

**SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET**

DIPLOMSKI RAD

**DEFINIRANJE INDIKATORA POSLOVNE
INTELIGENCIJE NA TEMELJU POSLOVNIH
POTREBA**

Mentor:

Prof. dr. sc. Nikša Alfirević

Studentica:

Tanja Urem

Split, kolovoz 2018.

SADRŽAJ

| | |
|--|-----------|
| 1. UVOD | 1 |
| 1.1. Problem istraživanja | 1 |
| 1.2. Cilj rada..... | 2 |
| 1.3. Predmet istraživanja | 2 |
| 1.4. Metode istraživanja..... | 4 |
| 1.5. Istraživačke hipoteze..... | 6 |
| 2. STRUKTURA DIPLOMSKOGA RADA | 7 |
| 3. POSLOVNA INTELIGENCIJA..... | 8 |
| 3.1. Pojam poslovne inteligencije | 8 |
| 3.2. Uloga poslovne inteligencije u unapređenju poslovnih procesa | 15 |
| 3.3. Uloga poslovne inteligencije u unapređenju poslovanja | 18 |
| 4. KLJUČNI INDIKATOR USPJEŠNOSTI (KPI) POSLOVANJA | 22 |
| 4.1. Pojam i temeljna teorijska obilježja KPI-ja | 22 |
| 4.2. Teorijsko razmatranje povezanosti procesa definiranja KPI te poslovne inteligencije u cjelini s performansama poduzeća | 27 |
| 4.3. Važnost i utjecaj korištenja usluga vanjskih konzultanata na poslovanje poduzeća..... | 32 |
| 5. EMPIRIJSKO ISTRAŽIVANJE IZGRADNJE INDIKATORA POSLOVNE INTELIGENCIJE NA TEMELJU POSLOVNIH POTREBA | 37 |
| 5.1. Uzorak i istraživački instrument..... | 37 |
| 5.2. Analiza i rezultat istraživanja | 40 |
| 5.3. Testiranje hipoteza..... | 50 |
| 6. ZAKLJUČAK..... | 61 |
| SAŽETAK..... | 63 |
| SUMMARY | 64 |
| LITERATURA | 65 |

| | |
|------------------------------|-----------|
| POPIS SLIKA..... | 69 |
| POPIS TABLICA | 69 |
| POPIS GRAFIKONA | 69 |

1. UVOD

1.1. Problem istraživanja

Pojam „Poslovna inteligencija“ ili „Business Intelligence“ (BI) se sve češće spominje kao važan faktor u poslovanju poduzeća. Koristi se za otkrivanje znanja skrivenih u poslovnim podacima, putem odgovarajućih računsko-logičkih metoda podržanih informacijskom tehnologijom. Koristeći alate poslovne inteligencije podaci se pretvaraju u informacije te poduzeća mogu analizirajući te informacije pronaći odgovore na ključna pitanja, steći obuhvatnije znanje o faktorima koji utječu na poslovanje te unaprijediti poslovanje djelotvornijim upravljanjem. Važnost i prednosti poslovne inteligencije u poslovanju, naročito u vrijeme globalizacije, prepoznala je većina poduzeća u svijetu. Hrvatska još uvelike kaska te se procjenjuje da se manje od 10% poduzeća koristi nekim oblikom poslovne inteligencije.¹

Zadatak poslovne inteligencije je unaprijediti poslovne procese kompanije. Pri tome je potrebno definirati ključne pokazatelje koje se želi promatrati i putem kojih će se pratiti funkcioniranje i napredovanje poslovnih procesa i njihovih performansi. Ključni pokazatelji mogu biti: ključni pokazatelji rezultata (Key result indicator- KRI) koji pokazuje postignuća kompanije u nekom vremenskom razdoblju, te ključni indikator performansi (Key performance indicator- KPI) koji pokazuje što je činiti da bi se povećale performanse. Oni moraju biti mjerljivi, ključni za uspjeh kompanije i reflektirati ciljeve. Pri određivanju ključnih indikatora je važno ograničiti se na faktore koji su neophodni za ostvarenje ciljeva. Važno je napomenuti da definiranje ključnih indikatora i uporaba alata poslovne inteligencije ne znači davanje rješenja za uspješno poslovanje poduzeća već davanje brzih i točnih informacija managementu kao potpora odlučivanju. BI alati služe da bi se promatrajući ključne indikatore a pomoću BI alata prikupile informacije te točno, precizno i djelotvorno izračunali pokazatelji potrebni za poslovnu odluku.

¹ Hrbud Z.: BI za uspješno poslovanje, Open info trend časopis, dostupno na: <http://www.infotrend.hr/clanak/2009/11/bi-za-uspjesno-poslovanje,46,851.html>

1.2. Cilj rada

Poslovna inteligencija se sve češće spominje kao rješenje za djelotvornije upravljanje poslovanjem. Odgovor na pitanje „je li to doista istina i koje su njene koristi, postoji li veza između pravilno izrađenih indikatora poslovne inteligencije i uspješnog poslovanja poduzeća“ je cilj ovoga istraživanja. U teorijskom dijelu će se prikazati važnost pravilnog formiranja ključnog pokazatelja poslovanja i njegova korisnost. Mišljenja će biti potkrijepljena studijama i stavovima različitih autora koji se bave poslovnom inteligencijom. U empirijskom dijelu rada će se pokušati empirijski pokazati povezanost indikatora poslovne inteligencije i pozitivnih učinaka na poslovanje. Korištenjem softverskog alata SAP, empirijsko istraživanje je provedeno korištenjem infrastrukture poduzeća DatArt SA sa sjedištem u Lausanni (Švicarska) koje pruža usluge poslovne inteligencije (optimizacija ERP sustava, formiranje KPI-a itd.).

1.3. Predmet istraživanja

Predmet istraživanja je definiranje ključnih indikatora uspješnosti odnosno pravilno definiranje indikatora poslovne inteligencije prema informacijskim potrebama poduzeća. Također će se ispitati koje kriterije mora zadovoljavati KPI da bi se mogao uspješno primijeniti i koliko su u tome procesu važni BI stručnjaci. Podaci koji će biti korišteni za formiranje KPI-a i analizu su preuzeti iz Eurostat-ovih baza podataka a odnose se na javnu upravu. Europska komisija, svjesna da je digitalna transformacija vlasti ključni element uspjeha jedinstvenog tržišta je postavila „eGovernment Action Plan 2016-2020“. Cilj akcijskog plana je modernizirati javnu upravu, postići digitalno unutarnje tržište i bolju interakciju s građanima i poduzećima. Želi se povećati dostupnost i broj digitalnih javnih usluga javne uprave da bi se postigla brža, jeftinija i korisnicima orijentirana eVlada (e-javna uprava). Akcijski se plan sastoji od nekoliko točaka na kojima će se temeljiti razvoj eVlade. U ovom radu će se pažnja usmjeriti na jednu točku akcijskoga plana za koju će se u empirijskom dijelu postaviti 3 ključna indikatora i ispitati međuovisnost pravilno postavljenoga indikatora i uspješnosti poslovnog procesa i poslovanja u cjelini. Za obradu podataka i formiranje KPI-a se koristio jedan od najpoznatijih alata za poslovnu inteligenciju, SAP. Ključne indikatore formira uprava/management poduzeća u suradnji sa (internim ili eksternim) BI stručnjacima.

Poslovna inteligencija ne može zamijeniti instinkt managementa nego mu može predočiti pokazatelje izračunate iz prikupljenih podataka i informacija, a koje će mu pomoći poduprijeti odluku brzim, točnim i preciznim činjenicama.

Pitanje je kako izgraditi indikatore koji će odgovarati poslovnim potrebama poduzeća. Osim što je važno da KPI zadovoljavaju SMART test (da su specifični, mjerljivi, dostupni i realni), oni mogu biti: kvantitativni - izraženi brojevima, praktični- povezani s postojećim procesima unutar kompanije, usmjeravajući - koji ukazuju na poboljšanje u organizaciji te optužujući - kojima se kontrolira uspješnost promjena u kompaniji². Mogu biti usmjereni na kvalitetu ili na rezultate poslovanja. Razlikuju se ovisno o organizaciji: npr. obrazovna institucija za jedan od KPI može uzeti uspjeh maturanata na maturi, a prodajna kompanija postotak prihoda od stalnih kupaca i sl. Ako je KPI vrijednost, treba odrediti način kako ga mjeriti, a u suprotnom je beskoristan.

Da bi se formirao ključni indikator uspješnosti ponajprije treba odrediti ciljnu vrijednost. Primjerice ako je cilj biti „poželjan poslodavac“, njegov KPI je „učestalost promjene poslodavca“. Nakon definicije cilja i odgovarajućega KPI te odluke da će se isti mjeriti kao „broj dobrovoljnih otkaza ili sporazumnih raskida ugovora, podijeljen s ukupnim brojem zaposlenika na početku promatranoga razdoblja“, da će te informacije prikupljati kadrovska služba kompanije, formira se željena vrijednost. Ona glasi: „smanjiti učestalost promjene poslodavca za 5%“, što je svima razumljiv i vrlo jasan cilj, prema kojemu treba poduzeti mjere za ostvarenje. S druge strane, ako se postavi KPI „biti najpopularnija kompanija“, on je beskoristan, jer ne postoji način kako bi izmjerili popularnost i usporedili ju s drugim kompanijama. Loše postavljen KPI može biti mjerljiv kako nalažu SMART načela, no nije ključan za uspjeh kompanije.

Kompanija postavlja više KPI-a no ipak ih treba ograničiti kako bi se pažnja usmjerila na njihovo ostvarivanje. Također, organizacijske cjeline unutar kompanije imaju svoje KPI-e čije izvršenje potpomaže ciljeve kompanije. Kompanija može imati zajednički KPI no on će biti različito usmjeren u različitim organizacijskim cjelinama. Primjerice KPI „povećanje zadovoljstva kupca“ u kompaniji koja se bavi proizvodnjom i prodajom dobara, u odjelu „proizvodnje“ taj KPI će biti „broj odbijenih jedinica proizvoda nakon provedene kontrole kvalitete“. U odjelu „prodaje“ taj isti KPI će glasiti „ broj minuta čekanja kupca na odgovor

² Metode znanstvenih istraživanja, str 2., dostupno na:
http://www.unizd.hr/portals/4/nastavni_mat/1_godina/metodologija/metode_znanstvenih_istrazivanja.pdf

prodajnog predstavnika“. Uspješno ostvareni KPI pojedinih odjela pridonose ostvarenju ciljeva kompanije.³

Važno je naglasiti da se KPI postavljaju i prate na dugi rok stoga je moguće da se promjenom ciljeva organizacije promjene i KPI.

Management putem pravilno postavljenih KPI-a može u realnome vremenu pratiti performanse poduzeća kroz izvještaje, grafove, tablične prikaze. Jasno vidjeti što je za kompaniju važno i što svatko treba napraviti da bi se ostvarili ciljevi.

U radu će se istražiti kako uspješno definirati indikatore poduzeća prema poslovnim potrebama kupca te ispitati povezanost i utjecaj postavljenih ključnih indikatora na uspješnost poslovanja poduzeća.

1.4. Metode istraživanja

Diplomski rad se sastoji od dva dijela: teorijskog i empirijskoga dijela. Teorijski dio će se izraditi pomoću nekoliko metodoloških postupaka⁴:

- Metoda deskripcije - primjenjuje se u početnoj fazi znanstvenoga istraživanja, a podrazumijeva postupak jednostavnoga opisivanja ili očitavanja činjenica, procesa i predmeta te empirijskih potvrđivanja njihovih odnosa i veza, bez znanstvenoga objašnjavanja i tumačenja.
- Metoda kompilacije - je postupak preuzimanja tuđih rezultata, opažanja, stavova, spoznaja i zaključaka. Upotrebljava se u kombinaciji s drugim metodama tako da djelo nosi u većoj mjeri osobni pečat autora a preuzeto propisno citira.
- Komparativna metoda - kojom se uspoređuju sličnosti između dva predmeta, pojave s ciljem donošenja zaključaka.
- Induktivna i deduktivna metoda- induktivnom metodom se na temelju analize pojedinih činjenica i zapažanja pojedinačnih slučajeva dolazi do općih zaključaka. Nasuprot njoj deduktivna metoda podrazumijeva poznavanje općih znanja temeljem kojih se spoznaje

³ Peterlić, S.:“Ključni pokazatelji uspješnosti (KPIs)-management kvalitete i poslovanja“, dostupno na: <https://issuu.com/kvaliteta.net/docs/peterlic-s1>

⁴ Metode znanstvenih istraživanja, dostupno na: http://www.unizd.hr/portals/4/nastavni_mat/1_godina/metodologija/metode_znanstvenih_istrazivanja.pdf

ono posebno i pojedinačno. U znanosti se koristi za objašnjavanje činjenica i zakona, predviđanje budućih događaja, otkrivanje novih činjenica i zakona, dokazivanje i provjeravanje postavljenih hipoteza...

- Metoda analize i sinteze- metoda analize je postupak znanstvenoga istraživanja raščlambom složenih pojmova, sudova, zaključaka na jednostavnije dijelove. Nasuprot analizi, metoda sinteze objašnjava stvarnost putem sinteze jednostavnih sudova u složenije.

- Metoda apstrakcije i konkretizacije- apstrakcijska metoda je postupak odvajanja općeg i posebnog tj. nebitnih od bitnih elemenata predmeta istraživanja dok je konkretizacijska metoda suprotan postupak i predmet istraživanja shvaća kao jedinstvo općeg i posebnog.

- Metoda generalizacije i specijalizacije- generalizacijskom metodom se od pojedinačnih opažanja izvode opći zaključci. Specijalizacijskom metodom se od općega pojma dolazi do novog pojma, manjeg opsega a većeg sadržaja tj. dolazi se od općeg do posebnog pojma.

- Metoda dokazivanja i opovrgavanja- dokazivanje je jedna od najvažnijih znanstvenih metoda, a za cilj ima utvrditi točnost neke spoznaje. Suprotan pojam je opovrgavanje ili falsifikacija koja za cilj ima dokazati pogrešnost teze a sastoji se u pobijanju teze ili argumentacije.

U empirijskome dijelu će se koristiti metoda anketiranja, statistička metoda, metoda uzoraka⁵.

- Metoda anketiranja - je kvantitativna metoda koja podrazumijeva prikupljanje podataka putem strukturiranog upitnika u svrhu daljnje statističke analize podataka i dobivanja saznanja o ponašanju, stavovima, mišljenju, preferencijama, interesima ispitanika. U radu nije direktno provedena anketa od strane autorice već su podaci ankete koju su provele institucije zemalja članica EU preuzete iz Eurostat database.

- Statistička metoda - se naziva i općom metodom znanstvenih istraživanja u svim znanstvenim područjima. Pomoću ove se metode, na temelju obilježja određenog broja elemenata neke skupine pojava, izvodi zaključak o prosječnoj vrijednosti obilježja, devijaciji od srednje vrijednosti. Važnost ove metode se očituje u činjenici da se jedino pomoću nje može na egzaktan način saznati opća određenost, pravilnost i zakonitost

⁵ Metode znanstvenih istraživanja, dostupno na:
http://www.unizd.hr/portals/4/nastavni_mat/1_godina/metodologija/metode_znanstvenih_istrazivanja.pdf

masovnih pojava. Glavni nedostaci metode su kvantitativna i numerička određenost pojava i pitanje mogućnosti spoznaje općega na temelju pojedinačnoga i posebnoga.

- Metoda uzoraka - je često primjenjivana metoda a podrazumijeva ispitivanje dijela nekoga skupa na temelju slučajnog odabira. Problem pouzdanosti ove metode se očituje u određivanju veličine uzorka i reprezentativnosti odabranih jedinica.

U istraživanju će se preuzeti podaci anketiranih poduzeća 28 zemalja članica EU o zadovoljstvu e-javnom upravom, procedurama pri pokretanju startup-a i njihovim troškovima (u toj državi). Također će se iz baza podataka Eurostata preuzeti podaci o zaposlenim ICT stručnjacima u pojedinim zemljama članicama EU kao mjera kvalitete formiranja KPI-a. Na koncu će se ispitati međuovisnost utjecaja zaposlenika u ICT sektoru (odnosno kvalitete procesa izrade KPI-a) i zadovoljstvo poduzeća (pojedinih zemalja) poslovnim procesima i poslovanjem e-javne uprave (te zemlje). Podaci će se obraditi, a KPI će se formirati u SAP-ovom alatu za poslovnu inteligenciju. Statistička obrada će se izraditi u programu za statističku analizu podataka SPSS koji će se koristiti i za testiranje postavljenih hipoteza.

1.5. Istraživačke hipoteze

Na današnjem globaliziranom i dinamičnom tržištu važno je biti u korak s vremenom, brzim razvojem tehnologije i poduzeća u okruženju ako se želi opstati na tržištu i biti konkurentan. To se može postići jedino pravovremenim pristupom informacijama s tržišta i unutar poduzeća, temeljem kojih se donose odluke o daljnjem smjeru kretanja poduzeća. Prije informacijskoga doba koje je nastupilo u drugoj polovici 20. stoljeća, odluke (naročito kratkoročne) su se donosile mahom prema intuiciji managementa jer je podataka bilo mnogo manje, nisu se koristili računalni resursi za analizu podataka a podaci su se prikupljali iz neautomatiziranih izvora. Danas je informacija na prvome mjestu i pristup istoj u pravo vrijeme jedan je od najvažnijih elemenata poslovanja o kojem ovisi opstanak poduzeća. Automatizacijom se višestruko povećala količina dostupnih podataka a analiza prikupljenih podataka i izrada izvještaja koja je prije trajala mjesecima sada je potrebna u realnom vremenu, kao podloga za donošenje kako vrlo važnih strateških (dugoročnih) tako i taktičkih

(kratkoročnih) odluka. One se više ne donose na temelju intuicije, nego na temelju informacija i znanja. Problem se ne javlja ukoliko su odluke jednostavne, i iz informacija je jednostavnim izračunom lako donijeti odluku kao npr. kod povećanja ili smanjenja proizvodnje nekoga proizvoda. Problem nastaje kod složenijih pitanja kao npr. što napraviti kada se dogodi pad prodaje proizvoda, kako povratiti prodaju. Informacije za takve odluke ne postoje već je potrebno veliku količinu neobrađenih informacija iz različitih izvora urediti tj. filtrirati, preraditi i povezati kako bi se dobile korisne informacije i donijele kvalitetne odluke. To nije jednostavan posao i upravo tu se javlja potreba korištenja poslovne inteligencije i postavljanje ključnih pokazatelja uspješnosti (KPI).

Glavna hipoteza i dvije podhipoteze koje će se analizirati u radu su:

H1: Postoji međuovisnost pravilno definiranog ključnog indikatora poslovne inteligencije i ostvarivanja performansi poslovnih procesa te poslovanja u cjelini

H1.1: Postoji međuovisnost kvalitete procesa izbora ključnog indikatora poslovne inteligencije i performansi poslovnog procesa

H1.2: Postoji međuovisnost kvalitete procesa izbora ključnog indikatora poslovne inteligencije i performansi poslovanja.

Glavnom hipotezom (H1) će se pokušati dokazati važnost primjene pravilno izrađenog indikatora poslovne inteligencije u poslovanju i njegov utjecaj na uspješnost poduzeća što se dodatno razrađuje dvjema podhipotezama.

2. STRUKTURA DIPLOMSKOGA RADA

Diplomski rad se sastoji od dva dijela: teorijskog i empirijskoga dijela. U prvome, teorijskome dijelu će se upoznati s pojmom poslovne inteligencije, ključnih indikatora uspješnosti poslovanja (KPI) kao problemom i predmetom istraživanja te ciljem istraživanja. Predstaviti će se metode koje će se koristiti u istraživanju te postavljene hipoteze koje će se dokazivati u empirijskome dijelu rada. U drugom dijelu, empirijskome će se predstaviti i objasniti korišteni uzorak, način i rezultati obrade sakupljenih podataka. Prikazati će se i primjer izgradnje

ključnog indikatora poslovne inteligencije za razvoj eGovernmenta u SAP alatu. Statistička značajnost postavljenih hipoteza i međuovisnost parametara će se analizirati u SPSS statističkom alatu za analizu podataka.

3. POSLOVNA INTELIGENCIJA

3.1. Pojam poslovne inteligencije

Poslovna Inteligencija (Business Intelligence) kao pojam postaje popularan 90-tih godina 20.stoljeća u poslovnoj i IT zajednici. U kasnim 2000-tim poslovna analitika (Business analytics) postaje ključna analitička komponenta poslovne inteligencije koja se koristi za analizu velikih i kompleksnih skupova podataka koji zahtijevaju napredne tehnologije za pohranu, upravljanje, analizu i vizualizaciju.⁶

Postoji razlika između pojmova Business Intelligence (BI) i Business Analytics (BA) ali se sve češće spominju i koriste kao jedinstven pojam. BI spada u deskriptivnu analizu te opisuje prošlo i trenutno stanje, dok BA spada u prediktivnu analizu te pomoću softvera (alata) za analizu podataka (internih i eksternih) predviđa buduće aktivnosti. Često se BI i BA koriste zajedno kao analiza sadašnjih i prošlih događaja i predviđanje budućih te se u literaturi može pronaći jedinstven pojam Business Intelligence and Analytics (BI&A).⁷

⁶ Hsinchun C., Chiang R.H.L., Storey V.C.: „Business Intelligence and Analytics:From Big Data to Big Impact“,str.2, dostupno na: <https://pdfs.semanticscholar.org/fbb1/8d40150508ef2f344359ec345da7fb77cc0a.pdf>

⁷ Primjer: Hsinchun C., Chiang R.H.L., Storey V.C.: „Business Intelligence and Analytics:From Big Data to Big Impact“



Slika 1. Razlika između poslovne inteligencije (BI) i poslovne analitike (BA)

Izvor: Analytics Bulgaria web site, dostupno na: <http://analytics.bg/en/business-analytics-2/bi-vs-ba/>

Poslovna inteligencija (BI) je pojam koji objedinjuje skup metodologija (Data Warehousing, Data Mining, OLAP) i softverskih alata kojima se omogućuje korištenje podataka iz različitih skladišta podataka (Data Warehouse) i njihovo pretvaranje u informaciju potrebnu za donošenje poslovnih odluka.⁸

Pojam poslovne inteligencije je teško jednoznačno definirati jer ne postoji univerzalna definicija. Štoviše, postoje i brojne kontroverze po pitanju definicije poslovne inteligencije⁹, a svaki je autor definira na svoj način.

Prema Panianu i Klepcu, poslovna inteligencija je složena, agregirana kategorija koja se stvara sustavnim ali unaprijed ciljanim prikupljanjem podataka o makroekonomskim kretanjima u određenoj geopolitičkoj sredini, njihovim organiziranim i strukturiranim bilježenjem odnosno pohranjivanjem, pretraživanjem te logičkom i računalnom obradom poradi otkrivanja makroekonomskih trendova ili tendencija te predviđanja i prognoziranja procesa i događaja u makroekonomskim sustavima i njihovih budućih stanja¹⁰.

⁸ MIT Software: "Općenito o BI sustavima", dostupno na: <http://www.mit-software.hr/usluge/bi/bi1/>

⁹ Panian Ž, Klepac G (2003): Poslovna inteligencija, Zagreb, Masmedia, str.4-6

¹⁰ Ibid., str.21

Prema Javoroviću i Bilandžiću, poslovna inteligencija je obavještajna aktivnost u poslovnom svijetu koju planiraju, organiziraju i provode poslovni subjekti, pri čemu ta aktivnost podrazumijeva proces legalnog prikupljanja javnih i svima dostupnih podataka etičnim sredstvima, njihovu analizu i pretvaranje u gotove poslovno-obavještajne analize („znanje“) radi pružanja potpore čelništvu poslovnog subjekta s ciljem donošenja i realizacije što kvalitetnijih poslovnih odluka usmjerenih na očuvanje postojeće pozicije poslovnog subjekta u poslovnom okruženju, izbjegavanje bilo kakvih prijetnji i u konačnici na ukupni kvalitativni napredak poslovnog subjekta¹¹.

Danas se može govoriti o pet dominantnih stilova poslovne inteligencije:¹²

1. Poslovno izvještavanje: široka lepeza izvještaja raznih formata, tablica rezultata poslovanja i poslovnih kontrolnih ploča. Namijenjeno je korisnicima različitih profila.
2. OLAP kocke: analitički alat koji omogućuje “presijecanje i raslojavanje“ (Slice and Dice) skupova podataka. Namijenjene su menadžerima i djelatnicima za provođenje bazičnih analiza podataka.
3. Ad hoc upiti i analize: softver koji omogućuje postavljanje neograničenog broja upita na raspoloživim podacima i OLAP analizu baza podataka. Namijenjeni su istraživačima i naprednijim poslovnim korisnicima.
4. Rudarenje podataka: aplikacije koje omogućuju složenu i cjelovitu matematičku, statističku i financijsku obradu podataka u svrhu analize korelacije, trendova, tržišnih i financijskih analiza te predviđanje budućih događaja i procesa. Namijenjeno je profesionalnim analitičarima.
5. Alarmni alati i sustavi ranog obavještavanja: alati za rano obavještavanje i upozoravanje korisnika po unaprijed utvrđenim kriterijima i događajima. Namijenjeni su unutarnjim i vanjskim korisnicima informacija.

Postoji potreba za jedinstvenom arhitekturom koja će pomoću kombinacije aplikacija objediniti navedene stilove poslovne inteligencije. Time bi se korisnicima omogućilo jedinstveno sučelje za pristup alatima a time i jednostavnije povezivanje funkcionalnosti

¹¹Javorović B, Bilandžić M (2007): Poslovne informacije i business intelligence, Zagreb, Golden marketing, str.205

¹² Panian Ž. I suradnici: „ Poslovna Inteligencija, Studije slučajeva iz hrvatske prakse“,str.41-42, dostupno na: https://bib.irb.hr/datoteka/481181.PISSHP_-_Glavnina_teksta.pdf

različitih stilova, isporuku rezultata putem jedinstvene platforme, unificirane metapodatke te zadovoljavajuću razinu sigurnosti, te minimiziralo troškove administracije i održavanja.

Sustavi poslovne inteligencije se počinju intenzivno razvijati informatizacijom i automatizacijom poslovnih procesa. Prije početka informacijskoga doba podaci su se prikupljali iz neautomatiziranih izvora. Nisu postojali računalni resursi za obradu tih podataka pa su se odluke donosile na temelju intuicije. Automatizacijom sustava lakše se prikupljaju podaci, količina podataka se naglo povećava, no analiza istih je trajala mjesecima. Stoga su se na temelju tih podataka mogle donositi samo dugoročne (strateške) odluke a kratkoročne (taktičke) su se i dalje donosile prema intuiciji. Danas se količina podataka mjeri u terabajtima, ili čak eksabajtima. Da bi se iz tolike količine podataka izvukli oni važni za donošenje poslovne odluke, koristi se poslovna inteligencija. Procesom poslovne inteligencije sirovi se podaci oblikuju u strukturno i vizualno prihvatljive informacije, koje se zatim analiziraju i interpretiraju putem trendova i ključnih pokazatelja poslovanja (Key Performance Indicators, KPIs) za ocjenu trenutnog stanja te kao takvi koriste u procesu odlučivanja i izradi smjernica za buduće poslovanje. Poslovna inteligencija „ne daje odgovor na pitanje što napraviti, ona govori što je bilo i što je sada“ poznata je rečenica Prof. Michaela F. Gormana sa University of Dayton, Ohio. Ona ne daje odgovor što raditi ili što će se dogoditi, već pruža sažeti prikaz podataka pomoću kojih poslovni korisnici mogu razumjeti trendove i dobiti uvid u kretanja. Osnovni cilj BI je sakupiti i BI alatima za analizu obraditi sirove i neupotrebljive podatke te dobiti korisne informacije relevantne za poslovanje poduzeće koje će omogućiti donošenje kvalitetnih poslovnih odluka. Pravovremena i točna informacija i njena pravilna upotreba jedan je od glavnih faktora napretka i opstanka poduzeća na tržištu. Ono poduzeće koje dođe do korisnih informacija i pravovremeno ih upotrijebi, stječe konkurentsku prednost. Upravo tu dolazi do izražaja važnost i korisnost poslovne inteligencije kao kritičan faktor poslovanja.

Treba napomenuti da sami postupci obrade podataka nisu dovoljni da bi se dobile kvalitetne, ispravne i vjerodostojne informacije za donošenje poslovnih odluka. Vrlo je važno da podatke obrađuju stručnjaci koji posjeduju BI znanja, razumiju poslovanje i poslovne potrebe kompanije. Potrebno je voditi računa i o kvaliteti podataka jer o njima ovisi donošenje poslovnih odluka. Postoje dvije skupine izvora podataka koje poduzeća prikupljaju: vanjski i unutarnji izvori podataka. Vanjskim izvorima se podrazumijevaju oni podaci prikupljeni iz okruženja poduzeća odnosno s tržišta na kojem poduzeće djeluje a unutarnjim izvorima oni podaci koji nastaju realizacijom poslovnih procesa unutar same organizacije. Može se

primijetiti kako su podaci koje poduzeća prikupljaju heterogeni, pa se znanje dobiveno iz tih podataka naziva poslovnom inteligencijom.¹³

Primjerice, multinacionalna kompanija koja se bavi veleprodajom i maloprodajom ima svoje baze podataka u svakoj državi. U cilju donošenja ispravnih odluka koje se ne temelje samo na intuiciji menadžmenta, potrebno je konsolidirati te odvojene baze podataka i na jednom mjestu pratiti podatke o proizvodima, dobavljačima, kupcima, stanju na skladištu, prodaji/profitabilnosti proizvoda i slično. BI stručnjaci (unutarnji ili vanjski) izrađuju skladište podataka, programska rješenja (pomoću BI alata) za prikupljanje i ujedinjavanje podataka iz odvojenih baza. Stvara se BI portal na kojemu korisnici mogu pratiti rezultate. Potom BI stručnjaci u suradnji s direktorima, menadžerima dogovaraju ključne indikatore performansi (KPI) koji će se pratiti i izvještavati. Potom se mogu povezati s podacima Državnog zavoda za statistiku o dobi, spolu, broju stanovništva, usporediti s bazom podataka i prema tim informacijama formirati marketing, prodajnu mrežu- gdje otvoriti dućan i sl.¹⁴

Četiri su osnovne kategorije kvalitete podataka koje imaju izravan utjecaj na donošenje poslovnih odluka u poduzeću: standardiziranost, podudarnost, verificiranost i proširivost.¹⁵

Poslovnu inteligenciju možemo podijeliti na dvije osnovne podvrste: tržišnu inteligenciju i unutarnju inteligenciju tvrtke.

Izvori podataka u tržišnoj inteligenciji su klijenti poduzeća, konkurencija poduzeća i poslovni partneri. Drugim riječima, podaci se prikupljaju održavanjem odnosa s postojećim i potencijalnim klijentima, prikupljaju se podaci o konkurentskim tvrtkama (na legalan i etičan način) te podaci koji pristižu uspostavljanjem opskrbnoga lanca i praćenjem tokova među sudionicima toga lanca.


Unutarnja inteligencija poduzeća nastaje prikupljanjem podataka iz operativnih poslovnih procesa poduzeća te upravljačkih procesa. Odnosno podaci se prikupljaju izvršavanjem poslovnih procesa tj. evidentiranjem podataka koji nastaju iz poslovnih događaja te podaci koji nastaju iz upravljanja poslovanjem, donošenjem poslovnih odluka, planova, budžeta, preporuka, naredbi i sl. Stoga unutarnju inteligenciju možemo dalje podijeliti na inteligenciju

¹³ Panian Ž. I suradnici: „ Poslovna Inteligencija, Studije slučajeva iz hrvatske prakse“,str.2, dostupno na: https://bib.irb.hr/datoteka/481181.PISSHP_-_Glavnina_teksta.pdf

¹⁴ Hrbud Z.: BI za uspješno poslovanje, Open info trend časopis, dostupno na: <http://www.infotrend.hr/clanak/2009/11/bi-za-uspjesno-poslovanje,46,851.html>

¹⁵ Panian Ž, Klepac G (2003): Poslovna inteligencija, Zagreb, Masmedia, str.30

poslovnih procesa i inteligenciju menadžmenta¹⁶, odnosno poslovanja koje će biti detaljnije razrađeno u dijelovima rada 2.1 i 2.2.



Slika 2. Poslovna inteligencija kao rafinerija podataka

Izvor: Eckerson W.: „Smart Companies in the 21st Century: The Secrets of Creating Successful Business Intelligence Solutions“, str.4, dostupno na:
http://download.101com.com/tdwi/research_report/2003BIReport_v7.pdf

Poslovna se inteligencija vremenom razvija, evoluirala pa se tako danas može govoriti o tri koncepta poslovne inteligencije: strateškoj, taktičkoj i operativnoj poslovnoj inteligenciji.

Strateška BI se razvila u samom početku kada se njezin potencijal ogledao u potpori upravljačkom potencijalu na strateškoj razini. Strateška BI se fokusira na ostvarenje dugoročnih organizacijskih i upravljačkih ciljeva (primjerice smanjenje troškova poslovanja i povećanje prihoda). Odluka se uglavnom odnosi na vremensko razdoblje duže od godine dana. Taktička poslovna inteligencija razmatra taktičke aspekte upravljačkog potencijala. Srednjoročnog je karaktera a odluke se odnose na razdoblje provedbe od nekoliko dana do nekoliko mjeseci. Srednjoročni ciljevi mogu biti primjerice upravljanje i analiza marketing kampanja za konkretni proizvod ili uslugu. Za stratešku i taktičku poslovnu inteligenciju je potrebno da poduzeće ima skladište podataka (Data Warehouse) i spremišta podataka (Data

¹⁶ Panian Ž. I suradnici: „ Poslovna Inteligencija, Studije slučajeva iz hrvatske prakse“, str.2-3, dostupno na: https://bib.irb.hr/datoteka/481181.PISSHP_-_Glavnina_teksta.pdf

Mart) u kojima se podaci ažuriraju jednom dnevno ili rjeđe. Operativna poslovna inteligencija je najnoviji aspekt BI i pomaže pri donošenju kratkoročnih poslovnih odluka i odluka u stvarnom vremenu (real time). Ova vrsta poslovne inteligencije ima široku paletu primjena i nastoji se integrirati u sve poslovne procese do razine poslovnih operacija. Primjer operativne BI je praćenje prodaje vrsta goriva na pojedinim crpkama tijekom dana, stalni nadzor distribucije robe na nekom geo području, promptno otkrivanje pokušaja prevara na kreditnim karticama i sl.¹⁷

Tablica 1. Obilježja strateške, taktičke i operativne poslovne inteligencije


| | Strateška poslovna inteligencija | Taktička poslovna inteligencija | Operativna poslovna inteligencija |
|---------------------------|---|--|--|
| Poslovni fokus | Ostvarivanje dugoročnih poslovnih ciljeva | Upravljanje taktičkim inicijativama radi ostvarivanja strateških ciljeva | Upravljanje i optimizacija dnevnih poslovnih operacija |
| Primarni korisnici | Vrhovni menadžment i poslovni analitičari | Srednji menadžment, poslovni analitičari i operativni menadžment | Operativni menadžment, klijenti |
| Vremenski horizont | Mjeseci, godine | Dani, tjedni, mjeseci | Unutar radnoga dana |
| Podaci | Povijesni, ključni pokazatelji uspjeha | Povijesni pokazatelji i podaci | Aktualni, realnovremenski podaci |

Izvor: Panian Ž. I suradnici: „ Poslovna Inteligencija, Studije slučajeva iz hrvatske prakse“, str.63, dostupno na: https://bib.irb.hr/datoteka/481181.PISSHP_-_Glavnina_teksta.pdf

Razni autori su se složili da poslovna inteligencija proizvodi brojne benefite za poduzeće koje je koristi. Od umanjivanja rizika donošenja nekvalitetnih odluka, štednje vremena i novca do ostvarenja konkurentskih prednosti. Poslovna inteligencija prema Eckersonu ima svoje opipljive (tangible) i neopipljive (intangible) prednosti. Opipljive je prednosti moguće mjeriti u jedinicama, postotcima ili korištenjem novčane vrijednosti dok je neopipljive teže mjeriti jer nemaju fizičku vrijednost. Eckerson je proveo istraživanje na 510 korporacija istražujući prednosti koje ta poduzeća imaju od korištenja Business Intelligence-a (rezultati na grafikonu 1). Istraživanjem je zaključio da je većina prednosti koje poduzeća imaju od korištenja BI rješenja po prirodi neopipljiva.¹⁸

¹⁷ Ibid., str. 61/62

¹⁸ Eckerson W.: “Smart Companies in the 21st Century: The Secrets of Creating Successful Business Intelligence Solutions“, str. 11, dostupno na: http://download.101com.com/tdwi/research_report/2003BIReport_v7.pdf



Grafikon 1. Prednosti korištenja poslovne inteligencije, opipljive i neopipljive prednosti

Izvor: Eckerson W.: "Smart Companies in the 21st Century: The Secrets of Creating Successful Business Intelligence Solutions", str.11, dostupno na:
http://download.101com.com/tdwi/research_report/2003BIReport_v7.pdf

3.2. Uloga poslovne inteligencije u unapređenju poslovnih procesa

Poslovanje bilo koje organizacije, bila proizvodne, uslužne, javne uprave i slično, sastoji se od niza poslovnih procesa. Svaku akciju u poduzeću se može nazvati poslovnim procesom. Prema definiciji, poslovni proces je povezani skup aktivnosti i odluka koji se izvodi na vanjski poticaj radi ostvarenja nekog mjerljivoga cilja organizacije. Traje određeno vrijeme i troši ulazne resurse pretvarajući ih u specifične proizvode ili usluge od značaja kupca ili korisnika.¹⁹ Da bi poslovanje organizacije bilo uspješno potrebno je najprije da su poslovni procesi svima razumljivi, povezani i usmjereni ka cilju organizacije. Svaki poslovni proces uključuje nekoliko uobičajenih faza: planiranje, izvršenje, mjerenje, procjena i poboljšanje. Ovaj se krug izmjene faza ponavlja sa svakim ciklusom poslovanja. A kako tvrtke sa svakim ciklusom uče i sazrijevaju, poslovna inteligencija im pomaže u svakoj od tih faza.

¹⁹ Brumec J.(2011): Modeliranje poslovnih procesa, Varaždin/Zagreb, str.3, dostupno na: <https://koris.hr/preuzmi/koris-uvod-u-modeliranje-poslovnih-procesa.pdf>



Slika 3. Demingov krug poslovne inteligencije kao pomoći za unapređenje poslovnog procesa

Izvor: Datta's Ramblings, IT blog portal, dostupno na: <https://dattatreysindol.com/2013/04/15/bi-basics-why-do-we-need-business-intelligence/>

Kako poslovanjem organizacija stječe iskustva i nova znanja tako se i učinkovitost poslovanja organizacije može povećati praćenjem i unapređenjem poslovnih procesa te njihovim preustrojem. Poslovanjem odnosno obavljanjem poslovnih procesa organizacija prikuplja velike količine podataka na dnevnoj razini. Unutarnji informacijski sustav organizacije skladišti podatke, obrađuje ih i sprema rezultate obrade. Uloga poslovne inteligencije je da, tijekom odvijanja poslovnog procesa, prati performanse koje se uspoređuju s postavljenim indikatorima uspješnosti (KPI). U skladu s navedenim upravljačko tijelo može promptno reagirati ukoliko se ciljevi ne ostvaruju kako je planirano. Za uspjeh organizacije na globalnome tržištu potrebno je unapređivati poslovne procese, a to podrazumijeva primjenu informacijske tehnologije na odgovarajući način čime procesi postaju brži, efikasniji, učinkovitiji. Uspije li organizacija uspostaviti odgovarajući sustav prikupljanja, spremanja i obrade podataka te ih povezati sa menadžerima i zaposlenicima, njihovim znanjima i vještinama da iskoriste informacije dobivene iz sakupljenih podataka, može se reći da je ostvarila pretpostavke za stvaranje svoje unutarnje poslovne inteligencije. Takva inteligencija

će joj omogućiti proaktivno upravljanje poslovnim procesima i poslovanjem u cjelini te će biti poveziva, kompatibilna i nadopunjujuća s njenom tržišnom inteligencijom.²⁰

Poslovni procesi se mogu mjeriti i pratiti pomoću poslovnih aplikacija i analitike te upravljanja poslovnim procesima (Business Process Management, BPM) što čini preduvjet za stvaranje inteligencije poslovnih procesa (Business Process Intelligence, BPI). BPI predstavlja primjenu postupaka analize uspješnosti upravljanja poslovnim procesima poduzeća. Sustav upravljanja procesima (BPMS) bilježi brojne vrste događaja koji se javljaju tijekom izvođenja poslovnog procesa uključujući vrijeme početka i završetak pojedine aktivnosti, ulazne i izlazne podatke, resurs izvršenja, te bilo koji uspjeh ili neuspjeh tijekom neke aktivnosti i izvršenja procesa. Pomoću poslovne inteligencije ti se podaci čiste, agregiraju procesi i spremaju u bazu podataka te se potom analiziraju. Analizom se dobivaju informacije/znanja o okolnostima u kojima se dogodila visoka ili niska kvaliteta izvedbe poslovnog procesa te se dobivene informacije mogu koristiti da bi se objasnio uzrok takvih rezultata i predvidjeli potencijalni problemi u budućim poslovnim procesima. Uvođenje inteligencije poslovnih procesa (BPI) umjesto jednostavne automatizacije poslovnih procesa (koja se koristi u poduzećima već dugi niz godina) može dovesti do značajnoga smanjenja troškova poslovanja i bržeg povrata ulaganja u tehnologiju.²¹

BPI ima nekoliko značajki koje nude razne razine automatizacije upravljanja kvalitetom poslovnih procesa i to:²²

◦ Analiza (Analysis): BPI korisnicima omogućuje da analiziraju izvršene procese iz poslovne i informatičke perspektive. IT analitičari će biti više zainteresirani za detaljnije promatranje podataka niže razine kao što je prosječno vrijeme izvršenja akcije ili dužinu repa čekanja. Poslovni će korisnici biti zainteresirani za informacije na višoj razini kao npr. broj „uspješnih“ procesa izvršenja ili karakteristike procesa koji je zadovoljio standard kvalitete.

◦ Predviđanje (Prediction): BPI može razviti modele predviđanja i primijeniti ih na pokrenute procese, te identificirati moguće iznimke ili neželjena ponašanja u budućnosti. Predviđanja se mogu izvršiti na razini IT-ja (predvidjeti hoće li računalo ili aplikacija biti uključeni u

²⁰ Panian Ž. I suradnici: „ Poslovna Inteligencija, Studije slučajeva iz hrvatske prakse“, str.29, dostupno na: https://bib.irb.hr/datoteka/481181.PISSHP_-_Glavnina_teksta.pdf

²¹ Panian Ž. I suradnici: „ Poslovna Inteligencija, Studije slučajeva iz hrvatske prakse“, str.30, dostupno na: https://bib.irb.hr/datoteka/481181.PISSHP_-_Glavnina_teksta.pdf

²² Grigori D., Casati F., Castellanos M., Dayal; Umeshwar D., Sayal M., Shan M.-C.: “Business Process Intelligence”. Computers in Industry 53, Elsevier, Volume 53(2004), str. 322, dostupno na: http://ceit.aut.ac.ir/~sa_hashemi/My%20Teachings/MS-CEIT-Business%20Process%20Re-Engineering/Resources/BPI-BussinessProcessIntelligence.pdf

provedbu poslovnog procesa) ili poslovanja (predvidjeti hoće li usluga biti isporučena u skladu sa standardom kvalitete)

- Praćenje (Monitoring): BPI može pratiti i analizirati tijek procesa te obavijestiti o neuobičajenim ili neželjenim situacijama. Korisnici mogu pratiti status i uspješnost sustava, procese, usluge i resurse. Osim toga, korisnici mogu i definirati kritične situacije (upozorenja) u slučaju kojih bi ih BPI obavijestio/alarmirao.

- Kontrola (Control): Temeljem praćenja procesa i predviđanja, BPI može komunicirati sa sustavom upravljanja poslovnim procesima (BPMS) kako bi se izbjegla degradacije kvalitete poslovnih procesa ili smanjio utjecaj degradacije na uspješnost sustava.

- Optimizacija (Optimization): BPI može identificirati područja poboljšanja u definicijama poslovnih procesa te dodjeli resursa i usluga u radnim aktivnostima.

Iako je uvođenje BPI (time i poboljšanja poslovnih procesa i poslovanja u cjelini) privlačno za svako poduzeće, razvoj BPI rješenja predstavlja neke izazove kao što su:

- identifikacija arhitekture i tehnologija koje mogu isporučiti navedene funkcionalnosti,

- razumijevanje kako primijeniti ili modificirati te tehnologije za postizanje ciljeva pojedinoga poslovnog procesa i u konačnici poslovanja,

- omogućavanje definicije pojmova i podataka za kvalitativnu analizu procesa,

- razvoj tehnika koje olakšavaju analitičarima korištenje alata da bi izvukli potrebna znanja (po mogućnosti bez pisanja nekoga koda) te

- razumijevanje interakcije s BPMS-om i s korisnicima kako bi izvještavali i ispravili kritične situacije pravovremeno.

Inteligencija poslovnih procesa (BPI) je tehnološki intenzivna i od korisnika zahtjeva sofisticirana znanja.

3.3. Uloga poslovne inteligencije u unapređenju poslovanja

Poslovanje u 21. stoljeću je kompleksnije no što je to bilo u prošlosti u pogledu globaliziranosti tržišta i brzih promjena. Orijentiranost ka kupcima/potrošačima,

transparentnost, dostupnost i brzina informacija, nestajanje geografskih (tržišnih) granica, razvoj naprednih komunikacijskih tehnologija itd. Transparentnost informacija jača položaj potrošača te dovodi poduzeće u situaciju da se, uz jaku konkurenciju, bori za svakoga potrošača. Svaka pogrešna odluka ili, akcija može dovesti u pitanje opstanak poduzeća. Takva situacija je izazov za menadžment koji je suočen s mnoštvom prilika koje pruža globalno tržište ali i prijatni. Menadžment, odnosno upravljanje poslovanjem više ne ovisi isključivo o znanju i sposobnosti menadžera, već ključnu ulogu u kvaliteti odluka preuzima kvaliteta i dostupnost informacija te brzina reakcije menadžmenta odnosno donošenja poslovnih odluka. Da bi na vrijeme pristupili kvalitetnim podacima i dobili točne i relevantne informacije na temelju kojih će donijeti brze poslovne odluke o daljnjem smjeru poslovanja, menadžeri sve više počinju shvaćati potrebu, korisnost i koncept poslovne inteligencije (da prikupi veliku količinu podataka iz različitih izvora i osigura dovoljno komponenti za točnu i vjerodostojnu informaciju koja će pomoći pri donošenju ispravnih odluka). Poslovna inteligencija je za menadžere alat, koji im omogućuje da na inteligentan način prate, kontroliraju, usmjeravaju i planiraju poslovanje. Iz tog razloga se stvaraju rješenja, koja povezuju odgovarajuće komponente i funkcije bez programiranja pa menadžer sam kreira alat prilagođen individualnim potrebama. Takav pristup koji „kroji“ inteligentno rješenje prema poslovnim potrebama stručnjaci danas nazivaju inteligencijom menadžmenta.²³

Alati poslovne inteligencije koji bi zadovoljili potrebe inteligencije menadžmenta bi trebali imati obilježja:²⁴

- Jednostavnosti: alat bi trebao biti jednostavan za korištenje i održavanje, lišen potrebe programiranja, niskih troškova nabave i održavanja
- Vertikalne proširivosti: alat koji bi bio u mogućnosti podržati potrebe različitih razina organizacijske strukture poduzeća
- Horizontalne proširivosti: alat bi morao moći servisirati specifične potrebe različitih poslovnih funkcija poduzeća (prodaje, marketinga, financija, itd.)
- Strukturirano višedimenzijско modeliranje: iz razloga povećanja fleksibilnosti analiza, jednostavnije integracije podataka iz različitih izvora, dosljednog korištenja informacija u svim organizacijskim jedinicama poduzeća, za stvaranje okvira za jednoobrazno, konceptualno usklađeno modeliranje i razvijanje aplikacija

²³ Panian Ž. I suradnici: „ Poslovna Inteligencija, Studije slučajeva iz hrvatske prakse“, str.33-34, dostupno na: https://bib.irb.hr/datoteka/481181.PISSHP_-_Glavnina_teksta.pdf

²⁴ Ibid, str.35.

- Podrška većem broju korisnika: višekorisnički pristup je nužan za kvalitetnu realizaciju upravljačkih procesa
- Brzina: alat bi trebao omogućiti kratko vrijeme odziva, promptno konsolidiranje i izvršavanje poslovnih procesa koji se obavljaju online, bez bojazni da će se dogoditi eksplozija podataka u bazi podataka (poznate kod korištenja nekih metoda rudarenja podataka).
- Dokazivost: alat bi trebao biti u mogućnosti dokazati koncept na kojemu počiva uz pomoć stvarnih „živih“ podataka.

Alati poslovne inteligencije se sve više dorađuju, unapređuju funkcionalnosti da bi se postigla što veća učinkovitost, točnost i usklađenost s potrebama poslovanja. Suvremeni alati sve su bliži ideji da se jednim klikom miša dobiju potrebne informacije a krajnji cilj je mogućnost provođenja analiza tipa „što-ako“ i razumijevanja zašto i kako se nešto događa. Analize „što ako“ su se do sada provodile proračunskim tablicama no one mogu obuhvatiti samo mali broj podataka i imaju još niz nedostataka.

Ukratko, od poslovne inteligencije se danas očekuje prediktivnost i proaktivnost. Prediktivnost podrazumijeva mogućnost predviđanja budućih događaja, stanja, promjena i sl., a proaktivnost mogućnost osmišljavanja, pripremanja i poduzimanja akcija za predviđene događaje, promjene, procese. Drugim riječima, ona mora moći odgovoriti na pitanja što je bilo i ponuditi odgovor na pitanje što učiniti ako se nešto dogodi.²⁵

U literaturi se pojavljuje i novi termin „right-time“ ili „real-time“ koncept poslovne inteligencije. „Kao novi koncept koji je tek nedavno izašao iz teorijskih okvira, right-time koncept poslovne inteligencije briše razlike između racionalnog strateškog i operativnog odlučivanja, omogućujući operativnoj razini odlučivanja da koristi platforme i alate koji su donedavno bili rezervirani za strateško odlučivanje. Poslovna inteligencija uvelike unapređuje poslovno odlučivanje, posebice kroz smanjenje latencije²⁶ u poslovnom odlučivanju (...)“²⁷ Nekih pak autori za real-time poslovnu inteligenciju koriste naziv BI 2.0²⁸, koji se odnosi na

²⁵ Panian Ž. I suradnici: „ Poslovna Inteligencija, Studije slučajeva iz hrvatske prakse“, str.36, dostupno na: https://bib.irb.hr/datoteka/481181.PISSHP_-_Glavnina_teksta.pdf

²⁶ Latencija- vrijeme čekanja odnosno vrijeme koje protekne od trenutka zahtjeva do trenutka isporuke

²⁷ Dukić B., Bara D., Dukić S. (2016):“ Impact of Right-Time Business Intelligence Tools of Efficiency in Decision Making“, str.1, dostupno na: <https://hrcak.srce.hr/162077>

²⁸ Hsinchun C., Chiang R.H.L., Storey V.C.: „Business Intelligence and Analytics:From Big Data to Big Impact“, str.3, dostupno na: <https://pdfs.semanticscholar.org/fbb1/8d40150508ef2f344359ec345da7fb77cc0a.pdf>

možnosti prikupljanja, dostavljanja i analize podataka u realnome vremenu što prijašnji alati poslovne inteligencije nisu omogućavali.

Naime, poslovna se inteligencija do nedavno koristila za donošenje strateških (dugoročnih) odluka u poslovanju na temelju raspoloživih podataka u bazama podataka, dok su se za operativne (kratkoročne) odluke koristile male količine podataka tj. transakcijski izvori podataka. Operativne odluke su se donosile vrlo brzo no zbog vremenski ograničenih izvora informacija, upitna je relevantnost takvih odluka. Zbog situacije na modernom tržištu, brzih promjena i konkurencije, važno je skratiti vrijeme donošenja strateških odluka a povećati važnost operativnih odluka. Time se gubi jasna podjela između strateških i operativnih odluka. Razvija se potreba za povećanjem brzine odlučivanja na svim razinama za što je potreban pristup podacima u realnom vremenu. Zbog sve veće količine podataka kojima poduzeća raspolažu javlja se problem latencije koji postaje središnji problem učinkovitosti poslovnog odlučivanja. Latencija odluke je vrijeme koje je potrebno da se razumije informacija, donese odluka za vrstu akcije i pokrene sama akcija. Da bi se riješili ti problemi razvio se koncept poslovne inteligencije u realnom vremenu (real-time business intelligence) obzirom na važnost dimenzije vremena. Podaci u realnom vremenu (real-time) neće proizvesti poslovnu vrijednost i dovesti do kvalitetnih poslovnih odluka, ukoliko se ne iskoriste u pravo vrijeme.

Bara i Knežević tvrde da smanjenje latencije podataka i analize ovisi prvenstveno o tehničkim rješenjima. Najnovija tehnologija, posebice u „real-time“ skladištenju podataka pruža pomoć u tom smislu. No glavna stvar koja smanjuje latenciju (kašnjenje) odluke zahtjeva promjene u poslovnim procesima i kako se koriste pružene informacije u obavljanju poslova.²⁹ S druge strane, Tank drži da implementacija real-time poslovne inteligencije može rezultirati značajnim prednostima poduzeću, smanjujući vrijeme provedeno u donošenju odluka a dajući donositelju odluka dovoljno vremena i informacija za donošenje odluke. To rezultira učinkovitijim procesom donošenja odluka i smanjuje troškove jer se odluke donose pravovremeno u jakom konkurentskom okruženju.³⁰ Real-time poslovna inteligencija bi trebala ponuditi: nultu latenciju u postupku, pružiti informacije u bilo kojem trenutku (kada god menadžment zahtjeva), imati mogućnost izvući ključne mjere performansi ovisno o trenutnoj situaciji (u ovom trenutku) a ne samo u nekoj prošloj (povijesnoj) situaciji. Primarni

²⁹ Dukić B., Bara D., Dukić S. (2016):“ Impact of Right-Time Business Intelligence Tools of Efficiency in Decision Making“,str.2-3., dostupno na: <https://hrcak.srce.hr/162077>

³⁰ Tank, M.(2015): „ Enable Better and Timelier Decision-Making Using Real-Time Business Intelligence System“, str.46, dostupno na: <http://www.mecs-press.net/ijieeb/ijieeb-v7-n1/IJIEEB-V7-N1-6.pdf>

cilj real-time poslovne inteligencije je povezati analizu upravljačkih funkcija tako da analiza postane sastavni dio posla menadžerima i timovima zaposlenika. Da bi real-time poslovna inteligencija funkcionirala, skladišta podataka bi trebala biti ažurirana s transakcijskim podacima u realnome vremenu. Tradicionalni sustavi poslovne inteligencije pomažu poboljšati strateške odluke koje utječu na uspješnost poslovanja. No to nije dovoljno za potpuno rješavanje problema na današnjem vrlo dinamičnom tržištu. Real-time BI pruža poduzeću mogućnost automatizacije mnogih zadataka i procesa u bazi podataka i tako osigurava više vremena za rad na znanju.³¹

Rezultati istraživanja utjecaja real-time alata poslovne inteligencije na efikasnost poslovnog odlučivanja provedenog u poslovnoj praksi u Hrvatskoj, pokazuju da poduzeća koja su uspješno implementirala alate poslovne inteligencije ili ih svakodnevno koriste kao korak pri donošenju poslovnih odluka, ostvaruju pozitivne promjene po pitanju profitabilnosti, učinkovitosti, konkurentnosti i imaju bolji pregled prilika i prijetnji u poslovanju.³²

4. KLJUČNI INDIKATOR USPJEŠNOSTI (KPI) POSLOVANJA

4.1. Pojam i temeljna teorijska obilježja KPI-ja

KPI predstavlja skup mjera usmjerenih na one aspekte organizacijskih performansi koji su najkritičniji za sadašnje i buduće uspjehe organizacije.³³ Pomoću njih menadžment prati uspješnost poslovnih procesa i planiranih ciljeva poslovanja. KPI utjelovljuje strateški cilj i mjeri učinkovitost djelovanja prema cilju. Kada su postavljeni ciljevi poslovanja, organizacija mora pronaći način za mjerenje i praćenje razvoja tj. parametara koji će pokazati u kojem smjeru se kreće poslovanje i dali vodi ka ostvarenju ciljeva, za što služe KPI. Ključni indikator performansi predstavlja metriku koja je usko povezana s ciljem. Oni se uglavnom prikazuju kao odnos planiranog i postignutog rezultata, pokazujući postoje li odstupanja od

³¹ Dukić B., Bara D., Dukić S. (2016):“ Impact of Right-Time Business Intelligence Tools of Efficiency in Decision Making“,str.4., dostupno na: <https://hrcak.srce.hr/162077>

³² Ibid, str.7-8.

³³ Parmenter D.:“Key Performance Indicators; Developing,Implementing, and Using Winning KPIs“, (2007), str.3., dostupno na: <https://www.slideshare.net/AddkwService/key-performance-indicators-david-parmenter>

planiranog i za koliko.³⁴ Osim što pokazuje poslovni uspjeh na temelju trenutnih i povijesnih mjera on može ukazati na buduće ishode te tako upozoriti rukovoditelje na moguće probleme u poslovanju, također i pružiti napredne smjernice o mogućnostima za maksimiziranje povrata ulaganja. Ove informacije pružaju menadžmentu mogućnost proaktivnog upravljanja poslovanjem u cilju stjecanja konkurentskih prednosti. Ključni indikator performansi je mjerljiv cilj poduzeća koji može uključivati sve razine poslovanja a značajan je za uspjeh kompanije. Stoga poduzeće uglavnom ima više postavljenih KPI-a, na razini poslovnih procesa te na razini menadžmenta. Svi ti KPI vode ka istom glavnom cilju kompanije. Ne postoje univerzalni KPI, već svako poduzeće kreira svoje vlastite ključne pokazatelje koji su kritični za njegovo poslovanje.

Dvije su osnovne vrste KPI-a: KPI ishoda (outcomes) i KPI vodilje (drivers). KPI ishoda (outcome KPI) su u literaturi poznati i kao pokazatelji zaostajanja (lagging indicators), a KPI vodilje (driver KPIs) kao vodeći pokazatelj ili vodilja vrijednosti (leading indicators). Outcome KPIs (lagging) su često financijske prirode iako ne nužno. Primjerice, to su: prihodi (rast/pad), prinos na kapital, zadovoljstvo kupaca, zadržavanje zaposlenika i sl. Nazivaju se indikatorima zaostajanja, jer prate događaje koji su se već dogodili, dok vodeći pokazatelji najavljuju nadolazeće poslovanje. Driver KPIs (leading) mjere aktivnosti koje imaju značajan utjecaj na outcome KPI-e. Oni mjere aktivnost tekućeg ili budućeg stanja (npr. broj sastanaka prodaje danas ili broj sastanaka prodaje zakazanih za slijedeća dva tjedna, rezervacije koje će generirati prihode u budućem kvartalu i sl.). No u praksi često nema velike razlike između ove dvije vrste indikatora.³⁵

Ključni indikator performansi se također mogu podijeliti na kvantitativne i kvalitativne, ovisno na kojim se podacima temelje. Kvantitativni KPI čine okosnicu većine KPI-a. Temelje se na kvantitativnim podacima koji aktivnosti mjere brojanjem, dodavanjem ili prosječnim vrijednostima. Podatke prikupljaju iz operacijskih sustava koji upravljaju opskrbnim lancem, nabavom, narudžbama, iz računovodstva i sl. Kvalitativni KPI su jednako važni i to su najčešće oni koji ocjenjuju kupca ili zaposlenika putem ankete. Takvi KPI objašnjavaju zašto

³⁴ Kojić N., Dajić M., Vučković N.: "Merenje i unapređenje indikatora ključnih performansi u savremenoj organizaciji", *Ekonomski signali*, 2017, str 4., dostupno na: <https://scindeks-clanci.ceon.rs/data/pdf/1452-4457/2017/1452-44571702001K.pdf>

³⁵ Eckerson W.W.: "Performance Management Strategies; How to Create and Deploy Effective Metrics" (2009), str.11., dostupno na: https://www.microstrategy.com/Strategy/media/downloads/white-papers/TDWI_Performance-Management-Strategies.pdf

performanse opadaju, a svi ostali pokazatelji izgledaju dobro. Mnoga poduzeća koriste KPI zadovoljstva korisnika kako bi poboljšali proizvode i optimizirali procese.³⁶

KPI se mogu mjeriti i uspoređivati dnevno, tjedno, mjesečno, tromjesečno, kvartalno, godišnje itd. Važno je da su usko formirani, značajni, razumljivi svima, jasni i jednostavni za mjerenje i praćenje te usporedivi kroz razdoblja, u suprotnome gube svoju funkciju. KPI-e je potrebno unapređivati zbog promjenjivih uvjeta na današnjem tržištu. Dobro postavljeni KPI, usko su definirani i neophodni za ostvarenje ciljeva. No, postoje mjerljivi dijelovi poslovanja koji nisu ključni za ostvarenje cilja te nisu relevantni za postavljanje KPI-a i praćenje njihovog kretanja. Pri postavljanju indikatora, trebalo bi usmjeriti pažnju na njihovo ostvarenje, odnosno njihovu kvalitetu a ne kvantitetu. Veliki broj postavljenih KPI-a (više od 2-3 po razini poslovanja a ukupno više od 10) može biti kontraproduktivan i napraviti više štete nego koristi. Svrha postavljanja ključnih indikatora je da iz „šume“ podataka izvuče najbitnije, krucijalne za poslovanje. Ukoliko se ne slijedi ideja KPI i postavi veliki broj pokazatelja ili se postave krivi KPI (mjere koje nisu ključne), rukovoditelji i zaposlenici mogu izgubiti fokus.

Da bi KPI bili dobro postavljeni trebali bi zadovoljiti SMART test, odnosno biti: S (specific)-specifični, jasni i usmjereni da bi se izbjeglo pogrešno tumačenje, M (measurable)-mjerljivi da bi se mogli uspoređivati s drugim podacima, A (achievable)- dostupni u očekivanim uvjetima, R (realistic)- realistični, usklađeni s uvjetima u organizaciji, T (time-based)-vremenski ograničeni da bi bili izvedivi u planiranome vremenu.³⁷ Također bi trebali dati svima jasnu sliku što je bitno za organizaciju i što je potrebno napraviti da bi se isto ostvarilo. Periodično praćenje razvoja KPI-a osigurava managementu kontrolu stanja poslovanja u realnome vremenu i uspješno napredovanje prema njenim ciljevima, a zaposlenicima praćenje napretka može biti motivator za rad i ostvarenje KPI ciljeva.

Ideja postavljanja ključnih indikatora je izbjegavanje velikih proračunskih tablica i složenih aplikacija tako da se uzmu tehnički podaci i prezentiraju na svima razumljiv jezik. Oni ne služe da bi dali odgovore na koji način nešto napraviti nego da bi iz hrpe zbunjujućih podataka, sažeto i jednostavno prenijeli što relevantnije informacije. Na taj način prikazuju kretanja i stanje promatranog procesa te pomažu pri donošenju odluke što i kako dalje. Ključni indikator poslovanja: koristi stope, omjere, postotke i prosjeke umjesto sirovih

³⁶ Ibid., str.12

³⁷ Peterlić, S.: "Ključni pokazatelji uspješnosti (KPIs)-management kvalitete i poslovanja", str 2/3., dostupno na: <https://issuu.com/kvaliteta.net/docs/peterlic-s1>, pristupljeno: 22.09.2017

brojeva, pruža uvid u vremenski kontekst i ističe promjenu umjesto prikazivanja tablice podataka, pokreće kritične poslovne akcije. Važno je istaknuti da svi dobro postavljeni KPI kreiraju očekivanja i pokreću akciju. „Svaki KPI koji, kada se odjednom i neočekivano promijeni, a ne potakne nekoga da pošalje e-mail, podigne slušalicu ili požuri potražiti pomoć, nije KPI vrijedan izvješćivanja“.³⁸

Ključni indikatori poslovanja se mogu definirati na svim nivoima poslovanja poduzeća, od cjelokupnog poduzeća, preko odjela do svakog pojedinog radnoga mjesta. KPI se stoga može svrstati u dvije kategorije:


Strateške mjere (high- level measure): usmjerene su na organizaciju kao cjelinu. Koriste se za donošenje strateških KPI-a na visokoj razini organizacije, za strateške ciljeve. Mogu se vrednovati kratkoročno (2 - 5god) ili dugoročno (20 god.) te mogu imati drill-down mogućnost usklađivanja sa operativnim mjerama.³⁹ Strateške mjere mogu biti: konkurentska snaga, relativni tržišni udio, organizacijska kultura, obuka i razvoj itd.,

Operativne mjere (low-level measure): služe za praćenje dnevnih aktivnosti/procesa u poduzeću. Ove su mjere detaljnije od strateških i fokusirane su na akcije kritične za provedbu ključnih poslovnih procesa. Ove mjere podupiru strateške mjere.⁴⁰ Operativni KPI se formiraju na nižim razina poslovanja. Loše formirani KPI na ovoj razini onemogućuju praćenje uspješnosti poslovnih procesa, uzrokuju pogrešne odluke, materijalne i financijske gubitke itd. Operativne mjere mogu biti: zadovoljstvo kupca, kvaliteta proizvoda i usluga, produktivnost članova tima itd.

³⁸ Peterson T. E.: „The Big Book of Key Performance Indicators“, (2006), str.7, dostupno na: http://www.webanalyticsdemystified.com/downloads/The_Big_Book_of_Key_Performance_Indicators_by_Eric_Peterson.pdf

³⁹ Kuhfahl R.,Sehlke C.,Sones J.,Howard N.:“ Key Performance Indicators:What Can They Do for You?”(2018), str.38, dostupno na: <http://web.a.ebscohost.com.ezproxy.nsk.hr/ehost/pdfviewer/pdfviewer?vid=0&sid=9d1aef2b-5572-4fee-92db-7321d1692660%40sessionmgr4008>

⁴⁰ Ibid., str 39.



Slika 4. Strateški i operativni KPI

Izvor: Shen J.: „Investigation of how to implement successful KPIs for organizations – based on an empirical study at an international organization“, Master degree, str.13-14, dostupno na: <http://www.diva-portal.org/smash/get/diva2:617504/FULLTEXT01.pdf>

Pri formiranju KPI-a trebalo bi voditi računa da postoji ravnoteža između strateških i operativnih ključnih pokazatelja. Ispravno postavljeni indikatori će na kraju: dati informacije dali poduzeće radi ispravno ili ne u smjeru zadovoljenja postavljenoga cilja, motivirati će zaposlenike i timove da „rade bolje“. Također je važno da se vrši mjerenje pravih stvari, u pravo vrijeme i na pravome mjestu.

Svi KPI su mjerni podaci no nisu svi mjerni podaci i KPI. Mjerama se mjeri poslovna aktivnost, a za unapređenje poslovanja potrebno je mjeriti poslovnu aktivnost (provedbu) usklađenu s poslovnom strategijom (KPI). Razlika između obične mjere poslovanja i KPI-a je da ključni indikator performansi utjelovljuje strateški cilj i mjeri napredovanje prema cilju. Ciljevi pridruženi ključnom indikatoru performansi su višedimenzionalni: imaju raspone koji su kodirani u softveru, vremenski okvir pomoću kojega ciljevi moraju biti ostvareni, i mjerilo prema kojemu se ciljevi uspoređuju.⁴¹

Jedan od načina prikaza KPI-a kojima se služe poslovni analitičari su dashboardi. To su ploče na kojima su vizualno i svima lako razumljivo prikazani KPI i njihova kretanja. Sve je više alata za vizualizaciju koji nude zanimljive prikaze putem grafikona, termometara, tahometara

⁴¹ Eckerson W.W.: „Performance Management Strategies; How to Create and Deploy Effective Metrics“ (2009), str.6., dostupno na: https://www.microstrategy.com/Strategy/media/downloads/white-papers/TDWI_Performance-Management-Strategies.pdf

te omogućuju da se klikom na pojedini podatak na dashboardu dobije detaljniji prikaz vezan uz taj podatak (drill-down). U ovom radu obrada i vizualizacija KPI-a je napravljena u SAP softwareu.

4.2. Teorijsko razmatranje povezanosti procesa definiranja KPI te poslovne inteligencije u cjelini s performansama poduzeća

Kao što je rečeno u prethodnim poglavljima poslovna inteligencija je proces kojim se prikupljaju brojni podaci iz unutarnje i vanjske okoline te pretvaraju u korisne informacije na temelju kojih će poduzeće moći kreirati kvalitetne poslovne strategije i donijeti kvalitetne poslovne odluke u cilju postizanja poslovnog uspjeha i konkurentske prednosti. Glavne odrednice poslovne inteligencije su kontinuirana točna, pravodobna i kvalitetna informacija kao podloga poslovnom odlučivanju. Primjena BI, odnosno kontinuirano prikupljanje podataka i njihova analiza (pomoću ključnih indikatora performansi) poduzećima donosi niz koristi i poslovnih prednosti. Zadatak poslovne inteligencije i analize putem KPI-a je predvidjeti moguća ili vjerojatna zbivanja u budućnosti i omogućiti menadžmentu brzu i ispravnu reakciju. Primjerice, omogućuje menadžmentu znanja da će u nekom gradu iduće sezone doći veći broj posjetitelja, te im tako omogućiti da se pripreme za povećanu potražnju za nekim artiklima ili možda smanje ponudu nekih drugih artikala za kojima će pasti potražnja i sl.

Izbor pogrešnih ključnih indikatora može rezultirati kontraproduktivnim ponašanjem i suboptimalnim rezultatom (troši se vrijeme i novac za mjerenje, praćenje i optimiziranje mjernih podataka koji nisu značajni). Uvijek se nameće pitanje kako od nekoliko stotina i tisuća mjera odabrati 10 KPI-a i biti siguran da su to uistinu KPI a ne obični mjerni podaci? Kako provjeriti da ti mjerni podaci dovode do optimizacije na razini poduzeća a ne samo do lokalne optimizacije? Kako uskladiti kratkoročne i dugoročne ciljeve?... KPI trebaju mjeriti vitalne aktivnosti a pri definiciji KPI-ja treba odgovoriti na pitanja: Što treba izmjeriti? Koliko mjernih podataka treba imati? Koliko često treba mjeriti? Tko je odgovoran za mjerni podatak? Koliko složen treba biti mjerni podatak? Kako normalizirati mjerni podatak? Što treba koristiti kao mjerilo? Kako osigurati da mjerni podaci odražavaju strateške vodilje (drivers)? Kako bi se utvrdilo da metrički podaci odražavaju strateške vodilje i dosljedni su sa

ciljem i vizijom poduzeća, KPI moraju proizaći iz vizije poduzeća odnosno najvišeg nivoa piramide i kaskadno se spuštati kroz organizaciju (slika 5.)⁴²



Slika 5. Piramida strateškog usmjerenja

Izvor: Bauer, K.: "KPIs- The Metrics That Drive Performance management" (2004), str 63, dostupno na: <http://web.a.ebscohost.com.ezproxy.nsk.hr/ehost/pdfviewer/pdfviewer?vid=0&sid=7a872d03-b96e-4463-900c-46d55d9368ed%40sessionmgr4008>

Vizija poduzeća se prevodi u KPI preko nekoliko posrednih koraka - kreiranja strategije, ciljeva i kritičnih čimbenika uspješnosti. Budućnost poduzeća (misija) mora biti podržana pitanjima: kako (strategijom), što (ciljevima), područja fokusa (kritični čimbenici uspjeha), mjernih podataka (KPI) te akcijskog plana (ključne akcijske inicijative), kako bi se ostvarilo njeno potpuno aktiviranje. Mora postojati sveobuhvatno i dosljedno usklađivanje svih nivoa piramide⁴³ od vrha do dna da bi se postiglo uspješno kreiranje i provedba KPI te njihov cilj - uspješno unapređenje poslovnog procesa i poslovanja u cjelini.

Šest je čimbenika učinkovitih KPI-a koji utječu na poboljšanje performansi poduzeća:⁴⁴

⁴² Bauer, K.: "KPIs- The Metrics That Drive Performance management" (2004), str 63/64, dostupno na: <http://web.a.ebscohost.com.ezproxy.nsk.hr/ehost/pdfviewer/pdfviewer?vid=0&sid=7a872d03-b96e-4463-900c-46d55d9368ed%40sessionmgr4008>

⁴³ Ibid, str.64.

⁴⁴ Taylor J.: "Best practice for picking the right KPIs for your business", dostupno na: <https://www.klipfolio.com/blog/best-practices-for-picking-business-kpis>

1. Odabir KPI-a koji su usklađeni sa strateškim poslovnim ciljevima- važno je odabrati različite KPI za različite razine upravljanja u poduzeću. Izvršni direktori se bave srednjim i dugoročnim ciljevima, menadžment srednjim i kratkoročnim ciljevima te linijski voditelji, kratkoročnim ciljevima. Obzirom na različite poslovne odluke za koje su odgovorni, imaju i različite ključne indikatore performansi. Osim toga važno je balansirati između strateških i operativnih KPI-a odnosno top-down i bottom-up metrika.
2. Provjeriti jesu li podaci za mjerenje KPI dostupni- treba provjeriti dali su podaci pomoću kojih će se mjeriti KPI dostupni i nisu pretjerano skupi. Pri odabiru ključnih indikatora i procjeni troškova, trebalo bi se zapitati: Koje točno podatke treba mjeriti? Koje tehnologije i procese bi trebalo implementirati za pristup podacima? Koliko će sve koštati i koje su mogućnosti povrata? Poslovna inteligencija bi trebala biti strateška odluka, odnosno dio strateškoga plana.
3. Biti konzistentan pri odabiru KPI-a - izabrati do deset KPI-a koji su dovoljno specifični da informiraju konkretne radnje i koji se kreću u istome smjeru. Ako je KPI nejasan, može se tumačiti na više načina čime gubi funkciju i cilj. Ograničavanje njihova broja prisiljava na odabir onih KPI-a koji su doista ključni za poslovanje i mjere koje su doista ključne za uspjeh. Manje KPI-a znači i veću usredotočenost, manje vremena i troška što povećava učinkovitost. Njihovo kontinuirano optimiziranje može dugo potrajati i biti skupo, stoga je manji broj indikatora lakše pratiti i optimizirati, i trošak je manji.
4. Odabir točnih KPI-a - pri odabiru KPI-a je važna točnost podataka koje koriste KPI i pouzdanost podataka u predviđanju uspješnosti poslovanja. Bilo bi potrebno zapitati se: Sadrži li KPI sve relevantne informacije? Primjerice da bi izmjerili točan trošak nabave kupca potrebno je sakupiti podatke iz različitih izvora (marketinga, prodaje, administracije a možda i neke opće troškove). Svi ti podaci bi trebali biti u istom mjerilu što može biti složen proces koji zahtijeva IT podršku a postoji mnogo prostora za pogrešku (ljudsku i tehnološku). Suočeni s ovim problemom dolazi se u iskušenje da se odbace ili zanemare važni podaci jer ih je teško uklopiti u mjerni podatak. Takav KPI može učiniti više štete nego koristi. Nadalje potrebno je zapitati se, koliko je točan KPI u odražavanju i predviđanju uspješnosti poslovanja?
5. Odabrati ključne pokazatelje koji su djelotvorni- jedno od najvažnijih razmatranja pri formiranju KPI-a je pitanje je li KPI djelotvoran ili ne. Za to postoji tzv. dvostruki lakmus test. Prvo, može li (barem neki) od događaja koji utemeljuju KPI biti

kontroliran poslovanjem? Ako su okolnosti koje pokreću KPI izvan kontrole tvrtke onda se taj KPI ne može koristiti. Drugo, dali je KPI strukturiran i prikazan na način, i pravim ljudima, da inicira akciju. Ukoliko KPI ne inicira akciju nije niti vrijedan.

6. Odabrati KPI-e koji su „živi“ - kako tržište i poslovanje nije statično, to ne bi trebali biti niti KPI. Trebalo bi povremeno provjeriti dali su razlozi postavljanja određenog KPI-a i dalje isti? Je li se promijenilo poslovanje ili kontekst unutar kojega djeluje KPI? Može li KPI biti prerađen da bi odgovarao nastalim promjenama ili ga treba potpuno ukloniti? Također bi trebalo povremeno pregledati procese nadzora i djelovanja po KPI-ma. Jesu li donositelji odluka radili na poboljšanju KPI-a? Imaju li prave alate za to? Podupire li sustav KPI-a donošenje odluka (temeljenih na tim podacima) i poboljšava li poslovne rezultate? Menadžeri bi trebali neprestano procjenjivati KPI-e kako bi bili sigurni da su postavljeni indikatori i dalje relevantni i usklađeni s prioritetima u poslovanju. Ukoliko pojedini KPI više ne služi svrsi potrebno ga je redefinirati ili potpuno zamijeniti.

Podaci, mjere i KPI su posvuda i vrlo je lako izgubiti fokus i orijentirati se na podatke koji nisu ključni za poslovanje. Zbog toga je važno uzeti vrijeme za kritičko razmišljanje zašto i kako je neki KPI ključan za poslovanje te koji su podaci vrijedniji od drugih.

Uvođenje poslovne inteligencije u poduzeće nije jednostavan i jeftin pothvat stoga je jako važno da je se ispravno implementira i koristi kako bi se postigla njena korisnost-poboljšanja performansi poslovanja i konačno poslovnoga uspjeha. Sustavi poslovne inteligencije u poduzećima često nisu uspješni, kvalitetni koliko je očekivano i ne ostvaruju postavljene ciljeve. Da bi se izbjegle takve situacije i postigao najviši stupanj korisnosti sustava BI-ja postoji 5 „zlatnih pravila“ za izgradnju, implementaciju i korištenje sustava poslovne inteligencije.⁴⁵

1. Korisnike treba razumjeti

Nekoliko je kategorija korisnika BI sustava: poslovni korisnici netehničkoga profila, poslovni analitičari i napredniji korisnici. Informatička služba osigurava alate i stvara uvjete za obavljanje poslova i zadataka korisnika. Poslovni korisnici netehničkog profila su u pravilu najbrojnija skupina korisnika. Oni nisu pretjerano stručni u korištenju informacijske tehnologije i potrebno im je slati pripremljene izvještaje,

⁴⁵ Panian Ž. I suradnici: „ Poslovna Inteligencija, Studije slučajeva iz hrvatske prakse“, str.74-81, dostupno na: https://bib.irb.hr/datoteka/481181.PISSHP_-_Glavnina_teksta.pdf

obavijesti i informacije koje će oni pregledavati i proučavati. Može im se pružiti i šira ponuda izvještaja iz koje sami mogu izabrati potrebne. U slučaju nedostatka potrebnih informacija oni se obraćaju informatičkoj službi koja posjeduje tehnička znanja da pribave tražene informacije ne ulazeći u problem i ne posjedujući znanja o tome zašto poslovnim korisnicima te informacije trebaju.

Poslovni analitičari su puno stručniji u korištenju informacijske tehnologije i obično su iskusni u korištenju softverskih alata za analizu podataka (i njihovih sofisticiranih funkcionalnosti). Oni znaju izmijeniti izgled i sadržaj izvještaja i odnose među podacima (sortirati informacije, filtrirati, ubaciti stupce, retke itd.)

Napredniji poslovni korisnici su najviša razina korisnika. Posjeduju tehnička znanja i kako iskoristiti potencijale informacijske tehnologije. Usmjereni su poslovanju a tehnologija im nije predmet interesa, već im služi isključivo kao sredstvo za ostvarenje poslovnih ciljeva. Dobro poznaju tehnologiju baza podataka i kako koristiti tako strukturirane podatke. Sami oblikuju ad hoc izvještaje koji su im potrebni. U tipičnoj organizaciji, u svakoj poslovnoj jedinici postoji barem jedan napredni poslovni korisnik koji savjetuje manje osposobljene korisnike informacija u slučaju kada ovi ne znaju riješiti problem iz područja informatike.

2. Primijeniti paradigmu broja klikova

Ova paradigma predstavlja osnovu za razumijevanje i utvrđivanje količine truda koju korisnik mora uložiti da bi došao do tražene informacije. Što je veći broj klikova potreban da bi se došlo do informacije to je veći uloženi trud korisnika. Svaka bi tvrtka trebala nastojati da što više dijelova sustava poslovne inteligencije korisniku osigura željene informacije s dva ili manje klikova.

3. Napredniji korisnici trebaju biti konzumenti ali i proizvođači informacija

Tradicionalno su glavni proizvođači informacija u poduzećima informatičari a poslovne jedinice i pojedinačni korisnici potrošači. Za uspješan sustav poslovne inteligencije treba uvesti promjene takvoga stanja iz dva razloga. Prvo, informatičari čine manjinu zaposlenika poduzeća pa trpe velike pritiske i dolazi do zagušenja. Drugo, oni obično nisu dovoljno educirani i informirani o pojedinostima poslovanja pa ne mogu predvidjeti koje i kakve će informacije korisnici trebati. Stoga bi napredniji korisnici trebali imati dvostruku ulogu u sustavu poslovne inteligencije- biti konzumenti informacija ali i aktivnije sudjelovati u stvaranju istih. Time bi se olakšalo informatičarima ali i poslovnim korisnicima koji ne posjeduju dovoljno znanja da to mogu učiniti sami. Preuzimanjem dvostruke uloge od strane naprednih korisnika

ostvaruje se ravnoteža opterećenja razvojnim aktivnostima, potrebna da bi BI sustav dobro funkcionirao i davao kvalitetne rezultate.

4. Uspostaviti i njegovati kulturu mjerenja

Trebalo bi ustrajati na razvoju, njegovanju i trajnom unapređenju kulture mjerenja. Ponuditi jasna objašnjenja kako će se mjeriti uspješnost provedbe strategije poslovanja. Stara uzrečica kaže da ono što se može mjeriti time se može i upravljati. Uspostavljanje kulture mjerenja je dugotrajan proces koji zahtjeva mnogo strpljenja. Provođi se u četiri koraka: 1. Komuniciranje korporativne strategije sa svakim pojedinim zaposlenikom, 2. Razrada strategije kako bi ostvarenje strateških ciljeva moglo biti iskazano jasnim i nedvosmislenim pokazateljima uspješnosti, 3. Kontinuirano objavljivanje i dostavljanje informacija o poslovnoj strategiji i pokazatelja njenoga ostvarenja svim poslovnim jedinicama, skupinama i izvršiteljima, 4. Nagrađivanje i priznanja zaposlenicima koji ostvaruju željene učinke na radu.

5. Razvoj poslovne inteligencije treba biti strateško opredjeljenje poduzeća

Uvođenje poslovne inteligencije je poslovni pothvat pa bi odluka o uvođenju i korištenju BI-ja trebala biti jedna od ključnih strateških odluka. Nabava BI alata je skupa stoga bi poslovna inteligencija trebala biti usmjerena na cjelokupnu organizaciju i uspješnost ukupnog poslovanja odnosno interes svim zaposlenika a ne samo užih skupina. Jedino tako se može osigurati uspješnost primjene poslovne inteligencije.

4.3. Važnost i utjecaj korištenja usluga vanjskih konzultanata na poslovanje poduzeća

U suvremenom poslovanju je neupitna potreba i korisnost uporabe poslovne inteligencije. Upitna je samo uspješnost BI sustava. Glavni uzorci neuspjeha sustava su nerazumijevanje i nedostatak iskustva pri korištenju softvera poslovne inteligencije. Najčešće greške u sustavu poslovne inteligencije u poduzećima se javljaju zbog: pogrešnog tumačenja korisničkih vještina, znanja, želja i potreba, stavljanja naglaska i koncentriranje sredstava na pogrešnu fazu životnog ciklusa sustava, generiranja informacija koje ne zadovoljavaju potrebe

poslovnih korisnika, neuspostavljanja kulture mjerenja, forsiranja konceptualno različitih i nekompatibilnih taktičkih rješenja.⁴⁶

Većinu zaposlenika prosječnoga poduzeća (izuzevši IT poduzeća) čine korisnici netehničkog profila. Oni se za pribavljanje informacija i dopremanje izvještaja koje će analizirati obraćaju informatičkoj službi. S druge strane informatičari znaju koristiti tehnologiju no nisu educirani i upućeni u ekonomske i poslovne aspekte poduzeća te često ne razumiju čemu služe tražene informacija i koliko su kvalitetne. Analizu podataka pomoću moćnih i uglavnom složenih alata poslovne inteligencije rade BI analitičari i napredni poslovni korisnici koji čine manjinu u poduzeću (ako ih u poduzeću i ima).


Tradicionalni BI proces počinje tako što poslovni analitičar prikuplja zahtjeve za analizu korisnika. On odlučuje kako interpretirati zahtjeve i isporučuje ih arhitektu skladišta podataka. Arhitekt skladišta podataka definira kočke, činjenice, dimenzije i granularnost činjenica/dimenzija. Potom modelar skladišta podataka odlučuje kako dimenzije i činjenice trebaju biti integrirane u skladište podataka. On razvija: modele podataka za područje postavljanja, skladište baze podataka i kočke. ETL developer razvija ETL kod za učitavanje podataka. BI developer razvija kočke i nadzorne ploče (dashboards). Analitičar za kvalitetu podataka provjerava kvalitetu dashboarda. Zatim se nadzorne ploče objavljuju na serveru te ih korisnici mogu koristiti.

Agilni (prilagodljivi) BI je pristup koji kombinira procese, metodologije, organizacijsku strukturu, alate i tehnologiju koje omogućuju donositeljima strateških, taktičkih i operativnih odluka da budu fleksibilniji i osjetljiviji na brz tempo promjena u poslovanju.⁴⁷ U agilnoj poslovnoj inteligenciji, BI konzultant savjetuje korisnike u području informacijskoga menadžmenta i odabire najprikladnija BI rješenja. On je prva točka kontakta za kupca. Ima iskustva s modernom tehnologijom poslovne inteligencije, modeliranjem podataka, ETL alatima, ciklusom razvoja softvera itd. BI konzultant je odgovoran za prikupljanje zahtjeva, dizajn i razvoj BI rješenja.⁴⁸

⁴⁶ Panian Ž. I suradnici: „ Poslovna Inteligencija, Studije slučajeva iz hrvatske prakse“, str.69-70, dostupno na: https://bib.irb.hr/datoteka/481181.PISSHP_-_Glavnina_teksta.pdf

⁴⁷ Muntean M., Surcel T.: „ Agile BI- The Future of BI“, 2013, str.115., dostupno na: <https://pdfs.semanticscholar.org/e6b5/93ca7fc2256ca8f49b70072c70dbe5645c8d.pdf>

⁴⁸ Ibid., str.122



Slika 6. Tradicionalni tijek rada nasuprot agilnog tijeka rada BI

Izvor: Muntean M., Surcel T.: „ Agile BI- The Future of BI“, 2013, str.122., dostupno na: <https://pdfs.semanticscholar.org/e6b5/93ca7fc2256ca8f49b70072c70dbe5645c8d.pdf>

Tehničke vještine koje posjeduje BI konzultant su: razumijevanje podataka i statistike (alati su beznačajni ako korisnik ne razumije odakle dolaze podaci i što predstavljaju), napredno poznavanje BI alata za analizu podataka (R, SPSS..) i alata za vizualizaciju podataka (SAP, Tableau, QlikView...). Mala i srednja poduzeća uglavnom nemaju svoje BI konzultante među zaposlenima pa koriste usluge vanjskih BI konzultanata. Osim znanja i iskustva BI stručnjaka, izrazito je važno da je BI konzultant dobro upućen u poslovanje poduzeća, njegove ciljeve i da dobro razumije poslovne procese unutar poduzeća. Danas su BI konzultanti jako popularni a ovisno na područje na koje su fokusirani i alate kojima se služe za analizu i vizualizaciju podataka koriste i različite nazive. Najpoznatiji nazivi/titule BI konzultanata su: BI Analyst, BI Developer, Oracle BI Consultant, SAP BI Consultant, BI Lead Data Consultant, Functional Consultant.⁴⁹

⁴⁹ Marinov V.:“The Job of a Business Intelligence Consultant“,freelancer magazine,2018, dostupno na: <https://www.freelancemap.com/freelancer-tips/12153-career-insights-business-intelligence-consultant>

Neizostavno se nameće pitanje, zašto bi neko poduzeće koristilo usluge vanjskih konzultanata umjesto da zaposli vlastitoga BI stručnjaka? Do prije dvadesetak godina rijetko je kojem poduzeću padalo na pamet da angažira vanjskog konzultanta za informacijsku tehnologiju. No danas je sasvim drugačija situacija a korištenje usluga vanjskih konzultanata je u porastu.

Korištenje usluga kako internih tako i eksternih konzultanata ima svoje prednosti i nedostatke.

Prednosti internih (unutarnjih) konzultanata se očituju u znanju unutarnjih osjetljivih pitanja, kulturnih normi i organizacijske povijesti. Posjeduju detaljno, praktično znanje o poslovanju, strategiji i kulturi organizacije, razumiju moći i politike, mreže odnosa u organizaciji, pojedinosti o učinjenome u prošlosti što malo koji vanjski konzultant može znati do toga stupnja kao unutarnji konzultant. Eksterni (vanjski) konzultanti se angažiraju zbog jedinstvenih i specijaliziranih znanja i vještina. Interni konzultanti imaju stvoren odnos (ponekad i osobni) s klijentima i kolegama s kojima blisko surađuju temeljen na povjerenju i vjerodostojnosti. Zbog prethodno navedenog, interni konzultanti imaju bolju sposobnost procjene i korištenja pravoga pristupa s kraćim vremenom uspona na novim projektima. Prednost je i njihovo sudjelovanje u životu organizacije što ih čini svjesnijima svakodnevnih poslovnih izazova, pitanja kupaca, upravljanja odlukama i djelovanja. Nakon završetka projekta, interni konzultant može pratiti napredak, identificirati izazove i prepreke, pokrenuti mjere i intervencije po potrebi, dok se vanjski konzultanti angažiraju i ulaze u sustav uglavnom na kratko vrijeme povodom provedbe određene intervencije/projekta te odlaze nakon što je projekt završen. Nedostatci internih konzultanata se očituju u diskutabilnoj neutralnosti i objektivnosti što može dovesti do nemogućnosti objektivnog sagledavanja problema. Ravnotežu između znanja o organizaciji i interesa kupca je ponekad jako teško održati. Interni se konzultanti često nalaze na srednjoj razini izvještavanja u poduzeću zbog manjka znanja i svjesnosti o njihovoj vrijednosti i vještinama. Oni se tako često susreću s barijerama u poslovanju na relaciji konzultant-klijent a osim toga ih se percipira kao podređene top menadžerima, a ne kao ključne „igrače/pomoćnike“ u prikupljanju informacija i donošenju odluka. S druge strane osjećaju pritisak od strane važnih klijenata koji od njih očekuju da opravdaju povjerenje, pokrenu nerealne projekte ili naprave neodgovarajuće promjene. Takvi izazovi i paradoksi stvaraju sukob i stres internim konzultantima koji nisu spremni na ovakve izazove.⁵⁰

⁵⁰ Scott B.:“Consulting on the Inside“,2008, str.2-4, dostupno na: <http://bevscott.com/bvs-content/uploads/2013/09/ASTD-Handbook-Consulting-on-the-Inside.pdf>

Prednosti eksternih (vanjskih) konzultanata su što ih poduzeće može angažirati na određeno vrijeme (trajanje projekta) jer im ostatak vremena nisu potrebni a tako visoko obučeni stručnjaci su prilično skupi kao stalni zaposlenici. Ako se njihove usluge koriste sustavno, periodično, poduzeće s vanjskim konzultantima gradi partnerski odnos. Konzultanti su upoznati s kulturom i ciljevima poduzeća te mogu savjetovati poduzeće o ažuriranju postojećeg informacijskoga sustava kao i novim tehnologijama i mogućnostima. Konzultantske tvrtke u svom portfelju imaju niz stručnjaka iz različitih područja informacijske tehnologije i znanjima različitih alata koje može ponuditi ovisno o potrebama klijenta. Posjeduju znanja i najnoviju tehnologiju koja brzo raste i zastarijeva. Konzultantsko poduzeće može ponuditi i popuste i posebne ponude za manja poduzeća. Korisnik tako smanjuje troškove održavanja skupe opreme i alata te edukacije zaposlenika.

Malo je poduzeća (naročito malih i srednjih) koje si mogu priuštiti sakupljanje takvih skupih resursa (opreme i ljudi) što je ključni razlog za korištenje usluga vanjskih konzultanata. Osim toga, vanjski konzultanti su objektivniji, „imaju pogled iz vani“, što je ponekad odlučujući faktor pri donošenju teških poslovnih odluka. Često poduzeća (klijenti) imaju svoju perspektivu o tome kako riješiti problem, ali angažiraju i vanjske konzultante kako bi bili sigurni u svoju odluku jer konzultanti imaju nepristran pogled. Vanjski konzultanti često rade s raznim poduzećima na rješavanju raznih pitanja/problema pa je moguće da imaju odgovarajuće iskustvo i znaju kako problem uspješno riješiti. Obzirom na stečeno iskustvo vanjski konzultanti često mogu donijeti inovativne ideje i predložiti moguće izazove koje samome poduzeću ne bi pale na pamet. Korištenjem usluga vanjskih konzultanata poduzeće uspostavlja fleksibilnost poslovanja jer brzo može reagirati na promjene bez dugoročnih financijskih obveza. Iako korištenje usluga vanjskih korisnika, na prvi pogled, iziskuje velike troškove, u konačnici se često više isplati nego zaposliti potrebne stručnjake.⁵¹

Brz napredak tehnologije je doveo do toga da poduzeća ne mogu poslovati bez korištenja informacijske tehnologije. Prosječna osoba ima samo djelić potrebnog znanja za uspješno upravljanje informacijskom tehnologijom pomoću koje se prikupljaju podaci a još manje ih posjeduje znanja korištenja alata za obradu, analizu i vizualizaciju podataka. Suvremeni poslovni procesi zahtijevaju visoko obučene stručnjake u IT i BI području te korištenje skupih i još uvijek složenih alata.

⁵¹ Betts J.:“5 reasons why you should hire an external consultant“, 2016, dostupno na: <https://www.linkedin.com/pulse/5-reasons-why-you-should-hire-external-consultant-christiano-puglia>

Možda bi najbolja opcija za poduzeće bila kada bi postojala mogućnost suradnje internog i eksternog konzultanta. Znanje internog konzultanta o organizaciji, sustavu i procesima unutar nje u kombinaciji sa stručnim znanjima eksternoga konzultanta bi doprinijelo jačanju organizacije. Interni konzultant bi mogao djelovati i kao širitelj znanja, stručnosti i najsuvremenijih koncepata integrirajući ih u kulturu organizacije kroz svoj svakodnevni rad. Oni, kao poznavatelji poslovanja iznutra, mogu djelovati kao katalizator promjena u poduzeću.⁵²

5. EMPIRIJSKO ISTRAŽIVANJE IZGRADNJE INDIKATORA POSLOVNE INTELIGENCIJE NA TEMELJU POSLOVNIH POTREBA

5.1. Uzorak i istraživački instrument

Primjer izgradnje indikatora poslovne inteligencije će se prikazati na temelju poslovanja javne uprave odnosno e-vlade (eGovernmenta).

Razvoj tehnologije omogućuje vladi da svoje usluge pruža građanima i poslovnom sektoru brže, jeftinije, pouzdanije, jednom riječju efektivnije i efikasnije. E-javna uprava potencijalno povećava socijalni i gospodarski razvoj zemalja omogućavanjem boljeg pristupa državnim službama. Primjerice, pružajući brži i bolji pristup informacijama, usluge online obrade zahtjeva za dozvole, plaćanja, potvrde... Upotreba tehnologije omogućuje zaposlenicima veću produktivnost rada, učinkovitije poslovne procese i slično. Razvoj eGovernmenta nije jednostavan posao. Europska komisija je postavila „Akcijski plan za e-Vladu 2016-2020“ s ciljem digitalne transformacije vlasti kao ključnim elementom uspjeha jedinstvenoga tržišta. Akcijski plan ima za cilj modernizirati javnu upravu, digitalizirati unutarnje tržište te unaprijediti isporuku kvalitetnih usluga građanima i tvrtkama. Akcijski plan (eGovernment Action Plan 2016-2020) identificira 3 prioriteta kako bi se ostvarila vizija:

1. Modernizaciju javne administracije pomoću ključnih digitalnih omogućitelja (eID, eSignature i sl.),

⁵² Scott B.: „Consulting on the Inside“, 2008, str.5, dostupno na: <http://bevscott.com/bvs-content/uploads/2013/09/ASTD-Handbook-Consulting-on-the-Inside.pdf>

2. Omogućavanje mobilnosti građana i poduzeća putem prekogranične interoperabilnosti,
3. Olakšavanje digitalne interakcije između javne uprave i građana/poduzeća.⁵³

Radom će se razmatrati treća točka za koju će biti postavljeno nekoliko KPI-a u svrhu praćenja i unapređenja digitalne interakcije između javne uprave i građana/poduzeća. Novo digitalno okruženje pruža priliku za olakšavanje interakcije građana, poslovnih i nevladinih organizacija s javnom upravom. Kvaliteta javne uprave je povezana s konkurentnošću i ima utjecaj na buduća ulaganja. Kvalitetne e-javne usluge (e-vlade) smanjuju birokraciju, olakšavaju korištenje usluga, smanjuju troškove. Otvaranjem podataka javna uprava povećava transparentnost, približava se građanima i potiče nove mogućnosti za stjecanje znanja, rast i radna mjesta.⁵⁴

Podaci na temelju kojih su formirani KPI su preuzeti iz Eurostat baza podataka. Podaci su sakupljeni anketiranjem u svakoj državi članici EU. Statistike moraju biti pouzdane i usporedive pa Europski statistički sustav (ESS) surađuje s Eurostatom, nacionalnim statističkim institutima (NSIs) i ostalim nacionalnim odgovornim autoritetima u zemljama članicama (u Hrvatskoj je to Državni zavod za statistiku).⁵⁵

Da bi ispitali postavljene hipoteze i istinitost tvrdnje da „postoji međuovisnost pravilno definiranog indikatora poslovne inteligencije i uspješnosti poslovanja“ koristit će se podaci iz Eurostat-ovih baza podataka te ispitati njihova međuovisnost. Istraživanje povezanosti podataka će se ispitati na uzorku od 28 zemalja članica Europske unije. Kao mjeru pravilnoga definiranja indikatora poslovne inteligencije će se koristiti podaci o postotku ICT (Information and Communication Technology) službenika u ukupnoj zaposlenosti, s obzirom da su to osobe koje imaju sposobnost i znanja razvijanja, upravljanja i održavanja ICT sustava. Veza koja se pronalazi u kvaliteti procesa izbora KPI-a za razvoj e-vlade i postotku ICT službenika u ukupnoj zaposlenosti se očituje u spoznaji da učinkovito upravljanje javnim sektorom zahtjeva korištenje ICT-a kako bi se postigla veća učinkovitost u funkcioniranju vlade i poboljšala isporuka javnih usluga pojedincima i organizacijama. Razvijene ekonomije su relativno napredne u korištenju ICT-a za poboljšanje funkcioniranja javnoga sektora i

⁵³ EU eGovernment Action Plan, dostupno na: <https://ec.europa.eu/digital-single-market/en/european-egovernment-action-plan-2016-2020>

⁵⁴ EU eGovernment Action Plan 2016-2020- Accelerating the digital transformation of government, str.9-11, dostupno na: <https://ec.europa.eu/digital-single-market/en/news/communication-eu-egovernment-action-plan-2016-2020-accelerating-digital-transformation>

⁵⁵ Eurostat, dostupno na: <http://ec.europa.eu/eurostat/web/european-statistical-system/overview>

pružanja usluga, odnosno prednjače u broju zaposlenih ICT stručnjaka u ukupnoj zaposlenosti. Da bi se moglo pratiti i uspoređivati status e-vlade, formulirati politike i strategije, potrebno je postaviti set mogućih, relevantnih i međunarodno usporedivih indikatora. Prikupljanje podataka za e-vladu je komplicirano i susreće se s nizom izazova mjerenja, primjerice statističkom izvedivosti, relevantnosti, troškovima prikupljanja podataka, opterećenjem ispitanika i sl. Stoga, ako se mjeri „udio ICT-a u vladinim organizacijama“, taj će omjer biti usporediv samo u zemljama koje imaju sličnu organizaciju vlade. Primjerice, ako zemlja A navodi 10 središnjih vladinih organizacija a zemlja B ih navodi 100, vjerojatno će omjer središnje države u zemlji A biti veći jer će veći, entiteti sigurno imati više ICT službenika od više manjih entiteta. Također postoje i strukturne razlike u funkcijama vladinih organizacija u različitim zemljama. Primjerice, željeznički promet u jednoj zemlji može biti funkcija opće vlade, a u drugoj odgovornost poslovnog (javnog ili privatnog) sektora. Većina vlada ima više razina vlasti (središnja, provincijska, regionalna, lokalna) pa tako promatran omjer „ICT službenika u vladinim organizacijama“ može dovesti do nevjerodostojnosti podataka.⁵⁶

Jedna od točaka koja se želi postići u okviru „eGovernment akcijskog plana 2016-2020“ je i transparentnost, otvorenost podataka. U nedostatku otvorenih/dostupnih kvalitetnijih podataka kojima bi se mjerila kvaliteta procesa izbora KPI kao npr. dostupnost i korištenje ICT u vladi i vladinim organizacijama, broj zaposlenih ICT stručnjaka u vladinim organizacijama i slično, u ovom radu će se kvaliteta procesa izbora KPI-a mjeriti udjelom ICT službenika u ukupnoj zaposlenosti (pojedinih država članica EU), koji je usporediv među državama. Naime, veći broj ICT službenika u ukupnoj zaposlenosti znači i kvalitetnije generiranje, sakupljanje i analizu podataka, veću dostupnost kvalitetnih podataka, što nadalje vodi ka lakšem, bržem i jeftinijem prikupljanju podataka te kvalitetnijim i vjerodostojnijim ključnim pokazateljima performansi. Kao što znamo, koliko god KPI bio dobro postavljen, on je beskoristan, ako podaci nisu kvalitetni i vjerodostojni te takav KPI može dati krive informacije i prouzročiti donošenje krive odluke.

⁵⁶Manual for measuring eGovernment, str.3/4, dostupno na: https://www.itu.int/en/ITU-D/Statistics/Documents/partnership/eGovernment_Manual_Final_2014.pdf

5.2. Analiza i rezultat istraživanja

Ovim radom se želi prikazati primjer i istražiti važnost, pravilno formiranog indikatora poslovne inteligencije. Zbog nedostatka otvorenih i dostupnih podataka o vladi i vladinim organizacijama kojima bi mogli usporediti kvalitetu procesa formiranja KPI u zemljama Europske unije, kvalitetu procesa izrade KPI-a će se mjeriti pomoću zaposlenih ICT stručnjaka. U trenutku kada se formiraju KPI, trebalo bi svaki pojedinačno detaljno definirati i obrazložiti da bi svim zaposlenicima bili potpuno jasni, pri čemu svaki KPI treba imati: ime, definiciju, naznačene metode prikupljanja podataka i koje podatke zahtijeva analiza, razvrstavanje podataka, formule, predložena pitanja modela, definiciju jedinica i pojmova, bilješke, uključujući opseg proširenja na druge razine vlasti, statistička pitanja i nacrt izvještaja statističkih standarda u svrhu međunarodnog izvještavanja.⁵⁷

Definiranje KPI-a izgrađenih za potrebe istraživanja:

KPI 1: Udio ICT stručnjaka u ukupnoj zaposlenosti države (top 3 države članice EU-28, Hrvatska i Slovenija)

Ime: % ICT stručnjaka u ukupnoj zaposlenosti države

Definicija indikatora: Udio stručnjaka informacijske i komunikacijske tehnologije u ukupnoj zaposlenosti u pojedinim zemljama Europske unije. Promatraju se prve tri zemlje članice EU po broju zaposlenih ICT stručnjaka. Postotak ICT stručnjaka u ukupnoj zaposlenosti po pojedinoj zemlji će se dobiti tako što će se broj zaposlenih u ICT-u (pojedine zemlje) podijeliti s ukupnim brojem zaposlenih (iste zemlje). Dobiveni broj će se pomnožiti sa 100 da bi se dobio postotak zaposlenih ICT stručnjaka u ukupnoj zaposlenosti.

Metode prikupljanja podataka: anketiranjem od strane državnih institucija pojedine zemlje, odnosno preuzimanje statističkih podataka iz Eurostat baze podataka.

Potrebni podaci: ICTuz - ukupno zaposleni u ICT, UZ-broj ukupno zaposlenih u zemlji

Razvrstavanje podataka: Pokazatelj je razvrstan po godinama i zemljama. Razmatra se 2016 godina te tri zemlje s najvišim udjelom ICT stručnjaka u ukupnoj zaposlenosti. Može se prikazati u postotku i u tisućama zaposlenih. Mjeri se na godišnjoj razini.

⁵⁷ Framework for a set of e-government core indicators, str.18, dostupno na: https://www.itu.int/en/ITU-D/Statistics/Documents/partnership/Framework_for_a_set_of_E-Government_Core_Indicators_Final_rev1.pdf

Formula: $KPI1 = (ICT_{uz} / UZ) * 100$

Predložena pitanja modela: Koliko je ukupno zaposlenih (u nekoj državi) u (nekoj) godini? Koliko je u toj godini zaposlenih ICT stručnjaka? Koliki je udio ICT stručnjaka u ukupnoj zaposlenosti u (određenoj) godini?

Definicija jedinica i pojmova: Stručnjaci informacijske i komunikacijske tehnologije su specijalisti koji imaju mogućnosti i znanja za razvoj, upravljanje i održavanje ICT sistema i kojima je to osnovni dio posla. Računaju se zaposleni stručnjaci u ukupnoj zaposlenosti, javnom i privatnom sektoru.

Bilješke: Potrebno je naznačiti datum (početak i kraj) prikupljanja podataka, naročito u međunarodnome izvješćivanju. Moguće je proširiti analizu, razvrstati zaposlene po spolu, stupnju edukacije, po županijama i slično.

KPI 2: Postotak poduzeća koja smatraju da broj procedura (u toj zemlji) nije prepreka za pokretanje poslovanja (2016) u top 3 zemlje članice EU, Hrvatskoj i Sloveniji

Ime: % poduzeća zadovoljnih brojem procedura (u toj zemlji) za pokretanje poslovanja

Definicija indikatora: Postotak poduzeća (pojedine zemlje) koja smatraju da broj administrativnih procedura (u toj zemlji) nije prepreka za pokretanje novoga poslovanja. Postotak „zadovoljnih“ poduzeća će se mjeriti tako što će se broj poduzeća koja su u anketi odgovorili da broj procedura nije prepreka pokretanju novog poslovanja podijeliti s ukupnim brojem ispitanih poduzeća. Dobiveni rezultat će se pomnožiti sa 100 da bi se dobio postotak zadovoljnih poduzeća. Promatrati će se tri zemlje članice s najvišim stupnjem zadovoljstva, Hrvatska i Slovenija.

Metode prikupljanja podataka: podaci se prikupljaju anketiranjem od strane državnih institucija (pojedine zemlje) koji se bave ispitivanjima i statističkom obradom podataka. U ovom slučaju, podaci su preuzeti od Eurostat-a.

Potrebni podaci: PBPnp- broj poduzeća koji smatraju da broj procedura (u toj zemlji) nisu prepreka pokretanju startup-a, PBPuk- ukupan broj ispitanih poduzeća

Razvrstavanje podataka: Pokazatelj je razvrstan po godinama. Razmatra se 2016. Godina. Može se prikazati u postotku i tisućama poduzeća. Mjeri se na godišnjoj razini.

Formula: $KPI2 = (PBPnp/PBPuk) * 100$ za svaku zemlju članicu EU

Predložena pitanja modela: Koliko je ukupno zadovoljnih poduzeća, odnosno onih poduzeća koja smatraju da broj administrativnih procedura nije prepreka za pokretanje startup-a? Koliko je nezadovoljnih poduzeća? Koliko je poduzeća koja ne znaju odgovor?

Definicija jedinica i pojmova: Poduzeća koja su uključena u istraživanje su mala i srednja poduzeća osnovana u periodu kada su napravljene zadnje izmjene broja procedura (ovisno o pojedinoj zemlji). Broj procedura je broj administrativnih postupaka potrebnih da bi se osnovalo novo poduzeće.

Bilješke: Potrebno je naznačiti datum (početak i kraj) prikupljanja podataka, naročito u međunarodnom izvješćivanju.

KPI 3: Postotak poduzeća koja smatraju da trošak procedura (u toj zemlji) nije prepreka za pokretanje poslovanja (2016) u top 3 zemlje članice EU, Hrvatskoj i Sloveniji

Ime: % poduzeća zadovoljnih troškom procedura (u toj zemlji) za pokretanje poslovanja

Definicija indikatora: Postotak poduzeća (pojedine zemlje) koja smatraju da trošak administrativnih postupaka (u toj zemlji) nije prepreka za pokretanje novoga poslovanja. Promatraju se top 3 zemlje po zadovoljstvu, Hrvatska i Slovenija. Postotak „zadovoljnih“ poduzeća će se mjeriti tako da se broj poduzeća koja su u anketi odgovorila da trošak procedura nije prepreka pokretanju novog poslovanja, podijeli s ukupnim brojem ispitanih poduzeća. Dobiveni rezultat će se pomnožiti sa 100 da bi se dobio postotak zadovoljnih poduzeća.

Metode prikupljanja podataka: podaci se prikupljaju anketiranjem od strane državnih institucija (pojedine zemlje) koji se bave ispitivanjem i statističkom obradom podataka. U ovom slučaju, podaci su preuzeti od Eurostat-a.

Potrebni podaci: PTPnp- broj poduzeća koji smatraju da trošak procedura (u toj zemlji) nije prepreka pokretanju startup-a, PTPuk- ukupan broj ispitanih poduzeća

Razvrstavanje podataka: Pokazatelj je razvrstan po godinama. Razmatra se 2016. godina. Može se prikazati u postotku i tisućama poduzeća. Mjeri se na godišnjoj razini.

Formula: $KPI3 = (PTPnp/PTPuk) * 100$ za svaku zemlju članicu EU

Predložena pitanja modela: Koliko je ukupno zadovoljnih poduzeća, odnosno onih poduzeća koja smatraju da trošak administrativnih postupaka nije prepreka za pokretanje poslovanja? Koliko je nezadovoljnih poduzeća? Koliko je neopredijeljenih poduzeća (koja ne znaju odgovor)?

Definicija jedinica i pojmova: Poduzeća koja su uključena u istraživanje su mala i srednja poduzeća osnovana u periodu kada su napravljene zadnje izmjene broja procedura (ovisno o pojedinoj zemlji). Trošak procedura je trošak administrativnih postupaka potrebnih da bi se osnovalo novo poduzeće.

Bilješke: Potrebno je naznačiti datum (početak i kraj) prikupljanja podataka, naročito u međunarodnom izvješćivanju.

Zbog nemogućnosti da se ovim radom obuhvate sve točke akcijskoga plana i napravi šire istraživanje, formirat će se nekoliko ključnih pokazatelja za točku 3. akcijskoga plana: „olakšavanje digitalne interakcije između javne uprave i građana/poduzeća“.

Istraživanje će se orijentirati na interakciju javne uprave i poduzeća.


Za ekonomski napredak i rast gospodarstva neke zemlje potrebno je otvaranje novih poduzeća, investicije. Najčešća ograničenja predstavlja birokracija (sporost, količina i troškovi procedura) koja odbija investitore i koči pokretanje poslovanja. Za pomoć pri rješavanju toga problema javne uprave, formirana su dva KPI-a (KPI 2 i 3). Indikatorima će se pratiti kretanje zadovoljstva poduzeća uslugom javne uprave u svrhu donošenja ispravnih odluka o olakšavanju procedure, odnosno unapređenju poslovnih procesa i poslovanja u cjelini.

Podaci, analiza i vizualizacija KPI 1 je preuzeta od Eurostata⁵⁸, dok su podaci za KPI 2 i 3 preuzeti također iz Eurostat baze podataka u obliku Excel tablice⁵⁹, te su isti obrađeni i analizirani. Napravljena je vizualizacija podataka (dashboard) u alatu za poslovnu inteligenciju SAP. Pristup alatu, za potrebe ovoga rada, omogućila je BI kompanija DatArt SA.

⁵⁸ Eurostat, http://ec.europa.eu/eurostat/statistics-explained/index.php?title=ICT_specialists_in_employment

⁵⁹ Eurostat, https://data.europa.eu/euodp/data/dataset/S2089_417_ENG

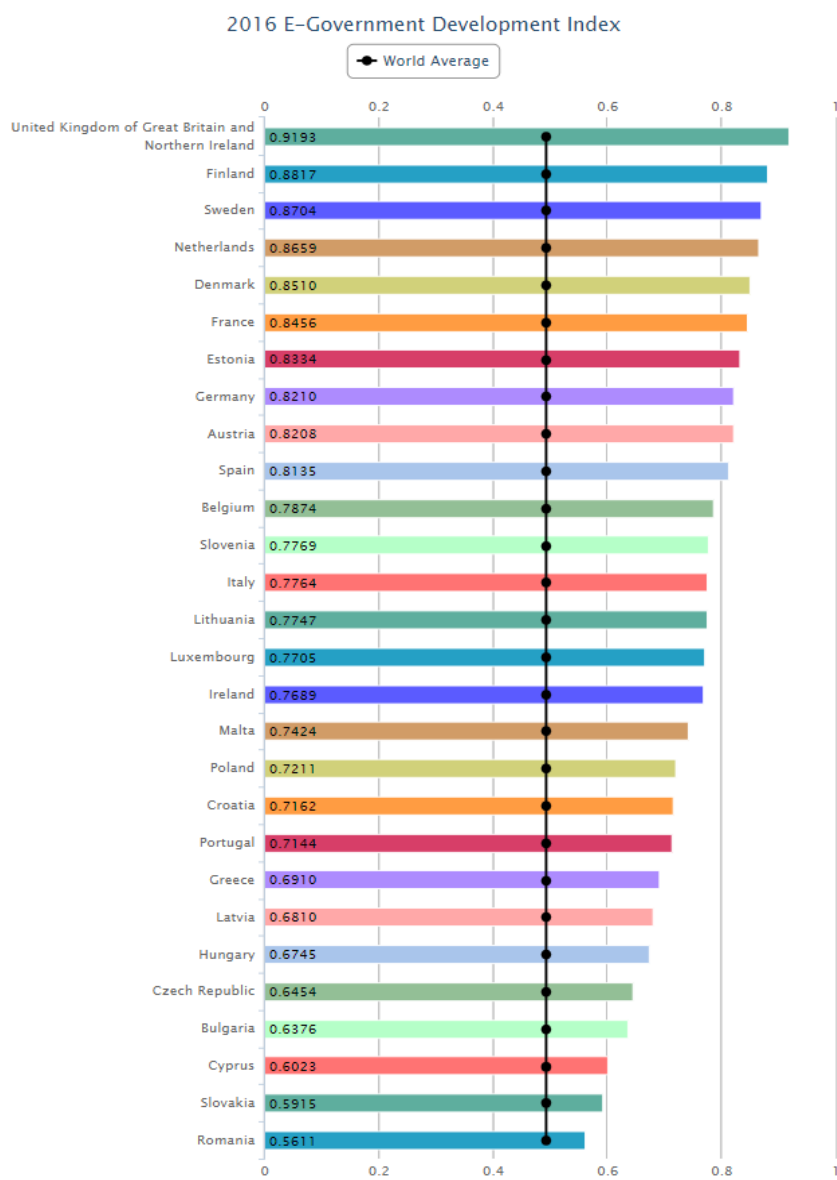
KPI 1- Udio ICT stručnjaka u ukupnoj zaposlenosti (2016)



Grafikon 2. Stupčasti grafikon, prikaz top 3 zemlje članice EU, Hrvatske i Slovenije, po udjelu ICT stručnjaka u ukupnoj zaposlenosti

Izvor: Eurostat, http://ec.europa.eu/eurostat/statistics-explained/index.php?title=ICT_specialists_in_employment

Iz stupčastoga dijagrama kojim je prikazan KPI 1 je vidljivo da najviši udio ICT stručnjaka u ukupnoj zaposlenosti 2016. godine imaju Finska (6,6%), Švedska (6,3%) i Estonija (5,3%) koje daleko nadmašuju udio zaposlenih ICT stručnjaka u EU (prosjeak zaposlenih u svim zemljama članicama) od 3,7%.




Grafikon 3. Indeks razvijenosti E-Governmenta u 28 zemalja članica EU

Izvor: UN E-Government Knowledge DataBase, 2016 E-Government Development Index, dostupno na: <https://publicadministration.un.org/egovkb/en-us/Data/Compare-Countries>

Prema istraživanju, zemlje s najvećim udjelom zaposlenih ICT stručnjaka u ukupnoj zaposlenosti su i zemlje s najvišim indeksom razvijenosti e-javne uprave (2016.god.) po UN-ovim izvješću, a što je vidljivo na grafikonu 2.i 3.⁶⁰

⁶⁰ UN E-Government Knowledge DataBase, 2016 E-Government Development Index, dostupno na: <https://publicadministration.un.org/egovkb/en-us/Data/Compare-Countries>

KPI 1- Udio ICT stručnjaka u ukupnoj zaposlenosti EU-28 (2016)




Grafikon 4. Linijski grafikon kretanja udjela zaposlenih ICT stručnjaka i ukupne zaposlenosti u zemljama EU po godinama

Izvor: Eurostat, http://ec.europa.eu/eurostat/statistics-explained/index.php?title=ICT_specialists_in_employment

Linijski grafikon prikazuje porast ukupne zaposlenosti u 28 zemalja članica EU za 3,6% u razdoblju od 2006.-2016., dok je porast zaposlenih ICT stručnjaka u istom razdoblju iznosio 39,5%. Vidljivo je da je rast zaposlenih ICT-ovaca 10 puta veći nego rast ukupne zaposlenosti, u promatranom periodu.

KPI 2- Postotak poduzeća koja smatraju da broj procedura (u toj zemlji) nije prepreka za pokretanje poslovanja (2016)




Grafikon 5. Top 3 zemlje u kojima broj procedura nije ograničenje za pokretanje poslovanja (usporedba s Hrvatskom i Slovenijom)

Izvor: Izvor: SAP alat za nalizu podataka, izrada autorice rada

Iz stupčastog grafikona 5. je vidljivo da je najveći postotak poduzeća koji misle da broj procedura u njihovoj državi nije ograničenje za pokretanje poslovanja u Estoniji (71%), potom u Švedskoj (55%) te Finskoj (51%). U Sloveniji 46% poduzeća smatra da broj procedura nije ograničenje a u Hrvatskoj tek 20% poduzeća misli to isto.

KPI 3 - Postotak poduzeća koja smatraju da trošak procedura (u toj zemlji) nije prepreka za pokretanje poslovanja (2016)



Grafikon 6.- Top 3 zemlje u kojima trošak procedura nije ograničenje za pokretanje poslovanja (usporedba sa Hrvatskom i Slovenijom)

Izvor: SAP alat za nalizu podataka, izrada autorice rada

Iz grafikona 6. je vidljivo da najviše poduzeća u Estoniji (73%) misli kako trošak procedura nije ograničenje za pokretanje poslovanja, potom slijedi Švedska (59%) te Finska (57%). U Sloveniji 51% posto smatra kako troškovi ne predstavljaju ograničenje a u Hrvatskoj njih tek (36%).

U ovom radu su formirani KPI kojima se mjeri kretanje postotka zadovoljnih poduzeća u top 3 zemlje po zadovoljstvu poduzeća javnom upravom, Hrvatskoj i Sloveniji. Opći izvještaj kao i izvještaj po zemljama za sve zemlje članice EU-28 je dostupan na stranicama Eurobarometra.⁶¹

⁶¹ European Commission, izvještaj po zemljama:
<http://ec.europa.eu/COMMFrontOffice/publicopinion/index.cfm/Survey/getSurveyDetail/instruments/FLASH/surveyKy/2089>, te opći izvještaj:
<http://ec.europa.eu/commfrontoffice/publicopinion/index.cfm/ResultDoc/download/DocumentKy/72225>

KPI ne daju odgovore što raditi niti BI stručnjaci savjetuju vodstvo poduzeća koje odluke bi trebali donijeti. KPI služe da iz velikog broja podataka koji zapisani u (npr. excel) tablici ne znače mnogo, jer se iz njih ne može baš puno iščitati, sažeto i jasno prikažu stanje i kretanje tako da svima stanje bude na prvi pogled jasno. Prikaz na dashboardu omogućuje drill-down podataka, odnosno da se klikom na pojedini podatak dobiju detaljniji podaci niže razine. Isto tako, postoji i mogućnost roll-up podataka, odnosno da se klikom na podatak najniže razine detaljnosti dobije općenitiji podatak-ovisno o potrebama.

Cilj rada je istražiti postoji li ovisnost kvalitete procesa izbora KPI-a i poslovnih procesa odnosno poslovanja. Zbog specifičnosti i kompleksnosti javne uprave, poslovnih procesa od kojih se sastoji i poslovanja uopće, ova će analiza razmatrati dio treće točke akcijskoga plana (interakciju javne uprave i poduzeća) kao cjelokupno poslovanje za koje će se formirati ključni indikatori performansi. Procedure koje čine interakciju poduzeća i javne uprave će se razmatrati kao poslovni proces. Postotkom poduzeća kojima broj potrebnih procedura za pokretanje poslovanja nije ograničenje će se mjeriti uspješnost poslovnih procesa javne uprave a cilj postavljanja KPI-a je povećanje postotka takvih poduzeća.

Trošak procedura za pokretanje poslovanja odnosno postotak poduzeća koji trošak procedura ne smatraju ograničavajućim za pokretanje startup-a će se koristiti kao mjera uspješnosti poslovanja (ovog dijela javne uprave). Manji trošak procedura znači veću interakciju s javnom upravom i lakše pokretanje poslovanja što čini poslovanje javne uprave uspješnom. Iz postavljenih KPI-a je vidljivo da zemlje koje imaju najviši postotak zaposlenih ICT stručnjaka u ukupnom poslovanju imaju i najviši postotak poduzeća koja smatraju da broj procedura i njihov trošak nisu ograničenje za pokretanje posla. To se poklapa s tvrdnjama u teoriji⁶² da zemlje s razvijenijim ICT-om imaju razvijeniju ekonomiju. Najveći broj zaposlenih ICT stručnjaka u ukupnoj zaposlenosti imaju redom: Finska, Švedska, Estonija itd., a te iste zemlje spadaju u „top 3“ u prikazu KPI-a 2 i 3, iz čega bi se moglo zaključiti da su to zemlje s najbolje i najuspješnije razvijenim eGovernmentom, čiju bi praksu mogle slijediti i ostale članice EU. Iako i kod tih zemalja ima prostora za napredak jer 40% poduzeća u navedenim trima zemljama broj procedura i njihov trošak smatra ograničenjem za pokretanje novoga posla. Stoga bi možda KPI za narednu godinu mogao biti: smanjenje procedura za pokretanje startup-a za 5%.

⁶² Kwang T.W.: „The impact of ICT on the global economy“, časopis eGovinnovation (2005), dostupno na: <https://www.enterpriseinnovation.net/article/impact-ict-global-economy-1388124773>

5.3. Testiranje hipoteza

Testiranje hipoteza je statistički postupak kojim se određuje dali i koliko pouzdano raspoloživi podaci iz reprezentativnog uzorka podupiru pretpostavljenu pretpostavku.⁶³

Formiranjem KPI-a i analizom dobivenih rezultata zaključeno je kako postoji veza između pravilno definiranog KPI-a i poslovnih procesa te poslovanja u cjelini. Pokazalo se da su zemlje s najvišim postotkom zaposlenih stručnjaka informacijske i komunikacijske tehnologije (ICT) u ukupnoj zaposlenosti iste one zemlje u kojima je poslovni sektor najzadovoljniji interakcijom s javnom upravom. U svrhu statističkog dokazivanja tih tvrdnji u radu su postavljene hipoteze koje će se testirati u SPSS alatu za statističku analizu podataka. Postavljene u tri hipoteze odnosno glavna hipoteza H1 te dvije pomoćne hipoteze H1.1 i H1.2.

Odnosi među varijablama mogu biti:

Korelacijski - kada promjena stanja jedne varijable prati promjenu druge varijable, a da ta prva varijabla nije uzrok drugoj

Uzročno-posljedični – kada je promjena jedne varijable uzrok nastajanja druge varijable ili promjena u njoj.

Da bi se utvrdila relacija među varijablama najprije će se izračunati njihova korelacijska povezanost putem linearne korelacije. Potom će se regresijskom analizom, analizirati njihova uzročno-posljedična povezanost.

Hipoteza H1.1: Postoji međuovisnost kvalitete procesa izbora ključnog indikatora poslovne inteligencije i performansi poslovnog procesa.

Kvaliteta procesa izbora ključnog indikatora poslovne inteligencije se mjeri % ICT stručnjaka u ukupnoj zaposlenosti pojedine zemlje članice EU. Performanse poslovnog procesa se mjere pomoću postotka poduzeća (pojedine zemlje) koji broj procedura (u toj zemlji) ne smatraju preprekom za pokretanje poslovanja.


⁶³ Pivac S.:“Statističke metode“, e-nastavni materijal (2010), EFST, str.121, dostupno na: <https://www.bib.irb.hr/933520>

Tablica 2. Korelacija između %ICT stručnjaka u ukupnoj zaposlenosti i % poduzeća koja smatraju da broj procedura javne uprave nije prepreka za pokretanje poslovanja

| | | %ICT inEmpl |
|-----------------------------|---------------------|-------------|
| BrP-Total 'Not an obstacle' | Pearson Correlation | ,639** |
| | Sig. (2-tailed) | ,000 |
| | N | 28 |
| %ICT inEmpl | Pearson Correlation | 1 |
| | Sig. (2-tailed) | |
| | N | 28 |

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Pearsonov koeficijent korelacije iznosi 0,639 što znači da postoji pozitivna i relativno jaka povezanost ova dva parametra. Empirijska signifikantnost koeficijenta korelacije iznosi $\alpha \approx 0\%$ što je manje od 1% i znači da je **statistički značajan**.



Grafikon 7. Dijagram rasipanja između varijable x i y

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Grafikonom 7. je prikazan dijagram rasipanja varijabli x (postotak ICT stručnjaka u ukupnoj zaposlenosti) i y (% poduzeća koja smatraju da broj procedura nije ograničenje za pokretanje poslovanja) s ucrtanom linijom pravca da bi se vidjela odstupanja od linije i protumačila veza između točaka.

Linearnom korelacijom je potvrđena pozitivna veza između varijabli uz 95% pouzdanosti. Povećanje % ICT stručnjaka u ukupnoj zaposlenosti prati povećanje % poduzeća koja smatraju da broj procedura (u toj zemlji) nije prepreka pokretanju poslovanja.

Postojanje uzročno-posljedične veze među varijablama će se ispitati pomoću linearne regresijske analize.

Tablica 3. Značajnost regresijskog modela

| ANOVA ^a | | | | | | |
|--------------------|------------|----------------|----|-------------|--------|-------------------|
| Model | | Sum of Squares | df | Mean Square | F | Sig. |
| 1 | Regression | 2640,350 | 1 | 2640,350 | 17,944 | ,000 ^b |
| | Residual | 3825,757 | 26 | 147,145 | | |
| | Total | 6466,107 | 27 | | | |

a. Dependent Variable: Br.Proc-Not an obstacle

b. Predictors: (Constant), %ICT inEmpl

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Prema tablici ANOVA, empirijska signifikantnost modela je na razini signifikantnosti od 1% ($p < 0.01$). Može se zaključiti da % ICT stručnjaka u ukupnoj zaposlenosti utječe na % zadovoljnih poduzeća, koji smatraju da broj procedura nije prepreka pokretanju poslovanja. Potvrđuje se da je ocijenjeni regresijski model **statistički značajan** uz signifikantnost testa od 1%.

Tablica 4. Vrijednosti ocijenjenih parametara linearne regresije

| Coefficients ^a | | | | | | | | | | |
|---------------------------|-------------|-----------------------------|------------|---------------------------|-------|------|---------------------------------|-------------|-------------------------|-------|
| Model | | Unstandardized Coefficients | | Standardized Coefficients | t | Sig. | 95,0% Confidence Interval for B | | Collinearity Statistics | |
| | | B | Std. Error | Beta | | | Lower Bound | Upper Bound | Tolerance | VIF |
| 1 | (Constant) | 3,473 | 7,074 | | ,491 | ,628 | -11,068 | 18,014 | | |
| | %ICT inEmpl | 7,875 | 1,859 | ,639 | 4,236 | ,000 | 4,053 | 11,696 | 1,000 | 1,000 |

a. Dependent Variable: Br.Proc-Not an obstacle

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Empirijska signifikantnost testa je $\alpha^*=0\%$, što je manje od 1%. Može se donijeti zaključak da je ocijenjeni regresijski parametar **statistički značajan**. Udio ICT stručnjaka u ukupnoj zaposlenosti ima statistički značajan utjecaj na % poduzeća koji smatraju da broj procedura javne uprave nisu prepreka za pokretanje poslovanja.

Postojanje kolinearnosti se može iščitati iz faktora inflacije varijance (VIF) i TOL-a.

VIF= 1,0 < 5 te TOL= 1 > 0,2. Zaključak je da **ne postoji** problem **kolinearnosti**.

Tablica 5. Osnovni podaci o ocijenjenom modelu


| Model Summary ^b | | | | | |
|----------------------------|-------------------|----------|-------------------|----------------------------|---------------|
| Model | R | R Square | Adjusted R Square | Std. Error of the Estimate | Durbin-Watson |
| 1 | ,639 ^a | ,408 | ,386 | 12,130 | 1,334 |

a. Predictors: (Constant), %ICT inEmpl

b. Dependent Variable: BrP-Total 'Not an obstacle'

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Problem autokorelacije reziduala je testiran Durbin-Watson testom koji iznosi 1,334, i ukazuje na to da **ne postoji** problema **autokorelacije** u modelu.




Grafikon 8. Histogram standardiziranih reziduala

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Histogramom standardiziranih reziduala se utvrđuje jesu li reziduali normalno distribuirani. Iz grafikona 8. je vidljivo da reziduali jesu normalno distribuirani.

Isto je vidljivo i iz grafikona 9. gdje su ucrtane vrijednosti opaženih i očekivanih vjerojatnosti, kada bi reziduali bili normalno distribuirani. Pretpostavku o normalnosti reziduala potvrđuje i funkcija distribucije opaženih vjerojatnosti, koja gotovo ne odstupa od očekivane funkcije vjerojatnosti kada bi rezidualna odstupanja bila normalno distribuirana (dijagonalna linija na grafikonu).



Grafikon 9. Grafikon normalno distribuiranih reziduala

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Pomoću neparametrijskog testa, Spearmanovog koeficijenta korelacije ranga će se testirati problem heteroskedastičnosti varijance reziduala. Testira se korelacija između apsolutnih vrijednosti reziduala i regresorskih varijabli.

Tablica 6. Spearmanov koeficijent korelacije između apsolutnih reziduala i regresorske varijable

| Correlations | | | BrP-Total 'Not an obstacle' | absres |
|----------------|-----------------------------|-------------------------|-----------------------------|--------|
| Spearman's rho | %ICT inEmpl | Correlation Coefficient | ,521** | -,190 |
| | | Sig. (2-tailed) | ,004 | ,332 |
| | | N | 28 | 28 |
| | BrP-Total 'Not an obstacle' | Correlation Coefficient | 1,000 | -,112 |
| | | Sig. (2-tailed) | . | ,572 |
| | | N | 28 | 28 |

** . Correlation is significant at the 0.01 level (2-tailed).

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Empirijska signifikantnost koeficijenta korelacije $\alpha^*1 = 0,332 > 5\%$ i $\alpha^*2 = 0,572 > 5\%$, pa se može zaključiti da u oba slučaja koeficijent korelacije nije statistički značajan. To znači da u ocijenjenom modelu **ne postoji** problem **heteroskedastičnosti** varijance reziduala.

Temeljem prethodnih rezultata istraživanja, hipoteza **H1.1 se prihvaća**.

Hipoteza H1.2: Postoji međuovisnost kvalitete procesa izbora ključnog indikatora poslovne inteligencije i performansi poslovanja.


Kvaliteta procesa izbora ključnog indikatora poslovne inteligencije se mjeri pomoću % ICT stručnjaka u ukupnoj zaposlenosti pojedine zemlje članice EU. Performanse poslovanja se mjere pomoću postotka poduzeća (pojedine zemlje EU) koji troškove procedura (u toj zemlji) ne smatraju preprekom za pokretanje startup-a.

Tablica 7. Korelacija između % ICT stručnjaka u ukupnoj zaposlenosti i % poduzeća koja smatraju da troškovi procedura javne uprave nisu prepreka u pokretanju poslovanja

| | | TrP-Total 'Not an obstacle' |
|-----------------------------|---------------------|-----------------------------|
| %ICT inEmpl | Pearson Correlation | ,581 ** |
| | Sig. (2-tailed) | ,001 |
| | N | 28 |
| TrP-Total 'Not an obstacle' | Pearson Correlation | 1 |
| | Sig. (2-tailed) | |
| | N | 28 |

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Pearsonov koeficijent korelacije iznosi 0,581 što pokazuje da postoji pozitivna i relativno jaka povezanost ovih dvaju parametra. Empirijska signifikantnost koeficijenta korelacije iznosi $\alpha \approx 0\%$ što je manje od 1% i znači da je **statistički značajan**.



Grafikon 10. Dijagram rasipanja između varijable x i y

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Na grafikonu 10., linearne korelacije, se vidi pozitivna linearna povezanost između % ICT stručnjaka u ukupnoj zaposlenosti i % poduzeća koja smatraju da trošak procedura (u toj zemlji) nije prepreka pokretanju poslovanja uz 95% pouzdanosti.

Tablica 8. Značajnost regresijskog modela

| Model | Sum of Squares | df | Mean Square | F | Sig. |
|--------------|----------------|----|-------------|--------|-------------------|
| 1 Regression | 2300,822 | 1 | 2300,822 | 13,246 | ,001 ^b |
| 1 Residual | 4516,178 | 26 | 173,699 | | |
| Total | 6817,000 | 27 | | | |

a. Dependent Variable: Tr.Proc.-Not an obstacle

b. Predictors: (Constant), %ICT inEmpl

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Empirijska signifikantnost modela teži ka nuli, $\alpha^*=0,001$, odnosno $\alpha^* < 1\%$ čime se potvrđuje da je regresijski model **statistički značajan**. Može se zaključiti da % ICT stručnjaka u ukupnoj zaposlenosti utječe na % zadovoljnih poduzeća koji smatraju da trošak procedura nije prepreka pokretanju startup poduzeća.

Tablica 9. Vrijednosti ocijenjenih parametara linearne regresije

| Model | | Unstandardized Coefficients | | Standardized Coefficients | t | Sig. | 95,0% Confidence Interval for B | | Collinearity Statistics | |
|-------|-------------|-----------------------------|------------|---------------------------|-------|------|---------------------------------|-------------|-------------------------|-------|
| | | B | Std. Error | Beta | | | Lower Bound | Upper Bound | Tolerance | VIF |
| 1 | (Constant) | 12,037 | 7,686 | | 1,566 | ,129 | -3,762 | 27,835 | | |
| | %ICT inEmpl | 7,351 | 2,020 | ,581 | 3,640 | ,001 | 3,199 | 11,503 | 1,000 | 1,000 |

a. Dependent Variable: Tr.Proc.-Not an obstacle

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Signifikantnost t-testa za parametar linearne regresije je na razini značajnosti od 1% ($p < 0.01$). Može se zaključiti da je ocijenjeni regresijski parametar **statistički značajan**. Odnosno da, % ICT stručnjaka u ukupnoj zaposlenosti statistički značajno utječe na % poduzeća koja smatraju da trošak procedura (u toj zemlji) nije prepreka za pokretanje poslovanja.

Vrijednosti faktora $VIF=1 < 5$ i $TOL=1 > 0,2$, ukazuju na **nepostojanje** problema **kolinearnosti**.

Tablica 10. Osnovni podaci o ocijenjenom modelu


| Model | R | R Square | Adjusted R Square | Std. Error of the Estimate | Durbin-Watson |
|-------|-------------------|----------|-------------------|----------------------------|---------------|
| 1 | ,581 ^a | ,338 | ,312 | 13,179 | 1,681 |

a. Predictors: (Constant), %ICT inEmpl

b. Dependent Variable: TrP-Total 'Not an obstacle'

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Problem autokorelacije reziduala je testiran Durbin-Watson testom koji iznosi 1,681 i ukazuje da **ne postoji** problema **autokorelacije** u modelu.




Grafikon 11. Histogram standardiziranih reziduala

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Iz histograma standardiziranih reziduala je vidljivo da su reziduali normalno distribuirani.

Isto je vidljivo i iz grafikona 12., gdje pretpostavku o normalnosti reziduala potvrđuje i funkcija distribucije opaženih vjerojatnosti, koja gotovo ne odstupa od očekivane funkcije vjerojatnosti kada bi rezidualna odstupanja bila normalno distribuirana (dijagonalna linija na grafikonu).



Grafikon 12. Grafikon normalno distribuiranih reziduala

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Spearmanovim koeficijentom korelacije ranga je testiran problem heteroskedastičnosti varijance reziduala.

Tablica 11. Spearmanov koeficijent korelacije između apsolutnih reziduala i regresorske varijable

| | | | Correlations | |
|----------------|-----------------------------|-------------------------|-----------------------------|--------|
| | | | TrP-Total 'Not an obstacle' | absres |
| Spearman's rho | %ICT inEmpl | Correlation Coefficient | ,521** | -,190 |
| | | Sig. (2-tailed) | ,005 | ,332 |
| | | N | 28 | 28 |
| | TrP-Total 'Not an obstacle' | Correlation Coefficient | 1,000 | -,118 |
| | | Sig. (2-tailed) | . | ,551 |

** . Correlation is significant at the 0.01 level (2-tailed).

Izvor: SPSS alat za analizu podataka, izrada autorice rada

Empirijska signifikantnost koeficijenta korelacije $\alpha^*1 = 0,332 > 5\%$ i $\alpha^*2 = 0,551 > 5\%$, te se može zaključiti da u oba slučaja koeficijent korelacije nije statistički značajan. U ocijenjenom modelu **ne postoji** problem **heteroskedastičnosti** varijance reziduala.

Temeljem prethodnih rezultata istraživanja, hipoteza **H1.2 se prihvća**.

Glavna hipoteza H1: Postoji međuovisnost pravilno definiranoga ključnog indikatora poslovne inteligencije i ostvarenja performansi poslovnih procesa te poslovanja u cjelini.

Pravilno definiran ključni indikator je mjeran postotkom zaposlenih ICT stručnjaka koji posjeduju znanja o korištenju podataka i tehnologije a ostvarenje performansi poslovnog procesa i poslovanja u cjelini je iskazan preko postotka zadovoljstva poduzeća javnom upravom (brojem i troškom procedura potrebnih za pokretanje poslovanja.)

Pri ispitivanju korelacije pravilno definiranoga KPI-a i ostvarenja performansi poslovnog procesa kao i kod korelacije pravilno definiranoga KPI-a i ostvarenja performansi poslovanja, empirijska signifikantnost koeficijenta korelacije iznosi približno nula ($\alpha \approx 0\%$) uz signifikantnost testa 1% što znači da je **koeficijent korelacije slučajnih varijabli statistički značajan**. Linearnom regresijom je dokazana uzročno-posljedična veza. Također, u oba slučaja **regresijski model je statistički značajan**. Pomoću dvije pohipoteze je dokazana glavna hipoteza.

Hipoteza H1 se prihvaća.

Stručnjaci posjeduju tehnološka znanja, znanja o podacima i njihovoj obradi, što dovodi do kvalitetno postavljenih KPI-a, pomoću kojih se prati napredak poslovanja i donose kvalitetnije odluke za unapređuje poslovanja. Iz prethodnih rezultata je vidljivo da se povećanjem broja zaposlenih ICT stručnjaka u ukupnoj zaposlenosti (neke zemlje), povećava i broj poduzeća zadovoljnih javnom upravom (u toj zemlji).

Zemlje EU-28, s većim postotkom zaposlenih ICT stručnjaka u ukupnoj zaposlenosti imaju i veći postotak poduzeća zadovoljnih interakcijom javne uprave i poduzeća.

6. ZAKLJUČAK

Poslovna inteligencija (BI) je pojam koji zbog svoje složenosti nema jedinstvenu definiciju. No svi se autori slažu po pitanju korisnosti i funkcije BI-ja. Koristi se za otkrivanje znanja skrivenih u mnoštvu podataka koji se nalaze unutar i izvan poduzeća. Uz pomoć alata poslovne inteligencije podaci se sakupljaju, obrađuju i pretvaraju u brze i točne informacije (u obliku jasnih i svima razumljivih izvještaja, vizualizacija) koje pomažu menadžmentu u donošenju ispravnih odluka, unapređenju poslovnih procesa i djelotvornijem upravljanju poslovanjem. U tu svrhu se definiraju ključni indikatori performansi (KPI). To su mjere usmjerene ka postavljenom cilju (bilo operativnom ili strateškom) poduzeća a čijim praćenjem poduzeće dobiva pregled smjera u kojemu se kreće. KPI pružaju tako menadžmentu brze i točne informacije koje služe da podupru donošenje ispravnih odluka. Ključne indikatore formiraju BI stručnjaci u suradnji s menadžmentom poduzeća, zbog čega je vrlo važno da stručnjaci razumiju poslovanje poduzeća za koje ih formiraju. Ne postoje univerzalni indikatori već se formiraju po potrebama poslovanja pojedinoga poduzeća. Upravo zbog tog individualnog pristupa i potrebe dubokog razumijevanja poslovanja poduzeća, formiranje pravilnog KPI nije jednostavan posao i zahtijeva vrijeme, stručnost i suradnju. Ovisno o KPI-u, prati se i izvještava u vremenskim intervalima (dnevno, polugodišnje, godišnje itd.). Predstavljaju se na nadzornim pločama (dashboard-ima) koji često uključuju grafikone i druge vizualizacije podataka, uz mogućnost detaljnije analize podataka (drill-down). Jednom stvoreni indikator treba sustavno pratiti i prilagođavati ovisno o promjenama u poslovanju. Sve je veća svijest poduzeća o korisnosti poslovne inteligencije i gotovo da ne postoji poduzeće koje ju, u nekom njenom obliku, ne koristi u poslovanju. No uvođenje sustava poslovne inteligencije je financijski izdašno. Troškovi se odnose na kupnju BI alata za baze podataka, upite, izvješća, softverske komponente, troškove održavanja, zaposlene stručnjake itd. Iz tog razloga neka čak i velika poduzeća pribjegavaju korištenju usluga eksternih BI stručnjaka odnosno BI poduzeća.

Ovim istraživanjem se željela ispitati ovisnost pravilno formiranog KPI-a i performansi poslovnih procesa te poslovanja u cjelini, na primjeru javne uprave (eGovernmenta). Kao mjera pravilnog formiranja KPI-a je korišten broj zaposlenih ICT stručnjaka u ukupnoj zaposlenosti pojedine zemlje članice EU. Kako bi se poboljšali proizvodi i optimizirali procesi, često se koriste KPI zadovoljstva korisnika. Pa je tako i u ovom istraživanju kao

mjera performansi poslovnog procesa korišten postotak poduzeća koja smatraju da broj potrebnih procedura nije prepreka za pokretanje startup-a. Kao mjera poslovanja je korišten postotak poduzeća koja smatraju da trošak procedura nije prepreka pokretanju startup-a. KPI su izgrađeni u SAP alatu za poslovnu inteligenciju a statistička analiza u SPSS-u. Istraživanjem je dokazana povezanost, odnosno pozitivna linearna korelacija između pravilno definiranoga indikatora poslovne inteligencije i ostvarenja performansi poslovnog procesa i poslovanja u cjelini. Drugim riječima, dokazano je da kvalitetno formiranje i praćenje ključnih indikatora poslovanja dovodi do unapređenja poslovnih procesa i poslovanja u cjelini. Zemlje koje imaju veći postotak zaposlenih ICT stručnjaka u ukupnoj zaposlenosti su zadovoljniji poslovnim procesima i poslovanjem e-javne uprave te zemlje. Također, zemlje koje prema istraživanju imaju najveći postotak ICT službenika u ukupnoj zaposlenosti spadaju u zemlje EU s najrazvijenijom e-javnom upravom, po UN indeksu razvijenosti eGovernmenta (2016). Na koncu možemo potvrditi teorijske tvrdnje o važnosti i korisnosti uvođenja i upotrebe poslovne inteligencije/KPI-a za unapređenje poslovnih procesa i poslovanja u cjelini. A svjedočimo porastu svjesnosti o važnosti poslovne inteligencije i analize podataka i u sportu. Naime, nogometna reprezentacija Hrvatske na svjetskom prvenstvu u Rusiji je postigla povijesni uspjeh, a u timu ima video analitičara koji s tribina prati i analizira protivnike, igru reprezentacije i taktičke pojedinosti tijekom utakmica. Povezan je video vezom s izborničkom klupom te direktno (GPS-om) prati i analizira sve aspekte igre. Analizira promjene u formaciji, pozicioniranost igrača, promjene kod suparnika. Ako je, primjerice, neki nogometaš izgubio više duela u nizu ili stoji gdje ne bi trebao i slično, te informacije šalje na klupu, a pomoću njih izbornik donosi odluke i korigira igru reprezentacije. Također prati važne fizičke komponente igrača poput, otkucaja, pretrčanih kilometara i ostalih parametara važnih da se igrači ne preforsiraju. Dotični analitičar, Marc Rochon, je izjavio:“Ja pomažem trenerima i donosim im informacije na temelju kojih oni odlučuju i pripremaju plan igre. Nakon utakmica, naglašavamo polja koja možemo poboljšati, a igrači su jako profesionalni i primaju savjete bez problema“.⁶⁴

⁶⁴ Net.hr, „Od škotskih garaža do nogometnog prvenstva: Upoznajte Dalićevo tajno oružje“, članak, dostupno na: <https://net.hr/sport/nogomet/od-skotskih-garaza-do-svjetskog-prvenstva-upoznajte-dalicevo-tajno-oruzje/>

SAŽETAK

Poslovna inteligencija i ključni indikatori performansi (KPI) se koriste za mjerenje performansi poslovnog procesa i poslovanja poduzeća a u cilju donošenja ispravnih odluka i unapređenja poslovanja. Razni autori govore o važnosti poslovne inteligencije i ključnih indikatora performansi za unapređenje, uspješnost poslovanja, postizanje konkurentske prednosti ali i samog opstanka poduzeća na današnjem globaliziranom tržištu. Radom se željela teorijski objasniti i u empirijskome dijelu ispitati važnost pravilnog formiranja KPI-a i njegovog utjecaja na poslovanje poduzeća. Odnosno ispitati utjecaj pravilnog formiranja ključnog indikatora performansi na unapređenje performansi poslovnih procesa i poslovanja, na primjeru eGovernmenta u 28 zemalja članica EU. Formiranjem KPI-a i statističkom analizom njihove međuovisnosti, dokazala se pozitivna linearna ovisnost parametara. Stoga se, na koncu, može potvrditi da je uvođenje sustava poslovne inteligencije u poduzeće i donošenje odluka pomoću ključnih pokazatelja, na temelju brzih i točnih informacija, iako financijski izdašno ipak isplativo. Poduzeća moraju moći pratiti današnji eksponencijalan razvoj ekonomije i tehnologije, brzo se prilagođavati i razvijati poslovanje. Nemaju vremena za dugo proučavanje i razmišljanje a još manje za intuitivne i pogrešne odluke, koje mogu značiti nestanak poduzeća.

Ključne riječi: poslovna inteligencija, ključni indikator performansi, javna uprava

SUMMARY

Business intelligence and key performance indicators (KPI) are used to measure performances of business processes and company business, to the end of making correct decisions and improving business. Many authors emphasize the importance of business intelligence and key performance indicators for business success and achieving market advantage, as well as company survival in the global market. This work is an attempt to both explain theoretically and study empirically the importance of proper KPI development and its influence on company business. We are studying the influence of properly formed key indicator performances on improving business process performances through the example of eGovernment in 28 EU member states. By forming the KPI and performing the statistical analysis of their relationship, a positive linear dependence of parameters has been proven. Therefore, it can be confirmed that introducing the business intelligence system in companies and introducing key indicators, based on quick and accurate information, into decision making process, although expensive, is still beneficial. Companies need to be able to follow the current exponential growth of the global economy and technology, adapt quickly and develop their business. There is no time for lengthy studies and considerations, and even less for intuitive and incorrect decisions, that can lead to company failure.

Keywords: Business Intelligence, Key Performance Indicator, E-Government

LITERATURA

Knjige:

1. Panian Ž, Klepac G (2003): Poslovna inteligencija, Zagreb, Masmedia
2. Javorović B, Bilandžić M (2007): Poslovne informacije i business intelligence, Zagreb, Golden marketing

Izvori s Interneta:

3. Analytics Bulgaria web site, dostupno na: <http://analytics.bg/en/business-analytics-2/bi-vs-ba/>
4. Bauer, K.: "KPIs- The Metrics That Drive Performance management" (2004), dostupno na:
<http://web.a.ebscohost.com.ezproxy.nsk.hr/ehost/pdfviewer/pdfviewer?vid=0&sid=7a872d03-b96e-4463-900c-46d55d9368ed%40sessionmgr4008>
5. Betts J.: "5 reasons why you should hire an external consultant", 2016, dostupno na: <https://www.linkedin.com/pulse/5-reasons-why-you-should-hire-external-consultant-christiano-puglia>
6. Brumec J. (2011): Modeliranje poslovnih procesa, Varaždin/Zagreb, dostupno na: <https://koris.hr/preuzmi/koris-uvod-u-modeliranje-poslovnih-procesa.pdf>
7. DatArt SA, web stranica, dostupno na: <http://www.datart.ch>
8. Datta's Ramblings, IT blog portal, dostupno na: <https://dattatreysindol.com/2013/04/15/bi-basics-why-do-we-need-business-intelligence/>
9. Dukić B., Bara D., Dukić S. (2016): "Impact of Right-Time Business Intelligence Tools of Efficiency in Decision Making", dostupno na: <https://hrcak.srce.hr/162077>
10. Eckerson W.: "Smart Companies in the 21st Century: The Secrets of Creating Successful Business Intelligence Solutions", str.4, dostupno na: http://download.101com.com/tdwi/research_report/2003BIRreport_v7.pdf
11. Eckerson W.W.: "Performance Management Strategies; How to Create and Deploy Effective Metrics" (2009), str.11., dostupno na: https://www.microstrategy.com/Strategy/media/downloads/white-papers/TDWI_Performance-Management-Strategies.pdf

12. European Commission, EU eGovernment Action Plan 2016-2020- Accelerating the digital transformation of government, dostupno na: <https://ec.europa.eu/digital-single-market/en/news/communication-eu-egovernment-action-plan-2016-2020-accelerating-digital-transformation>
13. European Commission, EU eGovernment Action Plan, dostupno na: <https://ec.europa.eu/digital-single-market/en/european-egovernment-action-plan-2016-2020>
14. European Commission, factsheets, dostupno na: <http://ec.europa.eu/COMMFrontOffice/publicopinion/index.cfm/Survey/getSurveyDetail/instruments/FLASH/surveyKy/2089>
15. Eurobarometar, European businesses and public administration- report, dostupno na: <http://ec.europa.eu/commfrontoffice/publicopinion/index.cfm/ResultDoc/download/DocumentKy/72225>
16. Eurostat, dostupno na: <http://ec.europa.eu/eurostat/web/european-statistical-system/overview>
17. Eurostat, dostupno na: http://ec.europa.eu/eurostat/statistics-explained/index.php?title=ICT_specialists_in_employment
18. Grigori D., Casati F., Castellanos M., Dayal; Umeshwar D., Sayal M., Shan M.-C.: "Business Process Intelligence". Computers in Industry 53, Elsevier, Volume 53(2004), dostupno na: http://ceit.aut.ac.ir/~sa_hashemi/My%20Teachings/MS-CEIT-Business%20Process%20Re-Engineering/Resources/BPI-BussinessProcessIntelligence.pdf
19. Hrbud Z.: BI za uspješno poslovanje, Open info trend časopis, dostupno na: <http://www.infotrend.hr/clanak/2009/11/bi-za-uspjesno-poslovanje,46,851.html>
20. Hsinchun C., Chiang R.H.L., Storey V.C.: „Business Intelligence and Analytics:From Big Data to Big Impact“, dostupno na: <https://pdfs.semanticscholar.org/fbb1/8d40150508ef2f344359ec345da7fb77cc0a.pdf>
21. Kojić N.,Dajić M.,Vučković N.:“ Merenje i unapređenje indikatora ključnih performansi u savremenoj organizaciji“, Ekonomski signali, (2017), dostupno na: <https://scindeks-clanci.ceon.rs/data/pdf/1452-4457/2017/1452-44571702001K.pdf>
22. Kuhfahl R.,Sehlke C.,Sones J.,Howard N.:“ Key Performance Indicators:What Can They Do for You?“, (2018), dostupno na: <http://web.a.ebscohost.com.ezproxy.nsk.hr/ehost/pdfviewer/pdfviewer?vid=0&sid=9d1aef2b-5572-4fee-92db-7321d1692660%40sessionmgr4008>

23. Kwang T.W.: „The impact of ICT on the global economy“, časopis eGovinnovation (2005), dostupno na: <https://www.enterpriseinnovation.net/article/impact-ict-global-economy-1388124773>
24. Marinov V.: „The Job of a Business Intelligence Consultant“, freelancer magazine, (2018), dostupno na: <https://www.freelancermap.com/freelancer-tips/12153-career-insights-business-intelligence-consultant>
25. Metode znanstvenih istraživanja, dostupno na: http://www.unizd.hr/portals/4/nastavni_mat/1_godina/metodologija/metode_znanstvenih_istrazivanja.pdf
26. MIT Software: „Općenito o BI sustavima“, dostupno na: <http://www.mit-software.hr/usluge/bi/bi1/>
27. Muntean M., Surcel T.: „Agile BI- The Future of BI“, (2013), dostupno na: <https://pdfs.semanticscholar.org/e6b5/93ca7fc2256ca8f49b70072c70dbe5645c8d.pdf>
28. Muntean M., Surcel T.: „Agile BI- The Future of BI“, (2013), dostupno na: <https://pdfs.semanticscholar.org/e6b5/93ca7fc2256ca8f49b70072c70dbe5645c8d.pdf>
29. Net.hr, „Od škotskih garaža do nogometnog prvenstva: Upoznajte Dalićevo tajno oružje“, članak, dostupno na: <https://net.hr/sport/nogomet/od-skotskih-garaza-do-svjetskog-prvenstva-upoznajte-dalicevo-tajno-oruzje>
30. Panian Ž. i suradnici: „Poslovna Inteligencija, Studije slučajeva iz hrvatske prakse“, dostupno na: <https://bib.irb.hr/datoteka/481181.PISSHP - Glavnina teksta.pdf>
31. Parmenter D.: „Key Performance Indicators; Developing, Implementing, and Using Winning KPIs“, (2007), dostupno na: <https://www.slideshare.net/AddkwService/key-performance-indicators-david-parmenter>
32. Peterlić, S.: „Ključni pokazatelji uspješnosti (KPIs)-management kvalitete i poslovanja“, dostupno na: <https://issuu.com/kvaliteta.net/docs/peterlic-s1>
33. Peterson T. E.: „The Big Book of Key Performance Indicators“, (2006), dostupno na: http://www.webanalyticsdemystified.com/downloads/The_Big_Book_of_Key_Performance_Indicators_by_Eric_Peterson.pdf
34. Pivac S.: „Statističke metode“, e-nastavni materijal (2010), EFST, dostupno na: <https://www.bib.irb.hr/933520>
35. Scott B.: „Consulting on the Inside“, (2008), dostupno na: <http://bevscott.com/bvs-content/uploads/2013/09/ASTD-Handbook-Consulting-on-the-Inside.pdf>

36. Shen J.: „Investigation of how to implement successful KPIs for organizations – based on an empirical study at an international organization“, Master degree, dostupno na: <http://www.diva-portal.org/smash/get/diva2:617504/FULLTEXT01.pdf>
37. Tank, M.(2015): „Enable Better and Timelier Decision-Making Using Real-Time Business Intelligence System“, str. 46, dostupno na: <http://www.mecspress.net/ijieeb/ijieeb-v7-n1/IJIEEB-V7-N1-6.pdf>
38. Taylor J.: “Best practice for picking the right KPIs for your business“, dostupno na: <https://www.klipfolio.com/blog/best-practices-for-picking-business-kpis>
39. UN E-Government Knowledge DataBase, 2016 E-Government Development Index, dostupno na: <https://publicadministration.un.org/egovkb/en-us/Data/Compare-Countries>
40. United Nations, „Manual for measuring eGovernment“, dostupno na: https://www.itu.int/en/ITU-D/Statistics/Documents/partnership/eGovernment_Manual_Final_2014.pdf
41. United Nations, „Framework for a set of e-government core indicators“, dostupno na: https://www.itu.int/en/ITU-D/Statistics/Documents/partnership/Framework_for_a_set_of_E-Government_Core_Indicators_Final_rev1.pdf

POPIS SLIKA

| | |
|---|----|
| Slika 1. Razlika između poslovne inteligencije (BI) i poslovne analitike (BA) | 9 |
| Slika 2. Poslovna inteligencija kao rafinerija podataka | 13 |
| Slika 3. Demingov krug poslovne inteligencije kao pomoći za unapređenje poslovnog procesa | 16 |
| Slika 4. Strateški i operativni KPI | 26 |
| Slika 5. Piramida strateškog usmjerenja | 28 |
| Slika 6. Tradicionalni tijek rada nasuprot agilnog tijeka rada BI | 34 |

POPIS TABLICA

| | |
|--|----|
| Tablica 1. Obilježja strateške, taktičke i operativne poslovne inteligencije | 14 |
| Tablica 2. Korelacija između %ICT stručnjaka u ukupnoj zaposlenosti i % poduzeća koja smatraju da broj procedura javne uprave nije prepreka za pokretanje poslovanja | 51 |
| Tablica 3. Značajnost regresijskog modela..... | 52 |
| Tablica 4. Vrijednosti ocijenjenih parametara linearne regresije..... | 52 |
| Tablica 5. Osnovni podaci o ocijenjenom modelu | 53 |
| Tablica 6. Spearmanov koeficijent korelacije između apsolutnih reziduala i regresorske varijable..... | 55 |
| Tablica 7. Korelacija između % ICT stručnjaka u ukupnoj zaposlenosti i % poduzeća koja smatraju da troškovi procedura javne uprave nisu prepreka u pokretanju poslovanja | 56 |
| Tablica 8. Značajnost regresijskog modela..... | 57 |
| Tablica 9. Vrijednosti ocijenjenih parametara linearne regresije..... | 57 |
| Tablica 10. Osnovni podaci o ocijenjenom modelu | 58 |
| Tablica 11. Spearmanov koeficijent korelacije između apsolutnih reziduala i regresorske varijable..... | 59 |

POPIS GRAFIKONA

| | |
|--|----|
| Grafikon 1. Prednosti korištenja poslovne inteligencije, opipljive i neopipljive prednosti | 15 |
| Grafikon 2. Stupičasti grafikon, prikaz top 3 zemlje članice EU, Hrvatske i Slovenije, po udjelu ICT stručnjaka u ukupnoj zaposlenosti | 44 |
| Grafikon 3. Indeks razvijenosti E-Governmenta u 28 zemalja članica EU | 45 |
| Grafikon 4. Linijski grafikon kretanja udjela zaposlenih ICT stručnjaka i ukupne zaposlenosti u zemljama EU po godinama..... | 46 |
| Grafikon 5. Top 3 zemlje u kojima broj procedura nije ograničenje za pokretanje poslovanja (usporedba s Hrvatskom i Slovenijom)..... | 47 |
| Grafikon 6.- Top 3 zemlje u kojima trošak procedura nije ograničenje za pokretanje poslovanja (usporedba sa Hrvatskom i Slovenijom)..... | 48 |
| Grafikon 7. Dijagram rasipanja između varijable x i y..... | 51 |

| | |
|---|-----------|
| Grafikon 8. Histogram standardiziranih reziduala | 53 |
| Grafikon 9. Grafikon normalno distribuiranih reziduala..... | 54 |
| Grafikon 10. Dijagram rasipanja između varijable x i y..... | 56 |
| Grafikon 11. Histogram standardiziranih reziduala | 58 |
| Grafikon 12. Grafikon normalno distribuiranih reziduala..... | 59 |