvani sustav. Ostali motivi mogu biti psihološka potreba, želja za učenjem, osveta, eksperimentiranje, nepovjerenje u druge osobe, samopriznanje, želja da nekoga pobijede ili zabava.

Policija i sigurnosne agencije često angažiraju hakere da surađuju sa njihovim djelatnicima u svrhu sprječavanja i otkrivanja napada na stranice i softvere državnih i drugih institucija poput banki, zračnih luka i dr. Također rade na zajedničkim pokušajima provaljivanja na takve stranice da se otkriju potencijalni nedostaci u sigurnosti.

Zbog lakog dostupa podacima i informacijama u današnje doba, vrlo je važno biti oprezan i pažljiv u komunikaciji i drugim postupcima koji bi mogli dovesti do neželjenih posljedica. Najmanja neopreznost, koju možda niti ne primjetimo, nekome može biti dovoljna za krađu osobnih podataka, broja kartice banke ili možda čak i PIN-a i sl. Postoje brojne mjere zaštite podatak i definitivno je potrebno primjenjivati ih u svakodnevnom životu.

3. Poslovna inteligencija

3.1. Objašnjenje pojma poslovna inteligencija

Jedan od najvažnijih problem danas nije prikupljanje informacija, već interpretacija i pretvaranje informacija u znanje.

Poslovna inteligencija predstavlja arhitekturu i kolekciju integriranih operativnih aplikacija, zatim aplikacija za potporu odlučivanju i baza podataka koje poslovnim sustavima omogućuju lagan pristup podacima. Nadalje, poslovna inteligencija predstavlja skupinu novih aplikacija oblikovanih tako da mogu organizirati i strukturirati podatke o poslovnim transakcijama na način koji omogućuje analizu korisnu u potpori odlučivanju i operativnim aktivnostima kompanije.¹⁹ Jednostavnije rečeno, poslovna inteligencija predstavlja proces prikupljanja raspoloživih internih i eksternih podataka te njihovu pretvorbu u korisne informacije koje pomažu poslovnim korisnicima pri donošenju odluka.

Kako bi se donijela prava odluka potrebno je uvažiti ukupnost svih društvenih kretanja i znati selektirati važne od nevažnih informacija. Upravo zbog toga razvijen je poslovna inteligencija. Danas se inteligencija sve više usmjerava na područje gospodarstva koje je obilježeno otvorenim tržišnim natjecanjem i gdje je kvalitetna i točna informacija u pravo vrijeme ključan segment održavanja koraka s konkurencijom.

Poslovna inteligencija je skup metodologija, procesa, arhitekture i tehnologije, koje transformiraju sirove podatke u smislene i korisne informacije, koje omogućavaju efektivnije strateške, taktičke i operativne uvide i bolje odlučivanje.²⁰

Ne postoji dogovorena definicija poslovne inteligencije pa ju autori različito interpretiraju. Upravo je inteligencija ono što podiže prikupljene informacije u nekoj organizaciji na višu razinu. Inteligencija proizlazi iz razumijevanja informacija, ranije poduzetih akcija i postojećih mogućnosti odnosno otvorenih opcija. Jednom utemeljena inteligencija se sama širi organizacijom. Kritična masa pojedinaca koji imaju dobar uvidi dijele slične stavove o poslovnim procesima postaje u takvim uvjetima vrlo moćna snaga. Pokušavajući uključiti sve bitne aspekte Bilandžić je sintetizirao definiciju poslovne inteligencije na slijedeći način: „To

¹⁹ „Payback on Business Intelligence", dostupno na: <http://www.dmreview.com/>, 01/2003. (27.08.2019.)

²⁰ Business Intelligence, dostupno na: <https://www.forrester.com/Business-Intelligence#> (27.08.2019.)

je poslovno-obavještajna/izvještajna aktivnost u poslovnom svijetu koju planiraju, organiziraju i provode poslovni subjekti, pri čemu je riječ o procesu legalnog prikupljanja javnih i svima dostupnih podataka etičkim sredstvima, pretvaranju podataka u gotove poslovno-obavještajne analize („znanje“) radi pružanja potpore čelništvu poslovnog subjekta pri donošenju i realizaciji što kvalitetnijih poslovnih odluka za očuvanje pozicije u poslovnom okruženju, izbjegavanje bilo kakvih prijetnji i u konačnici za ukupan kvalitativni napredak“.²¹

Da bi tvrtka preživjela na današnjem turbulentnom tržištu potrebno je doći do informacije koja omogućuje poduzimanje odgovarajuće akcije. Ta činjenica vrijedi za sve industrije i sve grane gospodarstva.²²

U današnje vrijeme svijet je povezan i integriran procesima globalizacije i suvremenih telekomunikacija više nego ikad prije i to je prilika da se manje države u velikoj mjeri povežu sa najrazvijenijim i usvoje procese i tokove koji će dovesti do bržeg razvoja na svim područjima u državi (gospodarstvo, komunikacije, turizam).

Što je društvo kompleksnije, to ima veće obavještajne potrebe. Na taj način svaki sektor društva postaje dostupan i transparentan. Kompanijama više nije kapital primarni čimbenik poslovnog uspjeha, već su za kontinuirano postizanje dobrih rezultata sve važnije informacije te visokokvalificirani i motivirani suradnici koji će znati selektirati važne od nevažnih informacija. Jedino obrazovani zaposlenici mogu rješavati probleme unutarnjeg i vanjskog usklađivanja i tražiti metode i tehnike rješavanja problema i prevladavanja kriza.²³ Stvaranje „organizacije koja misli“ zapravo je stvaranje inteligentne kompanije. Takva kompanija će brže od konkurenata donositi mudrije odluke te tako biti u prednosti na tržištu. Poslovna inteligencija omogućuje stvaranje takve organizirane i napredne kompanije.

Bilandžić navodi tri najznačajnije kategorije podataka koje je potrebno prikupljati: podatke o okruženju (politička i gospodarska situacija, razina sigurnosti, pravna regulacija itd.), podatke koji se odnose na tržište (kretanja na domaćem, regionalnom i globalnom tržištu, kako i gdje plasirati proizvode i usluge, kako zadržati stare i pridobiti nove potrošače itd.) i podatke koji se odnose na konkurenciju (poslovna strategija konkurenata, koji su njihovi novi proizvodi i usluge, koje su cijene tih proizvoda, kadrovska struktura itd.).

²¹ Bilandžić, M., Čulig, B., Lucić, D. Putar-Novoselec, M., Jakšić, J.: Business intelligence u hrvatskom gospodarstvu, Poslovna Izvršnost, Zagreb, 2012.

²² Željko Panian, Goran Klepac, Poslovna inteligencija, Masmedia Zagreb, 2003.

²³ Rupčić, N. (2002). 'PODUZEĆE KOJE UČI - FORMULA ZA 21. STOLJEĆE', Ekonomski pregled, dostupno na: <https://hrcak.srce.hr/28384> (27.08.2019.)

Kada govorimo o analizi potrebno je naglasiti da je poslovna i kompetitivna analiza ključna komponenta operativnog, taktičkog i strateškog odlučivanja te posljedično tome ostvarivanja konkurentске prednosti. Ako je dobro odrađena analiza i njen proizvod pomoći će organizaciji da što više smanji rizike, a poveća mogućnosti koje postoje u njenom okruženju. Zbog toga tvrtke koje ne posjeduju analitičke sposobnosti vjerovatno će propustiti profitabilne prilike i biti podložne napadima konkurenata.²⁴

3.2. Ciljevi i koristi primjene sustava poslovne inteligencije

Korijeni koncepta poslovne inteligencije prakticira se već tisućljećima u različitim domenama društvenog života. 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). Literatura iz područja poslovne inteligencije prepuna je citata iz zaostavštine drevnih ratnika. Najčešće se koriste citati T'ai Kunga, Hannibala, te Fridriha Velikog. Povijesne začetke znanstvenog pristupa poslovnoj inteligenciji moguće je naći u filozofskim studijama ili esejima Sun Tzu-a (300.-ta godina prije nove ere), Nicole Machiavellia (15. stoljeće) te Francisa Bacona (19. st). Neka novija istraživanja ukazuju i na postojanje koncepta poslovne inteligencije u Dubrovačkoj Republici s početka 18. st. Konceptualni model preuzet iz ovih radova koji počiva na informiranom snalaženju u novim prostorima, te raspoloživosti tzv. «prethodnog saznanja», s vremenom se nije puno promijenio.²⁵ Koncept se zasniva na ciljanom, svrhovitom i svjesnom prikupljanju podataka, njihovom vrednovanju i povezivanju u informacijske blokove koji se mogu višekratno i višenamjenski prostorno oblikovati i koristiti za različite projekcije ili izvješća. Ono što se promijenilo su korisnici i intenzitet te ciljevi korištenja ovog koncepta. Prvi korisnici strateških saznanja bili su vojskovođe i vladari, srednjovjekovni krug korisnika obuhvaćao je često i bankare (Dubrovačka Republika, poduzetnička augsburška obitelj Fugger, Rotschild, švedski bankar Walenberg), dok se krug suvremenih korisnika nezaustavljivo širi među populacijom suvremenih poslovnih ratnika i vladara – menadžera. Izvješća su nekada bila podređena ciljevima dobivanja bitke ili rata, dok su danas podređena ostvarivanju konkurentске prednosti

²⁴ Kopal R., Korkut D., TEORIJA IGARA Praktična primjena u poslovanju, Društvena istraživanja, Zagreb, 2012.

²⁵ Pfeifer, S., Alpeza, M.: Business Intelligence, Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet u Osijeku, Osijek, 2011.

ili kompetentnosti. Slično bojnopolju, suvremeni je poslovni svijet, polje nadmetanja brojnih konkurenata za prestiž. Poslovna inteligencija čini se postaje najnovije oružje u poslovnom ratovanju. Uporabom znanja, prije nego li oružja, Japan je postao ilustrativan primjer zemlje koja je mirnim putem zagospodarila globalnim tržištem elektroničke opreme. Suvremena uporaba termina inteligencija nastoji odvojiti vojnu od tzv. civilne inteligencije. Polje civilne inteligencije progresivno raste sukladno narastanju kompleksnosti domena civilnog društva.²⁶ Tako se u novije vrijeme razvijaju uz opću poslovnu (business intelligence) i čitav niz specijalističkih inteligencija poput: konkurentske, tehnološke, znanstvene, te gospodarske inteligencije. Civilna inteligencija inzistira na otvorenosti, javnosti, etičnosti i legitimnosti, dok se vojna profilira kao tajnovita i netransparentna. Ipak teško je povući jasnu granicu između metoda vojne ili civilne inteligencije. Vojnoobavještajne službe često ne kriju svoju ulogu u prikupljanju informacija namijenjenih velikim poslovnim sustavima koji planiraju ulazak u poslovnu suradnju sa stranim partnerom. S druge strane, ovakva praksa nije karakteristična za mnogobrojna mala i srednje velika poduzeća koja prihvaćanjem koncepta poslovne inteligencije dobivaju tehniku kreiranja i održavanja konkurentske sposobnosti. Koncept poslovne inteligencije se razvija u okvirima upravljačke paradigme, a snažan porast digitalizacije svakodnevnog života uvjetuje sve veće povezivanje koncepta poslovne inteligencije sa konceptom poslovnih informacijskih sustava i telekomunikacijske tehnologije. Klasični poslovni informacijski sustavi sve teže hvataju korak sa brojnošću i ažurnošću podatkovnih baza koje koriste. Intenziviranje broja konkurenata, dinamike i oštine konkurentske borbe, kao i skraćivanje vremena ostavljenog za reakciju poduzeća na podražaje zahtijeva preispitivanje uloge i efekata tradicionalnih informacijskih sustava. Alternative idu od redizajniranja i restrukturiranja do outsourcinga. Konkurentska prednost sve se teže stvara rutinskim i repetitivnim istraživanjem tržišta. Istinsko znanje zahtijeva visoke razine kreativnosti u prikupljanju i analiziranju podataka, te korištenju informacija i intelligencea. Koncept poslovne inteligencije orijentiran je aktivnoj potrazi, vrednovanju i transformaciji sitnih i široko disperziranih dijelica znanja prisutnih u poslovnoj okolini, u svrhu iskorištavanja poslovne prilike ili izbjegavanja krize. Njegovo je ishodište ipak određena strateška vizija te identifikacija strateških ciljeva i potreba za poslovnom inteligencijom.²⁷

²⁶ Pfeifer, S., Alpeza, M.: Business Intelligence, Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet u Osijeku, Osijek, 2011.

²⁷ Pfeifer, S., Alpeza, M.: Business Intelligence, Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet u Osijeku, Osijek, 2011.

U današnje doba sve veći broj zaposlenika koristi u poslu informacijske sadržaje. Menadžeri svakodnevno trebaju i koriste važne relevantne informacije za ostvarivanje poslovnih ciljeva. Ključni problemi djelatnika vezani su za sposobnost analize brojnih i fragmentiranih podataka, brzinu usvajanja znanja i njegovu primjenu u praksi.

Ciljevi i zadaci analize podataka su relativno jednostavni te obuhvaćaju podršku informiranom upravljanju, legitimizaciju odluka te smanjenje rizika i neizvjesnosti.

Istraživanja i analize velikih količina podataka, uporabom odgovarajućih tehnika i metoda, mogu u organizaciji dijagnosticirati ključne procese, identificirati i anticipirati smjer promjena, interpretirati financijske rezultate, klasificirati i klasterirati podatke, oblikovati model ponašanja sustava, agregirani podaci, detektirati promjene i devijacije u odonosu na ciljeve, odrediti korelaciju među varijablama, generirati asocijativna pravila.²⁸

Osnovna zamisao sustava poslovne inteligencije je korištenje operativnih podataka u cilju dobivanja novih korisnih informacija koje će pomoći pri donošenju ispravnih i efikasnih poslovnih odluka. Glavna značajka ovog sustava je da on analizom informacija uz pomoć cjelovitog sustava upita i izvještavanja (pomoću Q&R alata) i s jedinstvenim pogledom na tvrtku pomaže boljem razumijevanju poslovnih događaja. Uz pomoć alata poslovne inteligencije smanjeno je vrijeme izrade izvještaja, a povećano je vrijeme raspoloživo za analizu podataka. Isto tako ovaj koncept omogućuje praćenje dostignuća tvrtke u realnom vremenu, pa je informacija dostupna onog momenta kad je potrebno. Time je skraćeno vrijeme za donošenje operativnih i strateških odluka s tjedan - dva na donošenje odluka na dnevnoj razini. Očekivanja od sustava poslovne inteligencije vežu se uz gotovo sva područja, za upravljanje važnim procesima unutar tvrtke poput praćenja proizvodnje i prodaje, upravljanja dobavljanjem sirovina i materijala, financijskog odlučivanja i upravljanja općenito. Tako se očekuje njegov pozitivni utjecaj na marketing, na uvođenje novih proizvoda, bolje fokusiranje na kupca, povećanje konkurentske prednosti te rast prihoda i smanjenje troškova, razvoj investicija, razvoj zaposlenih itd.

²⁸ Bijakšić, S., Markić, B., i Bevanda, A. 'BUSINESS INTELLIGENCE AND ANALYSIS OF SELLING IN RETAIL', Informatologia, 2014., dostupno na: <https://hrcak.srce.hr/133658> (27.08.2019.)

Pet je osnovnih kategorija potencijalnih koristi od primjene poslovne inteligencije u funkciji potpore poslovnom odlučivanju:²⁹

- Povećanje prihoda
- Povećanje dobiti
- Unaprjeđenje zadovoljstva klijenata
- Uštede
- Povećanje tržišnog udjela

Kao i sve drugo tako i poslovna inteligencija ima svoje bolje i lošije strane. Sustavi poslovne inteligencije donose znatna poboljšanja sami po sebi u bilo kakvom okružju ili situaciji. Naravno da bi uspješno implementirali sustav potrebno je odraditi određene predradnje od osiguranja financijskih resursa, pa sve do obuke adekvatnih zaposlenika koji bi znali koristiti sustav. U današnjem poslovnom svijetu možemo reći da, ne samo da je poslovna inteligencija dobro zastupljena, nego je neophodna za uspješno poslovanje.

Podrazumijeva se da se poslovna inteligencija sastoji od skupa procesa i alata koji pomažu poduzeću odnosno višim menadžerima, kojima je funkcija donošenje odluka, u poboljšanju učinka samog poduzeća. Sustav poslovne inteligencije čine procesi za konvertiranje velike količine podataka koji uključuju DTS alate (alati za prenošenje i transformaciju podataka iz različitih izvora podataka), ETL procese (proces ekstrakcije, transformacije i punjenja), skladišta podataka, OLAP alate (alati koji će podatke oblikovati na način da budu pogodni za analizu i pretraživanje), rudarenje podataka, alate namijenjeni pretraživanju i dinamičkoj analizi, ali isto tako i kadar koji će poznavati poslovne procese.

John Veltkamp, voditelj odjela programiranja u Bank of Montreal, svojim primjerom ukazuje na veliku korist koju donosi upotreba poslovne inteligencije kroz analizu i sustave. On navodi da uz pomoć alata poslovne inteligencije oni poslovi koji su trajali tjednima sada se rješavaju u nekoliko sekundi. Sve situacije se analiziraju proaktivnije što je veliko postignuće. Visok povrat ulaganja vidi se na povećanju produktivnosti zaposlenika. Softver je banci uštedio stotine radnih sati i omogućio kvalitetno i precizno obavljanje poslova.

²⁹ Tomaš A., POSLOVNA INTELIGENCIJA -oblikovanje OLAP kocke na primjeru, SVEUČILIŠTE U SPLITU EKONOMSKI FAKULTET, 2014.

U mnogobrojnim uspješnim kompanijama, kao i u svijetu, važnost koncepta poslovne inteligencije odavno je prepoznat. Većina visokorazvijenih i ekonomski stabilnih zemalja svijeta u svojoj poslovnoj praksi primjenjuje poslovnu inteligenciju.

3.3. Razlozi primjene sustava poslovne inteligencije

Promjenjiva okolina, razvoj informacijskih tehnologija, novi i zahtjevniji potrošači, veliki značaj informacija su samo neki od razloga zašto je koncept poslovne inteligencije postao gotovo nezaobilazna tema današnjice. Implementacijom sustava poslovne inteligencije i njegovih alata organizacije očekuju bolju prilagodbu tržišnim uvjetima, veću konkurentnost i posljedično poboljšanje rezultata temeljnih ekonomskih pokazatelja. Glavna prednost sustava poslovne inteligencije je pružanje mogućnosti tvrtkama da brzo pohranjuju podatke, pristupaju im te ih modeliraju, zatim analiziraju velike količine informacija dobivene iz vanjskih ili unutarnjih izvora. Osnovni razlog za uvođenje sustava poslovne inteligencije je taj što poduzeće mora znati svoje dobre i loše strane. Mora uvažavati ponašanje i želje kupaca.³⁰

Razlozi za uvođenje sustava poslovne inteligencije:³¹

- Okolina nije više statična. Ponuda proizvoda i usluga je ogromna, konkurencija je velika. Istraživanja pokazuju da danas ponuda roba i usluga barem 30% nadmašuje potražnju. Tržišta su zasićena. Nove okolnosti traže nova rješenja, novi izazovi nove napore. Prošla su vremena kada je bilo dovoljno proizvesti robu ili uslugu.
- Globalizacijom tržišta, razvojem distribucijskih kanala, “uplitanjem” interneta u svaku poru gospodarstva, stvari su se promijenile. Sada su kupac i prodavač na udaljenosti „jednog klika mišem“. Danas su poduzeća pretrpana podacima, dok s druge strane, postoji nedostatak korisnih informacija. Da bi se smanjio raskorak između količine raspoloživih podataka i informacija, potrebno je definirati procese prikupljanja

³⁰ Perković, C., L.: VAŽNOST SUSTAVA ZA POTPORU ODLUČIVANJU NA PRIMJERU UPORABE SUSTAVA POSLOVNE INTELIGENCIJE COGNOS U POSLOVANJU TVRTKE, SVEUČILIŠTE U RIJECI, EKONOMSKI FAKULTET U RIJECI, 2009.

³¹ „Što je poslovna inteligencija?“. Dostupno na: <https://www.datalab.ba/sta-je-poslovna-inteligencija/> (25.08.2019.)

podataka i njihovu “preradu” u informacije. Vrijeme reakcije na podražaje iz okoline potrebno je skratiti što je više moguće.

- Resursi su uvijek ograničeni. Vrijeme kao najvažniji čimbenik gotovo uvijek je presudno. Vrlo je važno kvalitetno djelovati i iskoristiti resurse u najvećoj mjeri.
- Dekompozicija lanca vrijednosti (nabava, skladištenje, proizvodnja, prodaja, postprodajne aktivnosti) omogućava pravilnu upotrebu efekta poluge. Osim toga ona nam omogućava pronalaženje fundamentalnih rješenja za postojeće probleme, a ne ublažavanje simptoma.
- Nalaženje novih kupaca je deset puta skuplje nego zadržavanje postojećih. Ako poduzeće uspije smanjiti odlazak kupaca konkurenciji za 5%, može udvostručiti svoju zaradu.
- Kupci (uz zaposlenike i njihovo znanje) predstavljaju najveću vrijednost koju poduzeće posjeduje. Kako ih zadržati? Stabilni odnosi s kupcima ključ su dugoročne uspješnosti poduzeća.
- Osiguranje i održavanje likvidnosti operativni je upravljački problem. Rješenja ovog problema izravno utječu na upravljanje poslovnim rezultatom. Da bi se ovladalo ovim operativnim problemima treba poznavati svoje kupce, dobavljače, procese i veze među njima.
- Da bi cijeli ciklus operativnog kontrolinga (prikupljanje podataka, planiranje, analiza i kontrola te upravljanje) u poduzeću funkcionirao, treba imati adekvatnu informacijsku infrastrukturu.

Portal business2community³² naveo je šest razloga zašto je važno da se ulaže u poslovnu inteligenciju.

³² <http://www.business2community.com/business-intelligence/business-intelligence-software-need-know-now-01188358#7vQWU7jmqJUrVdsT.97> {13.08.2019}

1. Lagan pristup podacima: ako je poslovna inteligencija smještena u oblaku, korisnici joj mogu pristupiti s bilo kojeg mjesta na svijetu i s bilo kojeg pametnog uređaja. Na taj način dobivaju obrađene željene podatke pravovremeno i relevantno. Inače u kompanijama pristup podacima ima isključivo IT odjel, što automatski isključuje ostale odjele. Korištenjem poslovne inteligencije podatke će lakše shvatiti svi kojima su namijenjeni.
2. Bez traženja: Nepotpuni i netočni podaci znače da ne vodite svoju kompaniju, nego se kockate s njom i njezinom budućnošću. Uz pomoć poslovne inteligencije podaci poput financijskih informacija, ciljane i ostvarene prodaje, produkcije i podataka o klijentima su vidljivi dijelovima kompanije kojima je to u određenom trenutku potrebno. To znači da nema besmislenog traženja i "kopanja" kada hitno morate donijeti točnu i relevantnu poslovnu odluku.
3. Brži odgovori na ključna pitanja: Koliko smo novaca zaradili jučer? Je li produktivnost tima bolja nego prošli tjedan? Preko kojih kanala klijenti najviše preferiraju komunicirati s kompanijom? Koja je vodeća marketinška platforma kompanije? Je li kampanja na društvenim mrežama uspješna? Odgovore na ova pitanja bi trebali imati u "malom prstu", jer se ona najčešće postavljaju na poslovnim sastancima. Kada ih naučite uz pomoć BI-a, vrijeme koje bi inače potrošili na traženje istih po tablicama i dokumentima možete uložiti u nove dogovore i partnerstva.
4. Bolja prodaja i uspješniji pregovori: eksplozija interneta stvari (Internet of Things - IoT) u 2015. je omogućila kompanijama da uz pomoć novih softverskih aplikacija stvore vlastiti IoT-a. Svi podaci koje kompanija posjeduje su tako povezani u točne informacije koje se pravovremeno mogu preuzeti, što kompaniji poboljšava odnose s klijentima, a na kraju i financijsku dobit.
5. Riješite se viška troškova: korištenjem BI softvera koji objedinjuje sve podatke kompanije nakon nekog vremena mogu vidjeti koji im podaci stvaraju troškove te ih smanjiti ili srezati (npr. upotreba službenih telefona vidljiva preko podataka s računa).

6. Nove poslovne prilike preko trendova, analiza i previđanja: BI sprema sve vrste podataka - od proizvoda koji se najviše prodaje do demografske strukture klijenata. Donositeljima odluka je zbog toga puno lakše odrediti snage i slabosti kompanije te područja na koja bi se trebali proširiti. To je omogućeno zbog alata "dataversity" unutar BI-a. Uz njegovu pomoć BI odabire više rješenja, iz kojih korisnici mogu izabrati ono trenutno najbolje za njih.

U današnjem društvu informacija postaje najvažniji resurs. Upravo zahvaljujući poslovnoj inteligenciji rukovodstvo tvrtke ima pristup točno onim informacijama koje im trebaju. Sustavi poslovne inteligencije omogućavaju proaktivan način vođenja poduzeća, što znači da se može predvidjeti budućnost, izraditi nekoliko scenarija i biti pripremljen za svaku situaciju. Najveći problem je kako pretvoriti informaciju u znanje. Danas se poduzeće vodi na osnovi znanja o konkurenciji, kupcima, dobavljačima, procesima. Slobodno se može reći kako je poslovna inteligencija proizvodnja znanja, koje je osnovica za donošenje poslovnih odluka.

Najvažnije prednosti korištenja sustava poslovne inteligencije su:³³

- Olakšava donošenje pravih poslovnih odluka.
- Jedinstvena struktura izvještavanja omogućava brže, fleksibilnije i učinkovitije odlučivanje te doprinosi poboljšanju poslovnih procesa.
- BI je nadogradnja osnovnog informacijskog sustava poduzeća.
- Analizom prikupljenih podataka moguće je na najbolji način iskoristiti prikupljene podatke i povećati zadovoljstvo svih korisnika, ali i klijenata.
- BI pruža korisnicima samo one informacije koje su im potrebne, ali zato pravovremeno i iskazane na način kako to njima najviše odgovara.
- Mjerenje koristi od uvođenja sustava. Jasne su koristi kada znamo gdje, kako i što mjeriti.
- Omogućavanje prilika za povećanjem vrijednosti. Informacije danas predstavljaju resurs odnosno vrijednost, kako za poduzeće tako i za ostale.

³³ Prednosti i nedostaci Poslovne inteligencije, dostupno na: <http://www.ebizmags.com/bi-10-vs-bi-20-nedostaci-i-prednosti/> (23.08.2019.)

Tablica 1: Prednosti i nedostaci poslovne inteligencije

BI nedostaci	BI 2.0 prednosti
Većina korisnika želi servirane informacije bez da samoinicijativno istraže koji je najbolji način da se dobiju potrebni odgovori.	BI pristup je suprotan ideji <i>Consumer Web</i> , jer se pokazuje da kad ljudi pronađu način da dođu do onoga što žele kada imaju jednostavno pomagalo koje može učiniti nešto važno ili korisno za njih.
Proizvođači uglavnom usporavaju razvoj jednostavnijih i jeftinijih pomagala da bi zadržali svoju bazu korisnika.	Većina BI korisnika pripada generaciji koja je odrasla uz tehnologiju i koji će odbaciti današnju BI funkcionalnost.
Samo pojedini poslovi trebaju podatke u stvarnom vremenu poput kontrole leta ili financijskog sektora	Dostupnost svježih podataka iz rastućeg broja izvora zahtijeva obradu u stvarnom vremenu.
Analitički postupci se ne mogu podržati dok ne postoji skladište podataka s repozitorijem metapodataka i sveobuhvatnim modelom podataka koji predstavlja „jednu verziju istine“.	„Razumijevanje“ podataka će do neke mjere zamijeniti skladište podataka, a jedna verzija istine će ustupiti mjesto kontekstu, kontigenciji i potrebi da se brzo povežu informacije iz mnogo izvora.
Ne mogu se slati analitički upiti operacijskom sustavu.	Ne postoji dobar razlog za ovu zabranu, te ona postaje besmislena s primjenom SOA-e.
Podaci moraju postojati u spremištu podataka za analitičke procedure.	Potrebno je iskoristiti sve izvore podataka (redove poruka, logove, senzore, privremena spremišta, ...).

Izvor: <http://www.ebizmags.com/bi-10-vs-bi-20-nedostaci-i-prednosti/> (20.08.2019.)

Nastavno na tablicu 1., najvažniji nedostaci su:

- Visoka cijena uvođenja sustava za koji većina malih i srednjih poduzeća nemaju kapital i ne mogu osigurati sredstva.
- Da bi poslovna inteligencija dala korisne rezultate treba dugi vremenski period. Iako su nam podaci već pristupačni, treba nam vremena za analizu, a sama analiza zahtijeva određeno vrijeme. Također je potrebno vrijeme da se dobivene informacije uz pomoć poslovne inteligencije sprovedu u djelo. Taj vremenski period u pojedinim situacijama

može biti predug, stoga to sve može biti beskorisno. Ponekad informacije koje se dobiju sa zakašnjenjem znaju biti nekorisne.

- Sustav poslovne inteligencije zahtijeva, da bi funkcionirao normalno, rad educiranog osoblja. Nedostatak adekvatnog osoblja za rad u takvom okruženju čest je u manjim poduzećima koja si to ne mogu priuštiti. Nekađ i pored dodatne edukacije osoblja, slučaj je da zaposlenici jednostavno nisu navikli na prednosti korištenja poslovne inteligencije. Zbog toga dobivene informacije ne mogu biti iskorištene u namijenjene svrhe jer ih nema tko koristiti.

Sustavi poslovne inteligencije mogu poslovodstvu tvrtke uvelike pomoći upravljati tvrtkom, ali nikada ne mogu zamijeniti čovjeka.

Svakom dijelu poduzeća serviraju se informacije koje su im potrebne. Tako se ne dovodi do prevelikog opterećenja i gomilanja informacija po odjelima, a koje nisu važne za taj odjel.

Svaki tim poslovne inteligencije trebao bi imati poslovnog eksperta (ključni korisnici) i tehničkog eksperta (IT). Oni se jednostavno moraju dogovoriti oko zajedničkih ciljeva i moraju se složiti oko definicije pozitivno završenog projekta. Komunikacijom preko funkcionalnih zahtjeva i tehničke specifikacije, prije i tijekom projekta poslovni ekspert treba definirati ciljeve, a IT ih izvršavati. Ukoliko niti ovaj zahtjev nije ispunjen, BI projekt neće uspjeti iz jednostavnog razloga što uspjeh nije niti bio definiran.

Mnoge IT tvrtke ne shvaćaju da je prava inteligencija unutar ljudskih bića, a ne unutar softvera i stoga se projekti moraju prilagoditi ljudskim bićima i njihovoj percepciji. Vizualizacija podataka je ugrađena u ljudski DNA i preko 70% receptora našega tijela je u očima. Bez ispravne vizualizacije i prezentacije podataka, korisnici će zapeti na golim podacima i trošit će sate pokušavajući ih razumjeti; ili još gore, bit će im prezentirane loše vizualizacije koje navode na krive zaključke.³⁴

³⁴ <http://www.skladistenje.com/lose-vizualizacije-zasto-bi-projekti-propadaju/> (13.08.2019.)

Važnost potpore i utemeljenosti poslovne inteligencije na razini države očituje se na primjeru Francuske. Obilježja poslovne inteligencije u Francuskoj su sveprisutnost vladinih institucija, fokus na malim i srednjim poduzećima, naglasak na protuobavještajnom djelovanju (zaštiti informacija), te predstavljanje poslovne inteligencije kao pokreta od nacionalnog značaja. Osnovni ciljevi upravljanja poslovnim informacijama su: poticanje razvoja poslovne inteligencije na razini kompanija, što lakši i jednostavniji prijenos informacija između privatnog i javnog sektora, izgradnja baza podataka utemeljenih na potrebama korisnika te obrazovanje potrebnog kadra. U skladu s tim veći broj škola i sveučilišta u Francuskoj nudi programe obrazovanja.

Među brojnim primjerima zemalja koje su uspješno primjenile poslovnu iteligenciju je i Finska. Implementacija sustava upravljanja poslovnim informacija najprije je započela u tvrtkama iz područja telekomunikacija da bi se ubrzo taj sustav uvodio i u druga područja industrije. Ono što je bitno odredilo kretanja u finskom društvu, a što je ujedno i prethodilo kreiranju poslovne inteligencije, jest nepovoljna gospodarska i opća društvena situacija u zemlji nakon 1990-ih na koju je utjecao dugogodišnji odnos sa Sovjetskim Savezom te posebice propast istočnog bloka. Finski oporavak započeo je 1994. godine kada su stvoreni preduvjeti za sustavno bavljenje poslovnom inteligencijom. Drugi faktor koji je utjecao na razvoj sustava upravljanja poslovnim informacijama u Finskoj je ulazak u Europsku uniju. Od 1995. godine Finska se kao punopravna članica EU našla u situaciji u kojoj je novo tržište na kojemu je trebala nastupiti višestruko veće od onog nacionalnog kojega je sačinjavalo svega 5 milijuna ljudi, ali što je još važnije to tržište nije bilo dovoljno istraženo. Finski primjer posebno je zanimljiv za Hrvatsku. Obje države imaju sličnu veličinu teritorija i broj stanovnika. Upravo bi nas finški recept trebao nadahnuti i ukazati nam na sve mogućnosti i prednosti koje nam poslovna inteligencija može donijeti.

3.4. Uvođenje sustava poslovne inteligencije

Jedan od najrazvikanijih poslovnih koncepata u posljednje vrijeme je poslovna inteligencija, tj. tendencija tvrtki da izgrade svoj sustav poslovnog i izvješćivanja kako bi imale cjelovitu sliku

o tržištu, kupcima i konkurentima, dakle o svim eksternim faktorima koji utječu na poslovanje poduzeća.³⁵

Kreiranje strategije poslovne inteligencije podrazumijeva nekoliko osnovnih koraka. Prvi korak je dobivanje formalnog zahtjeva od uprave da se strategija definira. Bilo kakva strategija bez potpore s vrha neće se moći uspješno implementirati. Nakon toga potrebno je snimiti trenutno stanje te popisati sve izvještajne procese, tehnologije, alate, troškove, licence, korisnike i načine upravljanja podacima koji trenutno egzistiraju u tvrtki. Sljedeći korak je definiranje ciljeva strategije gdje je važno da se detaljno opiše gdje se poslovna inteligencija kao funkcija nalazi u organizacijskoj strukturi, uloge, način upravljanja sustavom i podacima, arhitekturu sustava te kako poslovanje inteligencija podržava sveukupno poslovanje tvrtke.

Implementacijom strategije poslovne inteligencije osigurat će se da buduće rješenje bude usklađeno s poslovnim ciljevima tvrtke te da uspješno odgovori na sve poslovne zahtjeve koje pred sustav stavlja poslovanje.³⁶

Pet je ključnih koraka uvođenja novog sustava poslovne inteligencije:

- a) Priprema - Tijekom ove prve faze, potrebno je stvoriti preduvjete za početak implementacije. Bez kvalitetne pripreme može doći do prekoračenja budžeta ili rokova potrebnih za dovršenje implementacije. U pripremnoj fazi je potrebno održati sastanak na kojem će se zaposlenicima predstaviti plan projekta. Pomno osmišljen projektni plan je ključ uspješne implementacije. On se treba sastojati od preddefiniranih ciljeva, terminskog plana i popisa odgovornosti za svakog zaposlenika. Svaki zaposlenik bi trebao biti upoznat s planom te znati što će se od njega očekivati tijekom implementacije.
- b) Snimka stanja - Svaka tipična implementacija počinje snimkom stanja. Snimka stanja podrazumijeva analizu trenutnih poslovnih procesa tvrtke. Tijekom ovog procesa, konzultanti dokumentiraju poslovne procese kako bi dobili uvid u način rada tvrtke. Kroz razgovor s ključnim korisnicima, utvrđuju se razlozi zbog kojih se prelazi na novi softver i prema tim saznanjima se prilagođava novi softver. Konzultanti također prikupljaju osnovne podatke o firmi, broju odjela i zaposlenih itd. Tijekom snimke

³⁵ Srića V., Muller J., Put k elektroničkom poslovanju, Sinergija, Zagreb, 2001.

³⁶ <http://blog.king-ict.hr/ivan-tepes/kako-lansirati-bi-projekt-7-savjeta-za-uspjesnu-implementaciju>

stanja, također se definira projektni tim koji će zajedno sa stručnim timom konzultanata raditi na implementaciji. Određuje se voditelj projekta koji će nadgledati i upravljati procesom od početka do kraja implementacije te sve ostale osobe koje će sudjelovati u projektu. Bitno je definirati koliko će zaposlenih raditi u novom softveru, što će točno raditi te koje module će koristiti. Zatim, treba odrediti koji podatci će se uvoziti u novi softver te hoćete li ih uvesti sami ili ćete to prepustiti konzultantima. Ovo je ujedno i prilika da se suvišni podatci „počiste“ prije unošenja u novu bazu. Prije prelaska na sljedeći korak, potrebno je još dogovoriti edukaciju i odrediti datum početka rada u sustavu.

- c) Instalacija i podešavanje poslovnih procesa - Nakon prikupljenih svih potrebnih informacija, potrebno je instalirati novi sustav i podesiti sve poslovne procese. Namješta se baza podataka i uvoze se podatci prema dogovoru tijekom snimke stanja. Osim toga, konzultanti tijekom ove faze postavljaju korisničke račune i lozinke te podešavaju autorizacije za svakog korisnika. Na kraju ove faze, konzultanti bi trebali testirati bazu podataka i provjeriti jesu li svi podatci točni te funkcionira li sve pravilno. Također, konzultanti korisnicima mogu postaviti testnu bazu. Ona se može koristiti za vježbanje prije nego sustav počnu koristiti za svakodnevno poslovanje. Testiranje je najdosadniji i najteži svakog projekta. Kod projekata poslovne inteligencije još je važnije staviti imperativ na testiranje jer o točnosti podataka direktno ovisi uspješnost projekta. Većina nečistih podataka u ovoj će fazi se otkriti. Najčešće se u tom slučaju primjenjuju različite metode automatskog pročišćavanja podataka. Svi članovi tima trebaju testirati rješenje, svatko u svojoj domeni odgovornosti te taj posao treba odraditi s posebnom pažnjom. Ovakvim pristupom kod korisnika osigurava se povjerenje u podatke.
- d) Edukacija - Edukacija zaposlenika je vjerojatno i najvažniji dio implementacije sustava. Kvalitetno provedena edukacija osigurat će uspješno rukovanje novim sustavom i smanjiti probleme pri uporabi. Važno je da se zaposlenici u potpunosti posvete svladavanju korištenja novog softvera. Na kraju, to je bitno za njihov svakodnevni rad. Zaposlenici neće „pohvatati“ sve detalje rukovanja novim sustavom tijekom edukacije i sigurno će tijekom daljnjeg rada imati pitanja za konzultante. Stoga je pri odabiru sustava poslovne inteligencije vrlo bitno obratiti pozornost na kvalitetu korisničke podrške koju nudi tvrtka za implementaciju novog sustava. Što je podrška kvalitetnija, zaposlenicima će biti lakše savladati funkcionalnosti novog sustava.

- e) Primjena novog softvera - Nakon uspješne implementacije i testiranja sustava, vrijeme je da korisnici počnu koristiti novi sustav u svakodnevnom poslovanju. No, ovdje posao ne završava, jer je tijekom korištenja sustava potrebno kontinuirano pratiti njegovo funkcioniranje. Program je potrebno redovito održavati i ažurirati kako bi pravilno funkcionirao te kako bi njegovi korisnici mogli neometano raditi. Ovdje ključnu ulogu ima management. Oni trebaju pratiti korištenje novog sustava i reagirati na eventualne probleme tijekom uporabe. Implementacija sustava poslovne inteligencije je veliki pothvat, ali uz pravilno planiranje i provedbu ne bi trebala predstavljati nikakav problem. Uz odgovoran i ozbiljan pristup, implementacija sustava donijet će mnoge benefite uključujući veću produktivnost, bolju organiziranost i konkurentnost na tržištu. Osim toga, značajno će pojednostaviti poslovanje jer neće biti potrebe za unošenjem podataka u više različitih programa.³⁷

Sam proces realizacije sustava poslovne inteligencije može se podijeliti u 4 koraka:

- a) Izgradnja inteligencije profila tvrtke – određivanje što zapravo želimo znati o okolini kako bismo mogli kvalitetnije upravljati tvrtkom, te identifikacija izvora potrebnih podataka. Pri tome se kod izvora podataka moguće opredijeliti za specijalizirane tvrtke kojima je djelatnost upravo pružanje ovakvih usluga (što je vjerojatno pogodnije za razvijenija tržišta) ili se tvrtke mogu odlučiti za izgradnju vlastitih – izravnih veza s izvorima podataka.
- b) Postići da informacije (definirane u prvom koraku) „teku k vama“, te izgaditi, kupiti ili rabiti postojeći modul (engl. Search engine) za pretraživanje informacija koji može služiti kao potpora za postavljanje ženjenih upita. Dobivene je informacije jednako tako poželjno integrirati u postojeće interne poslovne informacije (primjerice, u za to predviđeno skladište podataka – DW: engl. Data warehouse), kako bismo imali cjelovit uvid u poslovanje tvrtke.
- c) Pretvaranje informacija u inteligenciju, tj. identifikacija i analiza relevantnosti dobivenih informacija za poslovanje tvrtke. Potrebno je uspostaviti sustav koji među

³⁷ 5 ključnih koraka za implementaciju, dostupno na: [https://www.datalab.hr/blog/5-kljucnih-koraka-
implementacija](https://www.datalab.hr/blog/5-kljucnih-koraka-implementacija), (25.08.2019.)

informacijama o poslovnom okruženju utvrđuje koje su relevantne i na koji način za poslovanje dotične tvrtke.

- d) Na temelju identificiranih relevantnih informacija, poduzimanje odgovarajućih poslovnih poteza/koraka, kao odgovor na stanje poslovne okoline. Preduvjet za poduzimanje odgovarajućih poslovnih akcija je, dakako, stanje odgovarajućih izvješća relevantnim pojedincima koji imaju utjecaja na donošenje poslovnih odluka o dotičnoj akciji. Sustav poslovne inteligencije tvrtke tako podrazumijeva i produkciju poslovnih akcija, kao posljedicu dobivenih informacija, bez kojih bi smisao cjelokupnog sustava poslovne inteligencije bio upitan.³⁸

³⁸ Srića V. , Muller J., Put k elektroničkom poslovanju, Sinergija, Zagreb, 2001.

4. Uvođenje novog sustava poslovne inteligencije u proizvodno poduzeće

4.1. Prikaz problema prije uvođenja novog sustava poslovne inteligencije

Prostoria d.o.o. poduzeće je nastalo 2011.godine i od tada kontinuirano raste. Osnovna djelatnost poduzeća je proizvodnja ojaštuenog namještaja. Proizvodna poduzeća imaju složen poslovni proces sa velikom suradnjom odjela proizvodnje, prodaje, nabave te financija i računovodstava. Poduzeće Prostoria d.o.o. zbog povećanog obujma posla i kontinuiranog rasta proizvodnje te broja zaposlenih posebice u administraciji poduzeća, uvidjelo je da postojeći sustav ne zadovoljava njihove potrebe. Najveći problem postojećeg sustava je bio ogroman utrošak vremena za dobivanje raznih izvještaja za potrebe uprave te planiranja proizvodnje. Isto tako, puno operacija zahtjevalo je puno vremena budući da su pojedine operacije korištene u svakodnevnom poslovanju trebale biti odrađene ručnim unosom podataka. Svaki radni nalog se ručno unosio te je uz utrošak vremena postojala i velika mogućnost ljudske greške pri unosu (unešen krivi datum, kriva stavka, kriva količina, krivi kupac). Printanje radnih naloga koji su išli u proces proizvodnje bio je omogućen samo pojedinačno, i tu se također gubilo jako puno vremena.

Proces planiranja proizvodnje odvijao se nakon ručnog otvaranja radnih naloga, nakon čega su se pojavile potrebe za izradom proizvoda. Izvještaj za potrebe planiranja proizvodnje imao je jednu formu, a bio je sastavljen od popisa gotovih proizvoda koje je potrebno proizvesti u određenom sljedećem periodu te popisa poluproizvoda potrebnih da se proizvedu svi gotovi proizvodi. Izvještaj se izrađivao na tjednoj bazi i problem je nastao što su sve stavke sa izvještaja trebale biti završene u određenom tjednu, a ne prema danima u tjednu (postojala je mogućnost da se određena roba ne napravi na vrijeme ukoliko mora biti završena početkom tjedna). Navedeni problem se rješavao dodatnim pretraživanjem, a to je zahtjevalo dodatno vrijeme. Postojeći sustav nije podržavao mogućnost uparivanja radnih naloga poluproizvoda sa radnim nalogima gotovih proizvoda. U slučaju reklamacija na isporučenu robu, vremenski je dugo trajalo dok se nije utvrdilo kada je određeni proizvod napravljen, te koji je djelatnik radio na njemu.

Narudžbe koje je odjel nabave svakodnevno izrađivao također su nastajale na način da su se ručno unosile stavke te količine, kao i partner/dobavljač kojemu se narudžba šalje. Narudžbe

su se pohranjivale na lokalni disk te onda slale putem e-maila, što je još jedan dodatni korak budući da sustav ne omogućuje slanje narudžbe u pdf formatu direktno putem e-maila. Provjera izrađenih primki skladišta za naručenu i isporučenu robu te izrada kalkulacija, u kojima su se provjeravale pristigle količine sa naručenim, kao i cijene sa računa trajala je jako dugo jer su se cijene unosile ručno. Posebice je problem bio sa primkama koje su imale više desetaka stavki, jer je izrada kalkulacije trajala više sati. Također, sustav nije podržavao mogućnost unosa cjenika. Cjenik unešen u sustav omogućava veliku uštedu vremena budući da su se u kalkulaciju morale ručno unositi cijene. Odjel financija i računovodstva žalio se na nepregledne izvještaje, koji su rastom poduzeća postajali sve veći, složeniji i zahtjevniji za izradu. Probleme im je stvaralo nemogućnost praćenja proizvodnje te uskoda sa računovodstvenim standardima i procedurama. Rastom broja zaposlenika nerazvijena kadrovska evidencija postojećeg sustava postajala je sve veći problem. Razvojem informacijskih tehnologija te prelaskom na slanje računa digitalnim putem, problem nemogućnosti unosa e-računa predstavljalo je dodatan gubitak vremena. E-računi su jednostavniji u usporedbi s dosadašnjim oblicima kreiranja i slanja računa putem pošte koji su zahtijevali brojne korake prije nego što bi račun došao u ruke klijenta. Sustav e-Računi prije svega štede vrijeme računovođama olakšavajući im posao kreiranja i slanja računa te praćenja njihove naplate. Također, generiranje e-Računa omogućuje kreiranje više e-Računa odjednom kao i njihovo slanje. Osim toga, ovim načinom bitno se smanjuje korištenje papira čime štedimo prirodne resurse i pomažemo kod očuvanja okoliša.

Navedeni problemi sažeti su u zasebni izvještaj te su kao najbitnije točke rasprave o novom sustavu prezentirane potencijalnim partnerima u procesu istraživanja i izbora novog sustava. Tijekom cijelog procesa, svaki odjel poduzeća imao je svoje probleme i novitete koje su htjeli da im novi sustav omogući i na taj način smanji količinu posla i vremenski utrošak.

4.2. Izbor i implementacija novog rješenja

Vodstvo tvrtke mora odlučiti kakve izvještaje želi imati i koje podatke ti izvještaji trebaju sadržavati. Netko mora unijeti te podatke u sustav, a oni se zatim transformiraju u željene izvještaje.

Vodstvo poduzeća uvijek je da je potrebno uvesti novi sustav poslovne inteligencije. Potreba za novim sustavom poslovne inteligencije dovela je do zaključka da je potrebno promijeniti postojeći ERP sustav.

Nakon nekoliko mjeseci istraživanja te konzultacija, odlučeno je da će novi pružatelj softvera biti informatička tvrtka Microlab d.o.o. iz Zagreba.

Informatička tvrtka Microlab d.o.o. postoji na hrvatskom tržištu od 1990. godine te se može smatrati začetnikom tehnologije osobnog računarstva i pioninom u izradi informacijsko - poslovnog sustava. Tvrtka se bavi projektiranjem, izrađivanjem i održavanjem cjelovitih informatičkih sustava i rješenja. Stručno znanje zaposlenika inženjera uključuje analizu poslovnih procesa, dizajniranje računalnih mreža i komunikacija, razvoj poslovne aplikativne programske podrške i multimedijских projekata. Svojim poslovanjem, inovacijama i unapređenjima vlastitog softverskog rješenja i proizvoda, Microlab kontinuirano stvara nove vrijednosti za korisnike svojih proizvoda i usluga, poslovne partnere i zaposlenike. Microlab-ovi renomirani klijenti, odabir vodećih tehnologija za izradu rješenja, učinkovita logistika, pouzdana tehnička podrška, brz i učinkovit servis, zadovoljni korisnici te motivirani i educirani zaposlenici temelj su dosadašnjeg, ali i budućeg rasta i razvoja.

Glavni proizvod tvrtke je ERP software DIGLAS.³⁹

DIGLAS ERP (Enterprise Resource Planning), integralni poslovno-informacijski sustav, jest poslovno, operativno i upravljačko rješenje dizajnirano za upotrebu u dinamičnim i rastućim poslovnim okruženjima.

Diglas uključuje i industrijski-specifične funkcionalnosti i najbolje poslovne prakse bazirane na dugogodišnjem microlab-ovom poslovnom iskustvu i iskustvu njegovih klijenata, što ga pozicionira među najkompletnija, najskalabilnija i najučinkovitija rješenja za cjelokupno upravljanje tvrtkom sa fleksibilnom i otvorenom tehnološkom platformom.

Potporna informacijskog sustava cjelokupnom poslovanju organizacije smatra se jednim od temeljnih preduvjeta uspješnosti poslovanja. *Diglas* poslužuje sve dijelove i funkcije organizacije, ali istovremeno zadovoljava informacijske potrebe organizacije u cjelini. Dodatno, kao softverska arhitektura temeljena na zajedničkoj bazi podataka i korisničkom

³⁹ http://www.microlab.hr/o_nama/ (16.08.2019.)

sučelju, osigurava nesmetani tok informacija između dijelova organizacije i omogućava cjelovit informacijski pogled na poslovni sustav. Temeljen na tehnologijama modernog vremena, *Diglas* pruža jednostavnost uporabe i robusnost primjerenu kompleksnim poslovnim sustavima.

Također, omogućava integralnu potporu ne samo redovnom poslovanju već i upravljanju, odlučivanju, komunikaciji i suradnji čime *Diglas ERP* u potpunosti zadovoljava kriterij suvremenog ERP sustava (ERM i ERPII) koji je usmjeren na uređenje svih unutarnjih procesa – uključujući i upravljanje, odlučivanje i komunikaciju, kao i na integraciju procesa s okruženjem – povezivanje s poslovnim partnerima zbog postizanja učinkovitosti u cijelom lancu dodatne vrijednosti, od dobavljača do krajnjega kupca, korisnika.⁴⁰

Softverski paket podijeljen je na 5 modula:

A) DIGLAS FINANCIJE

Diglas Financije modul namijenjen je za cjelokupno praćenje financijskog prometa tvrtke. Sve funkcije unutar modula financija prilagođene su zakonskim normama te se ovisno o promjenama redovito ažuriraju. Jednom uneseni podaci (ili preneseni iz drugih modula) automatski se raspoređuju u odgovarajuće evidencije – dnevnik glavne knjige, saldakonti, dnevnik računa i sl.

B) DIGLAS LOGISTIKA

Diglas Logistika cjelovito je rješenje za podršku procesima prodaje, nabave, skladištenja i transporta. Opseg i način korištenja svakog od modula kao i njihovih pojedinačnih funkcionalnosti parametrizacijom sustava prilagođavaju se poslovnim procesima i potrebama korisnika. Integralnost Diglas-a garantira raspoloživost informacija i podataka o provedenim poslovnim događajima na bilo kojoj lokaciji u realnom vremenu uključujući i financijske efekte istih u modulu Diglas Financije. Na ovaj način Diglas Logistika osigurava kvalitetno praćenje realizacije procesa po zadanim parametrima (tvrtka, poslovna jedinica, djelatnik, trgovačka marka, proizvod) kroz module Diglas BI Poslovno izvještavanje i Kontroling.

⁴⁰ <http://www.microlab.hr/diglas/> (25.08.2019.)

C) DIGLAS AUTOMOTIV

Diglas Automotiv cjelovito je rješenje za podršku procesima uvoza, prodaje i servisiranja vozila te izvještavanja prema uvozniku i/ili principalu. Centralni objekt u svakom poslovnom procesu je vozilo, a integralnost i skalabilnost Diglas-a osiguravaju izravne veze sa svim ostalim Diglas modulima i potpuno prilagođavanje poslovnim procesima korisnika kroz parametrizaciju.

D) DIGLAS PROIZVODNJA

Diglas Proizvodnja cjelovito je rješenje za praćenje procesa proizvodnje i kontrole kvalitete a namijenjena je svim proizvodnim tvrtkama neovisno o industrijskoj grani. Integralnost Diglas-a osigurat će potpunu povezanost s ostalim segmentima poslovanja poput nabave, skladištenja, prodaje i financija te na takav način stvoriti pretpostavke za optimalizaciju procesa i rezultata poslovanja tvrtke. U ovisnosti o potrebama korisnika moduli Proizvodnja i Kontrola kvalitete mogu se koristiti i neovisno jedan o drugome, a uz obvezno korištenje Diglas Skladišnog poslovanja.

E) DIGLAS BI

Diglas Business Intelligence (Diglas BI) je integrirana metodologija i tehnološko rješenje koje omogućava korištenje podataka iz skladišta podataka (Engl. Data Warehouse) i njihovo pretvaranje u informaciju potrebnu za donošenje poslovnih odluka.

U kontekstu Diglas poslovnog sustava, pojam „poslovna inteligencija“ (Engl. Business Intelligence) označava tehnološko rješenje za prikupljanje, analizu podataka i distribuciju informacija (u obliku izvještaja ili interaktivnih sučelja) kako bi korisnici mogli donositi poslovne odluke na temelju pravovremenih i prikladnih informacija, te da bi održali i učvrstili vlastitu kompetentnost na tržištu.

Poslovni model tvrtke diktirat će odabir najznačajnijih odjela/grupa poslovnih pokazatelja koje žele analizirati – onih koji će najviše utjecati na povećanje konkurentnosti tvrtke. Bez obzira o kojem se odjelu radi, analiza podataka uvijek pruža mogućnosti optimizacije poslovnih procesa, identifikaciju kritičnih točaka i kontrolu u provođenju/mjerenju učinkovitosti procesa.

Diglas BI čuva informacije i znanje o kupcima, dobavljačima, procesima i omogućava poslovno pregovaranje i brojčano argumentirani nastup prema kupcima i dobavljačima, kvalitetno

operativno planiranje, promatranje pojedinih tržišnih segmenata te predviđanje budućih pojava. Također, nudi bolje razumijevanje vlastitih kupaca i spoznaju što ih potiče na određeno ponašanje.

Diglas BI jednostavan je i intuitivan alat koji omogućava korisnicima samostalno formiranje dinamičkih izvještaja sukladno poslovnim potrebama. Alat omogućava potpunu personalizaciju izvještajnog sustava kroz pohranjivanje definicija pojedinih izvještaja koji se standardno koriste u organizaciji kao i formiranje ad-hoc izvještaja za posebne potrebe. Pristupnim pravima definira se mogućnost izrade, odnosno korištenja izvještaja od strane jednog ili više korisnika Diglas-a. Izvještajni sustav bazira se na kompleksnim tablicama podataka koje se pune kombinacijom podataka iz transakcijskih tablica, podataka proknjiženih u ostalim modulima Diglas-a odnosno, tablica matičnih podataka i definicija izvještaja. Punjenje tablica se u pravilu odvija automatskim noćnim procedurama. Ovakav način rada osigurava mogućnost pripreme izvještaja i usporedbe podataka, a bez utjecaja dnevnih transakcija na rezultate izvještavanja. Izvještajni sustav kao rezultat može prikazati rezultate u obliku tabličnog prikaza, PIVOT prikaza i CHART prikaza podatak. Svaki od stvorenih prikaza moguće je spremirati kao definiciju prikaza za buduće korištenje. Spremljene prikaze korisnici mogu međusobno dijeliti. Podržan je izvoz podataka u nekoliko elektroničkih formata PDF, XLSX, HTML, RTF.⁴¹

Diglas BI modul prema potrebi izvlači podatke iz baze koja svakodnevno raste i puni se novim podacima. Zbog količine podatak, korisnik zadaje parametre prema kojima sustav izvlači podatke iz dijelova baze podataka i na taj način smanjuje broj i količinu podataka za pretragu i izvještaj.

Nakon odluke da se investira u novi softver, bilo je potrebno odraditi sve pripreme radnje za prijelaz sa postojećeg sustava na novi. Pripreme su započele 12 mjeseci prije planiranog prelaska na novi softver – 1.siječanj 2019.godine.

Bez kvalitetne pripreme može doći do prekoračenja budžeta ili rokova potrebnih za dovršenje implementacije. U pripreмноj je fazi održan sastanak na kojem je zaposlenicima predstavljen plan projekta. Pomno osmišljen projektni plan ključ je uspješne implementacije. On se treba sastojati od preddefiniranih ciljeva, terminskog plana i popisa odgovornosti za svakog zaposlenika i/ili odjel. Svaki zaposlenik bi trebao biti upoznat s planom te znati što će se od njega očekivati tijekom implementacije.

⁴¹ http://www.microlab.hr/poslovna_rijesenja/

U tom periodu svaki odjel u poduzeću je imao svoje zadatke, datumski određene, koje je trebalo odraditi da priprema podataka bude što preciznija i točnija. Ti zadaci predstavljali su veliki izazov budući da proces proizvodnje, prodaje i nabave u tom periodu nije prestao. Često su organizirane radionice sa djelatnicima Microlaba na kojima se raspravljalo o problemima na koje sa nailazilo i tražila se kvalitetna rješenja za iste. Unos podataka bio je olakšan budući da je Diglas kompatibilan sa Microsoftovim Excelom i putem njega se vršio import podataka na test, a zatim i na produkciju. Dva puta mjesečno radilo se testiranje sustava na testu i primjedbe te problemi su bilježeni i slani u izvještajima Microlabu na doradu. Budući da se radi o kompleksnoj situaciji – proizvodnom poduzeću sa velikim brojem kupaca, dobavljača, vlastitih proizvoda i ogromnom broju repromaterijala, u početku teško je bilo sve povezati. Diglas kao sustav jako je automatiziran i sam odrađuje razne radnje, tj. korisnik treba samo zadati određenu akciju. Iz narudžbe kupcu generiraju se potrebe za proizvodnjom, iz kojih se otvaraju radni nalozi sa određenim datumima i stvaraju potrebe za repromaterijalom. U postojećem sustavu bilo je potrebno printati narudžbe kupaca, prema njima ručno otvarati radne naloge i unositi stavke, a tek onda su nastale potrebe za nabavu materijala. Na taj se način gubilo puno vremena, a i bila je veća mogućnost pogreške.

Prilikom priprema bilo je bitno da se podaci koji se pripreme budu točni i ažurni, budući da se cijeli novi sustav temelji na njima. Jednom kada su ti podaci bili pripremljeni, djelomično su se inportirali u sustav putem importa iz Excela.

Tijekom pripremnog razdoblja organizirane su edukacije za nove korisnike budući da se sa datumom 1.siječanj 2019. prelazi na novi sustav, a postojeći ostaje samo sa funkcijom pregleda i kao takav zadnju radnu godinu ima 2018.

U čestoj komunikaciji sa djelatnicima Microlaba, prezentirane su im želje i potrebe koje su bile glavni fokus poboljšanja novog sustava u odnosu na postojeći. Uz to, softver Diglas kao napredniji softver od postojećeg, sam je nudio rješenja koja postojeći sustav nije mogao generirati.

Tim zadužen za uspostavu i implementaciju Diglasa u posljednja dva tjedna 2018.godine radio je samo na završnim testiranjima i doradama koje su još bile potrebne.

Baze podataka kupaca, dobavljača i materijala, te stanja skladišta prenešena su u novi softver bez problema, budući da Diglas nudi pretragu i povezivanje podataka i po šifri artikla iz starog sustava (EAN kod). Problemi su postojali kod odjela financija i proizvodnje. Odjel financija i

djelatnici iz Microlaba brzo su riješili probleme, a voditelj tima za implementaciju sustava izrazio je nezadovoljstvo nastalom situacijom.

Najveći problem u proizvodnji bio je što tijekom procesa prijelaza na novi softver proizvodnja nije stajala. Uz to, postojeći softver i Diglas imaju drugačije funkcije i statuse koje je bilo potrebno dodatno uskladiti da se sve narudžbe unesu u novi sustav te generiraju potrebe za proizvodnjom.

Sljedeći problem je bio ljudski faktor, tj. kadar koji je koristio tadašnji sustav i koji se opirao novom sustavu. U ljudskoj je psihologiji opiranje promjenama, ali budući da se ovdje prelazilo na moderniji i suvremeniji softver, sa brojnim dodatnim mogućnostima i taj se problem riješio nakon dodatnih edukacija o korištenju sustava i njegovim mogućnostima.

4.3. Prednosti i koristi novog sustava poslovne inteligencije

Novi sustav jednostavan je za korištenje, te korisnicima nije potrebno puno edukacije za osnovni rad. Za složenije zadatke i izvještaje potrebno je više znanja i edukacije.

Diglas sustav, pa tako i modul poslovne inteligencije zasnivaju se na Microsoft i Oracle tehnologiji i kao takvi već u početku korištenja bliži su korisnicima. Isto tako, sve podatke iz sustava moguće je jednostavno formatirano prebaciti u bilo koji MS Office program za daljnje analize i ispis.

Sustav ima prilagođene procedure i sisteme zaštite koji osiguravaju integritet i sigurnost svih pohranjenih podataka na najvišem nivou te se tako postiže 100% pouzdan sustav. Baza podataka nadopunjuje se svakodnevno sa aktulnim podacima, ali ta se radnja odvija tijekom noći dok se sustav ne koristi, ili je minimalni broj korisnika.

Svi procesi koji se odvijaju u sustavu povezani su u jedinstvenu cjelinu s centralnom bazom podataka. Cjelovit integralni informacijski sustav omogućuje da se evidentiraju svi poslovni događaji i da se njihovi podaci mogu učinkovito koristiti i analizirati unutar čitave organizacije. Svaki poslovni proces, započet u bilo kojem dijelu Diglas sustava, prati se od početka do kraja.

Sučelje sustava jednostavno je za korištenje i ubrzava obuku djelatnika i novih korisnika. Navigacija je poznata jer se sučelje temelji na standardima operacijskih sustava Microsoft Windows.

Diglas kao sustav posjeduje veliki broj mogućih operacija, akcija i izvještaja. Korisnik sam odlučuje koje mu informacije trebaju i ima slobodu filtrirati samo pojedine. Možemo pregledavati stanje skladišta za pojedini proizvod, grupu proizvoda, na određeni datum ili u određenom vremenskom periodu, kretanje cijena kroz određeni period, prodaju prema kupcima, artiklima, vremenskom periodu. Isti izvještaji imaju opciju printa, eksporta u Microsoft Excel, Microsoft Word, Outlook. Izvještaju sa puno (nepotrebnih) informacija nepregledni su i nefunkcionalni.

Novi softver omogućuje otvaranje radnih naloga i stvaranje potreba za materijalima za potrebu na brz i jednostavan način.

Planiranje proizvodnje dobilo je jedan sasvim novi pogled sa ovim softverom, omogućen je sustavni pregled potreba proizvodnje. Isto tako, olakšano je odlučivanje o proizvodnji za redovite potrebe i za lager temeljeno na proizvodnji i prodaji u prijašnjim razdobljima.

Najbolji primjer korištenja je prikaz izvještaja stanja skladišta za određeni artikl na dan bilo koji dan iz prošlosti. Sustav u modulu Diglas BI omogućuje prikaz željenih podataka za određene artikle, ili grupe, ovisno o volji korisnika za svako prošlo razdoblje. Sustav iz baze podataka dohvaća samo onaj dio koji mu korisnik zada, budući da je u bazi ogroman broj podataka i na taj se način dolazi do strukturiranih i preglednih izvještaja koji su potrebni za analizu. Također omogućuje praćenje stanja robe na skladištu kroz određeno razdoblje, koje omogućuje lakšu odluku oko minimalnih, maksimalnih te optimalnih količina robe na skladištu. Diglas BI modul služi kao alat za izvlačenje svih izvještaja koje korisniku trebaju, a pogotovo financijskih za potrebe uprave poduzeća. Na temelju tih izvještaja donose se odluke o budućim financijskim investicijama te projekcije za buduća razdoblja. Također, omogućuje praćenje financijskih troškova poslovanja poduzeća te usporedbu sa prošlim razdobljima i predviđanja za buduća razdoblja. Korisnik zadaje sve parametre izvještaja, a sustav mu izrađuje izvještaj prema istima. Ukoliko je potrebno, izvještaj se može preuzeti na lokalni disk u obliku Microsoft Excel-a te se mogu raditi još dodatne radnje potrebne za završni izvještaj.

Nakon nekoliko mjeseci korištenja novog sustav, zaključak je da je sustav jako dobar, sa puno mogućnosti koje pruža korisniku. Svaki korisnik može sučelje svog ekrana prilagoditi tako da attribute podataka dodaje ili miče, mijenja mjesto na ispisu i slično.

Iako je proces uvođenja bio dugotrajan i mukotrpan te skup u financijskom pogledu, implementacija je bila potrebna i sustav jako dobro funkcionira. Bitno je naglasiti da uvelike sustav ovisi i o ljudskom faktoru, kako on pripremi sustav te kako je posložena organizacija unutar poduzeća.

5. Zaključak

Mnoge velike i srednje tvrtke aktivno pristupaju pojmu poslovne inteligencije, razvijaju i implementiraju takve sustave i koriste ih u svojem elektroničkom poslovanju. Tvrtke uspijevaju pretvarati informacije u poslovnu inteligenciju, poslovnu inteligenciju u organizacijsko znanje, a kolektivno organizacijsko znanje u povećani profit.

Pretpostavka bavljenja ozbiljnim poslom u 21. stoljeću je poslovna inteligencija. Koncept poslovne inteligencije je postupak pretvaranja informacija u znanje. Izvorno bio namijenjen donositeljima odluka, odnosno ljudima koji donose poslovne odluke, upravljačima u poduzećima, menadžerima. Međutim, u suvremenim poduzećima odlučuju svi. To znači da je informacija i znanje potrebno svima.

Poslovna inteligencija je aktivno kreiranje i korištenje znanja umjesto pasivnog konzumiranja informacija. Ona je primarno orijentiran sustavnoj potrazi za znanjem iskoristivim u svrhu ostvarenja organizacijskih ciljeva, a počiva na principima javnosti i legalnosti.

Razvijanje sustava poslovne inteligencije je frustrirajući, vremenski zahtjevan i mukotrpan posao. S druge strane, ne uspijevaju svi takvi projekti pa je potrebno biti oprezan tijekom procesa razvoja sustava. Takvi poslovi i takve stvari ne gube, već dobivaju na vrijednosti. Postavlja se pitanje cijene ovakvih sustava i troškova informacija. U 21. stoljeću, stoljeću informacija i znanja, cijena informacije jednaka je cijeni opstanka na tržištu. Stoga je uvođenje sustava za upravljanje poslovnim informacijama isplativa investicija. Kako konkurencija postaje agresivnija, okolina nestabilnija i budućnost neizvjesnija, zahtjevi pred sustavima analize i prognoze postaju složeniji. Poslovna inteligencija je u funkciji planiranja, tj. kratkoročnih poslovnih odluka, ali i u funkciji strategije. Podaci pretvoreni u informaciju omogućavaju nam stvaranje konkurentne prednosti u tržišnoj borbi. Informacija predstavlja moćno oružje u poslovnim pregovorima, argumentiranom nastupu i omogućava kvalitetno operativno planiranje. Moguće je analizirati ponašanje kupaca, dobavljača, promatrati pojedine tržišne segmente i predviđati buduće pojave.

Uvođenje sustava poslovne inteligencije u poslovanje proizvodnog poduzeća sam po sebi je dugotrajan, mukotrpan i skup proces. Iznimno je bitno da je priprema procesa uvođenja dobro i kvalitetno napravljena. Sustav će biti dobar ukoliko su informacije dobre, ažurne i točne. Ukoliko su informacije loše, nepravovremene i netočne, niti najbolji sustav ne može ih

pretvoriti u dobar i pregledan izvještaj. Prednosti koje sustav poslovne inteligencije donosi poduzeću su raznolike. Izvještaji koje sustav generira bitni su i dio su svakodnevnog poslovanja poduzeća. Što su izvještaji točniji i precizniji, manje vremena je potrebno korisniku da donese odluku.

S obzirom da se radi o još uvijek relativno skupim projektima nameće se pitanje isplativosti i povrata investicije. U tom smislu važno je istaknuti da sustav poslovne inteligencije ne nudi nikakvu direktnu financijsku korist, već se korist ogleda kroz procese koje sustav olakšava ili omogućuje. U tom smislu indirektno pridonosi smanjenju troškova (ljudi i vremena potrebnih za pripreme i analize podataka) i povećanju prihoda (nastalih temeljem brzih i ispravnih poslovnih odluka).

Korisnici poslovne inteligencije počeli su zahtijevati poslovnu inteligenciju u realnom vremenu, odnosno analizu podataka u realnom vremenu. Svježe informacije nastale iz procesiranja podataka moraju biti dostupne u svakom trenutku. Kompanije će morati promijeniti poslovne procese da bi mogle iskoristiti tokove poslovnih podataka.

Poduzeća su još uvijek nesklona ulaganjima u poslovnu inteligenciju. Jedan od razloga je nedovoljna informiranost o mogućnostima i potencijalnim koristima koje poduzeće može ostvariti. U nekim slučajevima takva ulaganja predstavljaju velik novčani zalogaj pa se poduzeća ne odlučuju na ulaganje u sustave poslovne inteligencije. Uvođenje novog sustava podrazumijeva promjene u svim dijelovima poduzeća. Međutim, poduzeće teži stanju utroška minimalne energije i kao cjelovit sustav opire se promjenama. Može se reći da ono predstavlja skup političkih interesa pojedinaca u kojem suživot ostvaruju formalne i neformalne interesne skupine. Praksa govori da informatički projekti ne uspijevaju radi ljudskog faktora, a ne zbog tehnologije. U svakom prosječnom poduzeću susrest ćemo nekoliko vrsta zaposlenika. Jedna skupina u pravilu ne prihvaća promjene niti pod kojim uvjetima. Za njih je promjena prijatna te će pružati otpor uvođenju sustava poslovne inteligencije. Razlozi mogu biti različiti: zaokupljenost dnevnom operativom, niska motiviranost ili strah od novog i nepoznatog. Rješenje ovog problema ogleda se u edukaciji korisnika koja je od presudne važnosti. Na taj način smanjit će se odbojnost i strah od uvođenja sustava. Uz to, bitno je da su korisnici uključeni u proces uvođenja sustava poslovne inteligencije, da testiraju sustav i upoznaju se sa njegovim mogućnostima i funkcionalnostima prije početka aktivnog korištenja.

ŽIVOTOPIS

Ime i prezime: Marijan Maček
Datum i mjesto rođenja: 09.07.1991. Zagreb
Adresa: Plavić 54, 49296 Zagorska Sela, Hrvatska
Telefon: 049/ 552-215
Mobilni tel.: 095 505 8398
E-mail: mmacek9@gmail.com

Obrazovanje:

- 2014.- Diplomski studij, Menadžerska informatika, Ekonomski fakultet Zagreb
- 2010. - 2014. Preddiplomski studij poslovne ekonomije, Ekonomski fakultet Zagreb
- 2006. - 2010. X. Gimnazija „Ivan Supek“, Zagreb
- 1998. - 2006. OŠ Kumrovec

Radno iskustvo:

- studeni 2014. - rad u „KIKA“ Jankomir, Zagreb (studentski posao)
- kolovoz 2014. - rad na arheološkom iskopu Špićak za Institut za arheologiju (studentski posao)
- lipanj 2015. – prosinac 2017. - PROSTORIA d.o.o., administrator proizvodnje
- prosinac 2017. – danas – PROSTORIA d.o.o. – odjel nabave

Rad na računalu:

- Internet
- MS Office
- DIGLAS
- IRATA
- E-views

- Elektronička pošta i društvene mreže
- Upoznat sa radom softwera Bizagi Modeler, Doctus, SAP te Oracle SQL Developer

Poznavanje jezika u govoru i pismu:

- Engleski

Članstvo u udruženjima i dodatne edukacije

- 2005. godina do danas – član i volonterski rad u Dobrovoljnom vatrogasnom društvu „Sloga“ Plavić – tajnik udruge
 - pomoć u organizaciji natjecanja i raznih svečanosti te sudjelovanje u natjecanjima
 - sudjelovanje u radu kampa vatrogasne mladeži – Fažana (kao član mladeži i voditelj)
- Položen ispit za vatrogasnog časnika
- Član športskog društva Zagorska Sela i „Mladost '99“ Miljana
- Certifikat o sudjelovanju na „Case study competition“ – 2014. godine
- Vozačke dozvole B kategorije (potvrda o nekažnjavanju)

Dodatne informacije

- Marljiva, disciplinirana, komunikativna i ambiciozna osoba te timski igrač
- Iskustvo samostalnog rada i rada u timu
- Spreman i željan učenja te novih iskustava

LITERATURA:

Knjige i udžbenici:

1. Ćurko, K., Kezan, Š.M.: Skladištenje podataka – Put do znanja i poslovne inteligencije, Ekonomski fakultet – Zagreb, Zagreb, 2016.
2. Inmon W.H., Building the Data Warehouse, John Wiley & Sons, Inc. New York, 1992.
3. Liautaud, Bernard, "e-Business Intelligence: Turning Information into Knowledge into Profit" McGraw-Hill, New York, NY, 2001.
4. Panian, Ž.: Poslovna informatika za ekonomiste, Masmedia, Zagreb, 2005.
5. Panian Ž., Klepac G., "Poslovna inteligencija", Masmedia, Zagreb, 2003.
6. Srića, V. , Muller J., Put k elektroničkom poslovanju, Sinergija, Zagreb, 2001.
7. Srića, V. , Spremić, M.: Informacijskom tehnologijom do poslovnog uspjeha, Sinergija, Zagreb, 2000.
8. Varga, M.; Upravljanje podacima, Element, Zagreb, 2012.
9. Varga,M.; Baze podataka, Konceptualno, logičko i fizičko modeliranje podataka, Društvo za razvoj informacijske pismenosti (DRIP), Zagreb, 1994.

Znanstveni i stručni članci:

1. Bijakšić S., Markić B., Bevanda A.,: BUSINESS INTELLIGENCE AND ANALYSIS OF SELLING IN RETAIL Informatol. 47, 2014.
2. Bilandžić, M., Čulig, B., Lucić, D. Putar-Novoselec, M., Jakšić, J.: Business intelligence u hrvatskom gospodarstvu, Poslovna Izvrsnost, Zagreb, 2012.
3. Kopal R., Korkut D., TEORIJA IGARA Praktična primjena u poslovanju, Društvena istraživanja, Zagreb, 2012.
4. Perković, C., L.: VAŽNOST SUSTAVA ZA POTPORU ODLUČIVANJU NA PRIMJERU UPORABE SUSTAVA POSLOVNE INTELIGENCIJE COGNOS U POSLOVANJU TVRTKE, SVEUČILIŠTE U RIJECI, EKONOMSKI FAKULTET U RIJECI, 2009.
5. Pfeifer, S., Alpeza, M.: Business Intelligence, Sveučilište Josipa Jurja Strossmayera, Ekonomski fakultet u Osijeku, Osijek, 2011.

6. Rupčić, N. (2002). 'PODUZEĆE KOJE UČI - FORMULA ZA 21. STOLJEĆE', Ekonomski pregled, dostupno na: <https://hrcak.srce.hr/28384>
7. Tomaš A., POSLOVNA INTELIGENCIJA -oblikovanje OLAP kocke na primjeru, SVEUČILIŠTE U SPLITU EKONOMSKI FAKULTET, 2014.
8. Varga, M.: Poslovna inteligencija: ciljevi i metode, Ekonomski fakultet – Zagreb, 2004. dostupno na: https://bib.irb.hr/datoteka/166465.Poslovna_inteligencija_HrOUG_2004.pdf

Internet stranice:

1. Business Intelligence, dostupno na: <https://www.forrester.com/Business-Intelligence#>
2. Business intelligence software, dostupno na: <http://www.business2community.com/business-intelligence/business-intelligence-software-need-know-now-01188358#7vQWU7jmqJUrvDsT.97>
3. Enkripcija i zaštita podataka, dostupno na: <http://www.itsistemi.com/hr/rjesenja/sigurnosna-rjesenja/enkripcija-i-zastita-podataka/>
4. "The Business Intelligence and Data Warehousing Glossary", dostupno na: <http://www.sdgcomputing.com/glossary.htm>
5. „Payback on Business Intelligence", dostupno na: <http://www.dmreview.com/>, 01/2003.
6. „Što je poslovna inteligencija?": Dostupno na: <https://www.datalab.ba/sta-je-poslovna-inteligencija/>
7. Prednosti i nedostaci Poslovne inteligencije, dostupno na: <http://www.ebizmags.com/bi-10-vs-bi-20-nedostaci-i-prednosti/>
8. <http://www.skladistenje.com/lose-vizualizacije-zasto-bi-projekti-propadaju/>
9. <http://www.ebizmags.com/bi-10-vs-bi-20-nedostaci-i-prednosti/>
10. <https://hr.wikipedia.org/wiki/Podatak>