

ISTRAŽIVANJE MOGUĆNOSTI PRIMJENE BI ALATA U ANALIZI GLAVNIH OBILJEŽJA GOSPODARSTVA SPLITSKO-DALMATINSKE ŽUPANIJE

Juranović, Fani

Master's thesis / Diplomski rad

2016

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

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:124:622221>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-04-26**

Repository / Repozitorij:

[REFST - Repository of Economics faculty in Split](#)



UNIVERSITY OF SPLIT





SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET

DIPLOMSKI RAD

ISTRAŽIVANJE MOGUĆNOSTI PRIMJENE BI
ALATA

U ANALIZI GLAVNIH OBILJEŽJA
GOSPODARSTVA SPLITSKO-DALMATINSKE
ŽUPANIJE

Mentor:

prof. dr. sc. Nikša Alfiredić

Student:

Fani Juranović

Split, Kolovoz, 2016.

Sadržaj

1. UVOD.....	5
1.1. Problem istraživanja.....	5
1.2. Predmet istraživanja.....	6
1.3. Svrha i ciljevi istraživanja.....	7
1.4. Metode istraživanja	7
2. POSLOVNA INTELIGENCIJA KAO PODRŠKA ODLUČIVANJU ...	9
2.1. Koncept i razvoj	9
2.2. Metode i alati	18
2.3. Koristi primjene koncepta poslovne inteligencije	24
2.4. Poslovna inteligencija na makroekonomskoj razini	27
3. KLASITERIRANJE IZVORNIH PODATAKA	30
3.1. Pregled izvornih podataka	30
3.2. Odabir alata za klasteriranje.....	31
3.3. Izbor algoritma.....	32
3.4. Izrada modela.....	33
3.5. Formiranje klastera	35
4. ANALIZA EKONOMSKIH POKAZATELJA PO KLASITERIMA....	40
4.1. Izbor alata za analizu.....	40
4.2. Analiza ekonomskih pokazatelja za klastere formirane s obzirom na djelatnost poduzeća	40
4.2.1. Zaposlenost	40
4.2.2. Stopa rasta vrijednosti imovine.....	42
4.2.3. Stopa rasta vlastitog kapitala.....	45
4.2.4. Analiza likvidnosti	45
4.2.5. Analiza profitnih marži	47
4.3. Analiza ekonomskih pokazatelja za klastere formirane s obzirom na mjesto sjedišta poduzeća	48
4.3.1. Zaposlenost	49
4.3.2. Stopa rasta vrijednosti imovine.....	50
4.3.3. Stopa rasta vlastitog kapitala.....	50
4.3.4. Analiza likvidnosti	51
4.3.5. Analiza profitnih marži	51

4.4. Analiza ekonomskih pokazatelja za klastere formirane s obzirom na veličinu poduzeća	51
4.4.1. Zaposlenost	52
4.4.2. Stopa rasta vrijednosti imovine	53
4.4.3. Stopa rasta vlastitog kapitala.....	53
4.4.4. Analiza likvidnosti	54
4.4.5. Analiza profitnih marži	54
5. Vizualizacija	55
5.1. Odabir alata.....	55
5.2. Vizualizacija analize ekonomskih pokazatelja za klastere formirane s obzirom na djelatnost poduzeća.....	55
5.2.1. Zaposlenost	55
5.2.2. Stopa rasta vrijednosti imovine	57
5.2.3. Stopa rasta vlastitog kapitala.....	58
5.2.4. Analiza likvidnosti	59
5.2.5. Analiza profitnih marži	60
5.3. Vizualizacija analize ekonomskih pokazatelja za klastere formirane s obzirom na mjesto sjedišta poduzeća	61
5.3.1. Zaposlenost	61
5.3.2. Stopa rasta vrijednosti imovine	62
5.3.3. Stopa rasta kapitala	63
5.3.4. Analiza likvidnosti	64
5.3.5. Analiza profitnih marži	65
5.4. Vizualizacija analize ekonomskih pokazatelja za klastere formirane s obzirom na veličinu poduzeća	66
5.4.1. Zaposlenost	66
5.4.2. Stopa rasta imovine	67
5.4.3. Stopa rasta kapitala	68
5.4.4. Analiza likvidnosti	69
5.4.5. Analiza profitnih marži	70
6. USPOREDBA REZULTATA.....	71
6.1. Sažeti rezultati analize	71
6.2. Interpretacija rezultata	72
7. ZAKLJUČAK	74
8. POPIS TABLICA	76

9. POPIS GRAFIKONA.....	77
10. POPIS SLIKA.....	78
11. LITERATURA	79
11.1. Knjige	79
11.2. Časopisi	79
11.3. Web izvori.....	80
12. SAŽETAK	81
13. ABSTRACT	81

1. UVOD

1.1. Problem istraživanja

Poslovna inteligencija kao koncept može se objasniti na različite načine, te nema univerzalne definicije kojom bi se istakle sve prednosti i koristi primjene poslovne inteligencije. No jedno je sigurno na današnjem globalnom tržištu, koje je pod jakim utjecajem turbulentne poslovne okoline, informacija postaje jedan od temeljnih resursa svakog poslovnog subjekta. Neovisno o tome radi li se o poduzećima ili pak državnim upravnim jedinicama, u ovom slučaju županijama, alati poslovne inteligencije pružaju iznimnu podršku odlučivanju i upravljanju.

Poslovna inteligencija kombinira aktivnosti prikupljanja, skladištenja i obrade podataka s analitičkim alatima u svrhu generiranja kompleksnih i kompetitivnih informacija za podršku odlučivanju (Negash, 2014).

Sukladno prethodnom navodu možemo utvrditi da poslovna inteligencija u širem smislu pruža jedinstvenu podršku upravljanju podacima prvenstveno kroz ETL (eng. *Extraction, Transformation, Loading*) proces i OLAP (eng. *On-line analytical processing*) tehnologiju. ETL proces obuhvaća manipulaciju podacima kod skladištenja i obrade velike količine podataka. OLAP omogućava multidimenzijski pregled podataka, koji se postiže izvještavanjem, analizom, modeliranjem i planiranjem u svrhu optimizacije poslovanja. OLAP tehnologije i alati se također mogu koristiti kod poslovnih jedinica sa postojećim skladištima podataka koji su većinom dizajnirani kao skladišni prostor sofisticiranih informacijskih sustava. Za analitičke potrebe rada koristeći će se MS Office Excel i pripadajuća baza zbog veličine seta podataka i prirode sadržanih podataka. OLAP pristup je primjereniji u slučajevima velikih količina podataka zato što pokazuje efikasnije performanse kod izmjene istih i kreiranja izvještaja.

U poslovnoj je inteligenciji neizbježan pojam rudarenja podataka. Ono omogućava otkrivanje specifičnih obrazaca u velikim količinama podataka, što ne bi bilo moguće bez primjene sofisticiranih DM (eng. *Data Mining*) metoda i alata. Data mining se odnosi na skupinu aktivnosti kojima je zajednička specifična potraga za različitim načinom procesiranja podataka a sve sa ciljem prezentiranja novih informacija po određenim kriterijima (Hoover i Perez, 2000).

Data mining obuhvaća niz metoda i pripadajućih algoritama za manipulaciju podacima ovisno o svrsi samog istraživanja. O metodama korištenim unutar sučelja alata za rudarenje podataka – Rapid Miner Studio nešto će više govora biti u nastavku.

Kako bi se rezultati klasifikacije i analize vrijednosti pokazatelja opservacija što bolje razumjeli, neizbježna je vizualizacija podataka. Kao jedan od vodećih alata na tržištu softvera za vizualizaciju podataka za posljednju fazu istraživanja odabran je Tableau.

Problem istraživanja je prikaz primjenjivosti, mogućnosti i koristi primjene spomenutih tehnologija u profiliranju gospodarstva na primjeru gospodarstva Splitsko-dalmatinske županije.

1.2. Predmet istraživanja

Istraživanje se temelji na analizi glavnih obilježja poslovnih subjekata Splitsko-dalmatinske županije. Izvor podataka je set podataka (eng. *Dataset*) iz europske poslovno-financijske baze podataka, Amadeus baze u MS Excel formatu. Dataset sadrži 12646 poslovnih subjekata koji posluju na području Splitsko-dalmatinske županije s pripadajućim ekonomskim i financijskim pokazateljima.

Navedeni pokazatelji su sljedeći:

- Broj zaposlenih
- Tip vlasništva
- Ukupna imovina kroz pet obračunskih razdoblja
- Vlasnički kapital kroz pet obračunskih razdoblja
- Pokazatelj tekuće likvidnosti kroz pet obračunskih razdoblja
- Profitna marža kroz pet obračunskih razdoblja

Dostupni podaci dovoljni za potrebe ovog rada obuhvaćaju pet obračunskih razdoblja (2009. – 2013.). U razmatranje nisu uvrštena naredna obračunska razdoblja, jer obračuni nisu bili dovršeni ni dostupni u vremenu ekstrakcije podataka iz baze Financijske agencije i njihovog uključivanja u bazu Amadeus. Poslovni subjekti su podijeljeni u skupine po tri kriterija:

- Djelatnost
- Mjesto sjedišta tvrtke (više od 10 000 stanovnika)
- Veličina poduzeća.

U bazi podataka nema jasne naznake o veličini poduzeća po Zakonu o računovodstvu (Članak 3. Razvrstavanje poduzetnika) pa su ona naknadno razvrstana po kriterijima broja zaposlenih i ukupne aktive, kako iznos ukupnih prihoda nije dostupan u bazi.

Kao što je već navedeno, razdoblje promatranja odnosi se na razdoblje od 2009. do 2013. godine uključujući početnu i završnu godinu. Osim samog ispitivanja gospodarskog profila, odnosno analize pokazatelja i njihovog kretanja donijeti će se zaključci o ponašanju pojedinih skupina poduzeća po određenim kriterijima nakon razdoblja recesije.

1.3. Svrha i ciljevi istraživanja

Cilj istraživanja je efikasna primjena skupine alata poslovne inteligencije pri ispitivanju glavnih obilježja gospodarstva u Splitsko-dalmatinskoj županiji, u svrhu dokazivanja važnosti prijemjene navedenih alata kod kvalitetnog donošenja odluka.

Analizom glavnih obilježja stvara se jasnija slika o gospodarstvu na navedenom prostoru uključujući trend kretanja tih obilježja, donose se zaključci o ponašanju gospodarskih subjekata nakon razdoblja recesije, te se testira primjenjivost korištenih alata u ovom slučaju.

Bez dobre podloge u relevantnim informacijama donošenje odluka ne može biti na željenoj razini. Ovim radom se ističe potreba iscrpnijeg iskorištavanja informatičke podrške u otkrivanju novih informacija koje posljedično dovode do jasnije putanje razvoja poduzeća, regionalnog ili nacionalnog gospodarstva.

1.4. Metode istraživanja

U teorijskom dijelu rada koristit će se opće znanstvene metode, kako bi se prikupili sekundarni podaci (literatura) iz područja primjene tehnologija poslovne inteligencije. Navedena istraživanja su srodne tematike te su navedena u korištenoj literaturi.

U empirijskom dijelu koriste se statističke, ekonometrijske te matematičke metode i algoritmi. Obrada izvornih podataka započinje formiranjem skupina po različitim kriterijima. Kroz sučelje alata RapidMiner Studio biti će korišteni potrebni operatori, odnosno algoritmi u svrhu klasterizacije podataka. Kako bi se osiguralo ispravno i efektivno korištenje alata, korišteni su priručnik za ovaj alat te službena internetska stranica.

Set podatka nad kojim se provodi istraživanje je prikupljen u obliku MS Excel tablice, koja je korištena i za analizu podataka. Prvenstveno se radi o izračunu željenih ekonomskih i

financijskih pokazatelja za generirane skupine poslovnih subjekata. Potrebne formule za izračune preuzete su iz relevantne literature.

Vizualizacija podataka je posljednji korak ostvaren korištenjem funkcija alata Tableau, odnosno grafičkim prikazom indikatora i njihovog kretanja kroz promatrano razdoblje.

1.5. Doprinos istraživanja

Doprinos istraživanja se ogleda u otvaranju novih mogućnosti prihvaćanjem koncepta konstantne primjene različite skupine alata poslovne inteligencije pri analizi podataka u gospodarstvu. Navedenom primjenom otkrivaju se nove informacije korisne ujedno za poduzeća i nacionalni prosperitet kao i za investitore koji će se u situaciji dostupnih relevantnih podataka i saznanja vjerojatnije odlučiti na investiciju, naravno pod pretpostavkom da su podaci zadovoljavajući.

Proširenjem aspekta korištenja informatičke podrške povećava se i obim korisnih informacija. Metode i alati obuhvaćeni ovim radom samo su dio niza tehnologija koje unaprijeđuju poslovanje, bilo ono na mikro ili makroekonomskoj razini.

Osim povećanja obima informacija zbog prihvaćanja suvremenih metoda i alata povećava se i kvaliteta informacija što se odnosi na njihovu relevantnost kao i na vizualizaciju podataka dobivenih analizom.

2. POSLOVNA INTELIGENCIJA KAO PODRŠKA ODLUČIVANJU

2.1. Koncept i razvoj

Zbog nepostojanja univerzalne definicije, u nastavku je navedeno nekoliko definicija koncepta poslovne inteligencije.

Naziv poslovna inteligencija kao prijevod engleskog izvornika *business intelligence* najčešće se upotrebljava, ali ne ukazuje na pravo značenje pojma. Problem je što u engleskom jeziku riječ *intelligence* ima dva značenja, a u hrvatskom jeziku samo jedno. U ovom kontekstu relevantno je značenje riječi *intelligence* koje se odnosi na prikupljanje, obradu, analizu i interpretaciju podataka o okruženju nekog sustava u vojno-sigurnosnom kontekstu. Ujedno se isti naziv odnosi i na sustav koji obavlja navedene aktivnosti (Garača, 2009).

Poslovna inteligencija je definirana kao sposobnost organizacije da svoje procese i sposobnosti konvertira u znanje stjecanjem pravih informacija, za prave osobe, u pravo vrijeme, preko pravih kanala (Kumari, 2013).

Poslovna inteligencija objedinjuje prikupljanje i skladištenje podataka s menadžmentom znanja koristeći analitičke alate za prezentaciju internih i kompetitivnih informacija donositeljima odluka (Negash, 2014).

Poslovna inteligencija se definira kao integrirani pristup temeljen na informatičkoj tehnologiji, čija je implementacija specifična za svako poduzeće, sa ciljem podrške odlučivanju na različitim menadžerskim razinama (Grossman i Rinderle, 2007).

Poslovna inteligencija kombinira proizvode, tehnologije i metode u cilju organiziranja ključnih informacija potrebnih menadžmentu, a sve u svrhu poboljšavanja performansi i povećanja profita (Williams i Williams, 2015).

Sukladno navedenim definicijama poslovna inteligencija u suvremenom poslovanju se pojavljuje u obliku spektra metoda, alata i tehnologija čiji je cilj podrška odlučivanju. Iako inicijalno fokusirana na najviše razine menadžmenta, poslovna inteligencija se sve više i češće koristi i na nižim razinama. Kada govorimo o podršci odlučivanju to se prvenstveno odnosi na predviđanje trendova u poslovnoj okolini, utvrđivanje strateških ciljeva te na optimizaciju dugoročne alokacije resursa.

Bez obzira na korištenu tehnologiju poslovna inteligencija se temelji na nekoliko načela:

- Centralizacija - kako bi alati poslovne tehnologije imali utjecaja na strateške ciljeve poduzeća, upravljanje konceptima poslovne inteligencije mora biti centralizirano.
- Objektivnost - bez objektivnih i relevantnih podataka ne mogu se očekivati točna i precizna predviđanja.
- Pravovremenost - podaci i informacije moraju uvijek biti dostupni onda kada su potrebni.
- Prilagodljivost - manjak fleksibilnosti uvelike otežava odgovaranju na zahtjeve poslovnog sustava.
- Kontinuiranost - kontinuiranost se odnosi na stalno evidentiranje novih promjena i skladištenje novih informacija i podataka onda kada su nastali.
- Sustavnost - korištenje svih potrebnih resursa sa pripadajućim ograničenjima.
- Dostupnost - skladišteni podaci i generirane informacije uvijek moraju biti dostupne interesnim skupinama.
- Etičnost - problem etičnosti se javlja kod prikupljanja podataka koji nemaju interni izvor, a nisu javno dostupni.
- Sveobuhvatnost - za što relevantnije rezultate analiza potrebno je prikupiti dostupne podatke iz svih raspoloživih izvora.

Ako promatramo poslovnu inteligenciju kao kontinuirani i ciklički proces, poslovna inteligencija pretvara podatke u informacije, a informacije u znanje korišteno za napredak poslovnog sustava.

Kada bi definirali osnovne faze poslovne inteligencije kao cikličkog procesa one bi bile sljedeće:

- Definiranje i analiza potreba. Kako bi istraživanja imala željeni učinak potrebno je naravno, inicijalno definirati ciljeve i pitanja na koja poslovna inteligencija treba dati odgovor.
- Kontinuirano promatranje poslovnog okruženja i prikupljanje informacija. Svjedoci smo turbulentnih i dinamičnih promjena u poslovnoj okolini suvremenih poduzeća. Stoga je potrebno ažurno pratiti te promjene.

- Obrada podataka i analiza informacija. Nakon faze prikupljanja internih i eksternih podataka poslovnog subjekta, te skladištenja istih nad tim podacima se vrši niz analiza kako bi se došlo do relevantnih zaključaka.
- Pohranjivanje proizvedenog znanja. Znanje stečeno analizom i obradom skladištenih podataka pohranjuje se u svrhu korištenja poslovnog znanja u nadolazećim situacijama.
- Prezentacija rezultata istraživanja. Prezentacija rezultata može poprimiti različite oblike, od standardnih izvještaja do vizualizacije višedimenzijskih modela podataka.
- Uporaba rezultata istraživanja. Bez korištenja znanja stečenog analizom, sama analiza nema svrhu ni smisao.

Poslovna inteligencija kao koncept postojala je mnogo prije razvitka suvremene tehnologije koju danas poznajemo i svakodnevno koristimo. U dijelu Richard Millara iz 1865. godine “Cyclopaedia of Commercial and Business Anecdotes” prvi put se pojavljuje pojam poslovne inteligencije. Spomenuti pisac smatrao je upravo poslovnu inteligenciju zaslužnom za uspjeh Sir Henry Furnesea, tadašnjeg londonskog bankara. Njegovo razumijevanje političkih problema, nestabilnosti i tržišta nazvao je poslovnom inteligencijom. *“Preko Nizozemske, Flandrije, Francuske i Njemačke održavao je besprijekornu praksu poslovne inteligencije. Na taj način vijesti su uvijek prvo dolazile do njega. Iako je Furnese imao negativnu reputaciju kao korumpirani političar, njegovi načini pronalaženja i skladištenja podataka u svrhu predviđanja trendova u poslovanju preteča su poslovne inteligencije.”* U nastavku će biti spomenuti i razgraničeni relevantni koncepti i tehnologije koje prepoznajemo kao temelj razvitka suvremene poslovne inteligencije.


Pojam poslovne inteligencije kakvu danas poznajemo nije postojao do 1958. godine i objave članka “A Business Intelligence System” Hans Peter Luhn, IBM-ovog znanstvenika, koji je poslovnu inteligenciju opisao kao alat koji donosi informacije svim gospodarskim subjektima. U svom članku autor je definirao inteligenciju kao sposobnost shvaćanja relacija među poznatim konstatacijama na način da su te relacije izvjestan vodič akcija, koje vode ka željenom cilju. U načelu, poslovna je inteligencija način najefikasnijeg i najefektivnijeg razumijevanja velike količine podataka u svrhu boljeg donošenja odluka. Luhnov rad je i više nego predstavio i proširio mogućnosti koncepta poslovne inteligencije, te postavio temelje modernog informacijskog sustava, koji omogućava prikupljanje, pohranjivanje, obradu, i isporučivanje potrebnih informacija kao kontinuirani proces kakav danas poznajemo. Luhn ciljem korištenja informacijskog sustava smatra nabavku informacija u svrhu podrške

poslovanju, odnosno u svrhu podrške specifičnih aktivnosti koje iznose individualci, grupe, odjeli ili veće poslovne jedinice koje naziva pristupnim točkama (eng. *Action Points*).

Zadatak informacijskog sustava je da omogući nabavku, pristup i ulaz novih podataka i informacija, te raspodjelu, skladištenje, korištenje i tranziciju istih brzo i efikasno (Luhn, 1958).

Kako je prikazano na slici 1., autor u strukturi poslovnog informacijskog sustava prvo prikazuje input podataka, odnosno dokumenata, eksternih i internih. Nakon ulaska dokumenata u sustav svakom dokumentu se dodjeljuje serijski broj te se kreira kopija dokumenta fotografskom reprodukcijom pomoću mikrofilma. Takva kopija se pohranjuje pomoću magnetnih vrpce dok se original čuva u fizičkim datotekama na potreban vremenski rok. Snimka na magnetnoj vrpce se zatim sažima, kodira te analizira statističkom analizom baziranom na fizičkim karakteristikama teksta kako bi se, ukoliko postoji, prepoznao obrazac u podacima na temelju signifikantnih riječi. U svrhu maksimalnog iskorištavanja postojećih podataka Luhn razvija koncept indeksiranja¹ pomoću kojeg se eliminiraju greške i mogućnost previđanja informacija zbog različitih izraza korištenih u dokumentima od strane autora. Derivirani obrazac dokumenta se transferira na skladišni uređaj zajedno sa naznakom naziva, autora i serijskog broja dokumenta. Kada je novi dokument ušao u sustav te je prepoznat obrazac podataka isti podliježe usporedbi koja se izvršava pomoću uređaja koji komunicira sa svim pristupnim točkama.

¹ Indeksiranje dokumenata na računalu predstavlja postupak u kojem informacijski sustav pregledava dokumente te ih kategorizira kako bi se omogućilo njihovo pretraživanje



Slika 1: Struktura poslovnog informacijskog sustava prema Luhn-u

Izvor: Luhn, H.P. (1958): A Business Intelligence System, IBM Journal, October 1958, str. 317.

Njegove istraživačke i razvojne metode korištene su za kreiranje nekih od temeljnih analitičkih sustava u IBM-u. Zbog svih navedenih razloga mnogi ga danas nazivaju ocem poslovne inteligencije.

Sredinom sedamdesetih godina prošlog stoljeća stvara se ponuda prvih tehnoloških rješenja sa područja poslovne inteligencije koja nužno ne zahtijevaju poznavanje programskih jezika za obradu i analizu podataka. Primarni razlog za plasiranje ovakvih proizvoda bila je samostalna obrada vlastitih podataka odgovarajućeg formata od strane krajnjih korisnika.

Drugi razlog nepostojanje relacijskih baza podataka u to vrijeme, pa su proizvođači alata bili prisiljeni ponuditi vlastita rješenja u kreiranju podataka relevantnog formata. Postoji niz nedostataka ovakvih izvora podataka. Naistaknutiji nedostaci su sljedeći:

- Nefleksibilnost. Izvor i format podataka funkcionira samo s alatom proizvođača od strane kojeg su kreirani.

- Kompleksnost. Krajnjim korisnicima je u većini slučajeva potrebna pomoć IT stručnjaka pri izvlačenju informacija iz originalnog izvora podataka.
- Neefikasnost. Visoka ulaganja u ove tehnologije isključivo bi vezala podatke uz postojeće tehnološko rješenje.

Značajan broj krajnjih korisnika bio je nezadovoljan ovim, kompleksnim načinom manipulacije podacima. Navedeni alati su pružali izuzetno veliku moć pri obradi podataka, no krajnji korisnici koji nisu vladali naredbama potrebnim za obradu podataka, posljedično nisu bili u mogućnosti samostalno koristiti spomenute alate.

Ranih osamdesetih godina došlo je do pojave informacijskog centra kao koncepta. Krajnji korisnici su sve više bili uključeni u procese vezane uz podatke i informacije, zbog čega je i došlo do ideje stvaranja informacijskog centra, kojem su se krajnji korisnici mogli obratiti, ukoliko trebaju pomoć tehničke prirode. Dakle, informacijski centar je bio dizajniran kao spona između IT odjela i krajnjih korisnika, u svrhu pružanja podrške krajnjim korisnicima u nizu aktivnosti i procesa, koji zahtijevaju napredno tehničko znanje. Kada se radi o podacima i manipulaciji istih, upravo je IT odjel imao sve relevantne informacije o skladištenju i ekstrahiranju podataka, kao i o alatima preporučenim za obradu tih podataka.

U to vrijeme prakticirala se takozvana centralizacija tehnološkog znanja, koja je i dovela do pojave informacijskog centra. Ovakva praksa je zaživjela u poduzećima do trenutka kada počinju rasti tehničke vještine i kompetencije krajnjih korisnika, uslijed napretka tehnologije. Postoji još jedan razlog koji je doveo do iščezavanja ovog koncepta. Tehnološki rast bio je popraćen i rastom troškova koji su bili alocirani isključivo na središnju IT jedinicu tj. informacijski centar. Zbog navedenog razloga, nije postojao način provjere, ni kontrole mjesta nastanka troškova informatičke podrške. Iz tog razloga nastaje sistem naplate IT troškova (eng. *IT chargeback system*), koji je zapravo računovodstvena strategija koja alocira troškove IT usluga, hardvera ili softvera na poslovnu jedinicu u kojoj su troškovi i nastali. Ovakav sustav je namijenjen poticanju odgovornijeg korištenja IT usluga i razjašnjavanju indikatora troškova. Pojavom mikroprocesora i posljedično većom dostupnošću osobnih računala dolazi do izrazitog unaprijeđenja obrade podataka za krajnjeg korisnika. Međutim, poteškoće koje su se javljale većinom su bile povezane uz pristupanje skladištenih podataka.

Spomenute poteškoće dominantan su razlog masivne implementacije klijent/server arhitekture i niza alata baziranih na SQL (eng. *Structured Query Language*) upitima. Implementacija klijent-server arhitekture zahtijevala je mnoštvo strukturnih promjena u poslovnim procesima,

najčešće korištenjem metodologijom reinženjeringa poslovnih procesa (eng. *BPR – Business Process Reengineering*), zbog čega su ovakvi projekti bili izrazito skupi i zahtjevni no jednako toliko i nužni. Osim izmjene poslovnih procesa i procedura, razlog visokih troškova nalazio se i u promjeni formata podataka, koji većim dijelom nisu odgovarali relacijskim bazama podataka. Pojavom relacijskih baza podataka i relacijskih sustava za upravljanjem bazama podataka (eng. *RDBMS - Relational Database Management Systems*), analiza podataka dosegla je mnogo višu razinu standardiziranosti. Analitički alati sada su nesmetano funkcionirali sa sustavima za upravljanje bazama podataka različitih proizvođača. Osim relacijskih baza, podataka važno je napomenuti pojavu objektno-orijentiranog programiranja koje je devedesetih godina prošlog stoljeća zauvijek promijenilo dotadašnji pristup programiranju.

Objektno-orijentirani pristup zauzima centralno mjesto među pristupima razvoju programske podrške jednostavno zato što je dokazao svoju vrijednost u razvoju sustava u raznim domenama problema i u obuhvaćanju svih razina kompleksnosti. Nadalje, većina modernih jezika operativnih sustava i alata su na neki način objektno-orijentirani, dajući veći doprinos objektnom pogledu na svijet (Garača, 2008).

Prednosti objektno-orijentiranog pristupa:

- Veća pouzdanost i fleksibilnost u razvoju
- Lakši rad sa nestandardnim tipovima podataka
- Manja ovisnost o sklopovskoj opremi
- Lakša izvedba klijent-server aplikacija
- Usmjerenost na ponašanje, a ne na procedure obrade.

Objektno-orijentirana analiza, kao i svaki drugi oblik analize ima za cilj potpuno razumijevanje sustava temeljem funkcijskih zahtjeva. Razlika u odnosu na strukturnu analizu koja podatke i funkcije razmatra odvojeno je u tome da objektno-orijentirana analiza promatra objekte kao jedinstvo podataka-svojstava i ponašanja-metoda. Bez spomenutog koncepta funkcioniranje suvremenih informacijskih sustava ne bi bilo moguće (Garača, 2008).

Postoji niz razlika između relacijskih i objektno-orijentiranih baza podataka. Dok relacijske baze podataka pokazuju veću efikasnost u upravljanju većom količinom podataka, objektno-orijentirane baze efektivnije ukazuju na kompleksne veze među objektima baze. Relacijske baze podataka pružaju izvrsnu podršku dohvaćanju skladištenih podataka no ograničene mogućnosti upravljanja tim podacima. S druge strane, objektno-orijentirane baze pomoću objektno-

orijentiranih programskih jezika pružaju znatno veću podršku manipulaciji podataka nego dohvaćanju istih. Mnogi su pokušavali integrirati spomenuta dva sustava u svrhu manipulacije velikom količinom podataka među kojima postoje kompleksne relacije, no bezuspješno. Objektno-orijentirani i relacijski pristup počivaju na potpuno različitim paradigmatima. Relacijske baze podataka su temeljene na dvodimenzionalnim tablicama i vezama među podacima koje se ispituju pomoću SQL upita, dok se objektno-orijentirane baze temelje na objektima, koji predstavljaju strukture podataka kombiniranih sa povezanim kodom.

Kasnih osamdesetih godina pojavljuje se i koncept skladišta podataka (eng. *Data Warehouse*). Umjesto transformiranja postojećih podataka u nove, korisne informacije, ideja je bila zadržavanje podataka u skladišnom prostoru i pristupanje istim podacima pomoću bilo kojeg alata. Tijekom izgradnje prvih skladišta podataka, uočena je i potreba za metapodacima zbog različitih izvora i posljedično definicija skladištenih podataka. Sam nastanak skladišta podataka je uzrokovan potrebom objedinjavanja sadržaja pojedinačnih baza podataka i drugih izvora u svrhu jednostavnijeg pristupa tim podacima te efikasnije i efektivnije podrške odlučivanju.

Objedinjavanje više baza podataka ne treba shvatiti pojednostavljeno kao jednostavno skupljanje raspršenih podataka. Skladište podataka je centralizirana i integrirana organizacija pročišćenih i transformiranih izvornih podataka, prilagođena potrebama složenih poslovnih analiza (Ćukušić i Garača, 2011).

Iako je skladištenje podataka zajednička svrha i relacijskih baza podataka i skladišta podataka neke temeljne razlike između spomenutih pojmova su navedene u nastavku.


Tablica 1: Temeljne razlike relacijskih baza podataka i skladišta podataka

	Relacijska baza podataka	Skladišta podataka
Svrha	Vođenje poslovnih aktivnosti (dnevne operacije)	Izvještavanje o poslovanju, analiza poslovanja.
Korisnici	Operativna razina (službenici)	Taktička i strateška razina (menadžeri i analitičari).
Sadržaj podataka	Trenutni podaci	Povijesni podaci.
Detaljnost podataka	Detaljni podaci	Detaljni i sumarni podaci.
Jedinica obrade	Transakcija	Upit.
Interakcija korisnika i način obrade	Predodređena interakcija; strukturni zahtjevi koji se ponavljaju.	Interakcija ad hoc: Nestrukturirani zahtjevi.
Trajnost podataka	Vrlo promjenjivi podaci.	Nepromjenjivi podaci.
Način pristupa podacima	Čitanje i pisanje.	Čitanje.
Količina zapisa kojima se pristupa	Deseci i stotine.	Stotine tisuća, milijuni.
Fokus	Pohrana podataka.	Dobivanje informacija.

Izvor: Čukušić M., Željko G. (2011): Višedimenzijski informacijski sustavi: Skladištenje i analitička obrada podataka, Ekonomski fakultet, Split

Analiza podataka u svrhu podrške odlučivanju postojala i prije implementacije OLAP koncepta u poslovne sustave, no danas je analiza podataka bez analitičke obrade nezamisliva gdje se većinom koriste relacijske baze podataka i SQL za manipulaciju pohranjenim podacima.

Za samo punjenje skladišta podataka odgovoran je proces ekstrakcije, transformacije i punjenja podataka odnosno ETL proces te alati koji podržavaju spomenuti proces. Zahvaljujući konceptu skladišta podataka sadašnji i povijesni podaci lako su dostupni za analizu i obradu u svakom trenutku. Postoji niz metoda obrade podataka iz baza i skladišta koje će biti objašnjene u nastavku.



Slika 2: Iterativni procesi u BI arhitekturi

Izvor: Prikaz autora

2.2. Metode i alati

Optimizacija, simulacija, analitička i transakcijska obrada podataka samo su neke od BI metoda. Možemo reći da su metode poslovne inteligencije podijeljene u dvije glavne skupine:

- Metode poslovne inteligencije namijenjene obradi podataka.
- Metode koje se odnose na upravljanje poslovnim procesima uključujući odnose sa klijentima i poslovnim partnerima.


Poslovna inteligencija, pripadajuće metode i alati kojima se poslovna inteligencija koristi su nesporno preširok pojam za ovu tematiku. Sukladno tome bit će objašnjeni koncepti relevantni za temu ovog rada fokusirajući se na metode i alate analize podataka. Ovom prilikom se neće dodatno pojašnjavati ni zasebne aplikacije namijenjene upravljanju odnosima s kupcima (eng. *Customer Relationship Management* – CRM), korporativnim upravljanjem učinkom (eng. *Corporate Performance Management* – CPM), sustavima strateškog i taktičkog planiranja (eng. *Enterprise Performance Planning* – EPP), sustavima praćenja uravnotežene tablice rezultata (eng. *Balanced Scorecard* – BSC) ili sustavima upravljanja sadržajima (eng. *Content*

Management – CM) kao ni informacijskim sustavima u užem smislu ili pojedinim ETL alatima i platformama.

Najvažnije BI alate možemo podijeliti u nekoliko kategorija, ovisno o namjeni tih alata i metodama koje ti alati koriste. Nepotrebno je navoditi raznovrsne alate i metode koje koristi poslova inteligencija zbog broja istih, pa će u nastavku biti opisane metode i koncepti koji se odnose na empirijski dio rada, s tim da će mogućnosti korištenih alata biti objašnjene u za to pripadajućim odjeljcima.

Namjenska kategorizacija alata poslovne inteligencije je sljedeća (na pojedinim mjestima dani su dvojezični nazivi zbog lakšeg razumijevanja pojmova):

- Proračunske tablice (eng. *Spreadsheets*). Alati za skladištenje i obradu podataka u tabelarnoj formi.
- Alati za upite i izvještavanje, namijenjeni ekstrahiranju, sortiranju sažimanju i prezentiranju podataka.
- OLAP alati. Alati za analitičku obradu podataka.
- Digitalne kontrolne ploče (eng. *Digital Dashboards*). Alati za vizualizaciju i praćenje ključnih indikatora performansi poslovnog sustava.
- Data mining alati. Alati koji podržavaju obradu podataka rudarenjem.
- Alati za skladištenje podataka u baze ili skladišta podataka. Ovom tipu alata pripadaju i oni fokusirani na ETL proces.
- Alati za inženjering poslovnih odluka (eng. *Decision engineering tools*). Riječ je alatima koji koriste primjere najbolje prakse, te imaju primjenu pri donošenju odluka u poslovnom sustavu.
- Alati namijenjeni rudarenju poslovnih procesa.
- Alati za menadžment poslovnih performansi (eng. *Business performance management tools*).
- Lokalni informacijski sustavi



Slika 3: Tijek obrade izvornih podataka pomoću BI metoda i alata

Izvor: Prikaz autora

Metode poslovne inteligencije čija je svrha obrada podataka su svakako neizbježne kada je riječ o ispunjavanju korporativnih ciljeva, ujedno na mikro i makroekonomskoj razini. Tijekom prošlih nekoliko desetljeća obrada podataka evoluirala je od transakcijske do analitičke obrade i na poslijetku rudarenja podataka:

- OLTP (eng. *OnLine Transaction Processing*). Bilježenje velikog broja transakcijskih podataka i kreiranje jednostavnih upita i izvještaja.
- OLAP (eng. *OnLine Analytical Processing*). Kompleksna analiza velike količine podataka iz različitih vrsta izvora.
- Rudarenje podataka (Data mining). Otkrivanje obrazaca među podacima koje ne bi bilo moguće bez upotrebe suvremenih tehnologija.

Tablica 2: Temeljne razlike između OLTP i OLAP analize podataka

	OLTP(OnLine Transaction Processing)	OLAP(OnLine Analytical Processing)
Izvor podataka	Operativni podaci, OLTP su originalni podaci.	Konsolidacija podataka: OLAP podaci dolazi iz različitih OLTP baza podataka.
Namjena podataka	Kontrola i provođenje temeljnih poslovnih zadataka.	Pomoć pri planiranju, rješavanje problema i podrška odlučivanju.
Na što se podaci odnose	Prikaz poslovnih procesa koji su u tijeku.	Višedimenzijski pogled na različite vrste poslovnih aktivnosti.
Unos i ažuriranje podataka	Brzi i kratki unosi ažuriranja od strane krajnjeg korisnika.	Periodična i dugotrajna ažuriranja podataka.
Upiti	Standardizirani i jednostavni upiti koji rezultiraju s nekoliko zapisa.	Složeni upiti koji uključuju agregacije.
Brzina procesiranja upita	Vrlo brza.	Ovisno o količini podataka uključenoj u analizu: brzina procesiranja upita se može povećati indeksiranjem.
Potreban prostor za pohranu	Može biti relativno mali ukoliko su povijesni podaci arhivirani.	Velik, ovisno o agregacijskim strukturama i povijesnim podacima, zahtijeva više indeksiranja u odnosu na OLTP.
Dizajn baze podataka	Visoko normaliziran ² s mnogo tablica relacijskih baza podataka.	Obično normaliziran s nekoliko tablica – skladište podataka.
Backup i recovery	Backup je obavezan: Operacijski podaci su ključni za poslovanje. Gubitak podataka predstavlja značajni novčani gubitak i pravnu odgovornost.	Umjesto regularnog backupa, često se koristi jednostavno povlačenje OLTP podataka kao recovery metoda.

Izvor: Ćukušić M., Željko G. (2011): Višedimenzijski informacijski sustavi: Skladištenje i analitička obrada podataka, Ekonomski fakultet, Split

OLAP sustavi u načelu postoje u dva oblika, ovisno u kojem obliku su podaci pohranjeni. Pa tako razlikujemo višedimenzijski OLAP ili MOLAP (eng. *Multidimensional OLAP - MOLAP*) ukoliko su podaci pohranjeni u višedimenzijskim bazama podataka i relacijski OLAP (eng. *Relational OLAP – ROLAP*) ako su podaci pohranjeni u relacijskim bazama podataka unutar skladišta podataka.

Iz svega navedenog se može zaključiti da je riječ o dvije potpuno različite vrste analize. Bez transakcijskih podataka analitička obrada svakako ne bi ni bila moguća, no ono što tim podacima i informacijama izvedenih iz tih podataka daje prediktivnu vrijednost je upravo analitička obrada.


Neizostavni pojmovi koji se prožimaju kroz koncept skladišta podataka su veliki podaci (eng. *Big Data*) i rudarenje podataka (eng. *Data Mining*). Big data predstavlja veliku količinu

² Normalizacija je postupak organiziranja podataka s ciljem kreiranja učinkovite, pouzdane i fleksibilne baze podataka u kojoj je sačuvan integritet.

podataka tj. velike setove podataka za koje metode standardne analitičke obrade nemaju rješenje. Vrsta analize pogodna za obradu podataka uvelike ovisi i o vrsti tih podataka. Podaci za obradu mogu biti podijeljeni u nekoliko kategorija:

- Strukturirani podaci. Podaci čija forma odgovara unosu u ćelije relacijskih baza podataka i koji su mahom numerički ili kraćim riječima i oznakama prikazuju činjenično stanje opservacija. Izvorni podaci na kojima se temelji empirijski dio ovog rada su upravo strukturirani podaci.
- Nestrukturirani podaci. Ovakve podatke nije moguće unijeti i analizirati iz tradicionalnih dvodimenzionalnih tablica. Nestrukturirani podaci često uključuju tekst i multimedijski sadržaj, primjerice videa, slike, prezentacije, web stranice, poruke elektroničke pošte ili objave na društvenim mrežama.
- Polustrukturirani podaci. Također ne odgovaraju klasičnoj formi relacijskih baza podataka ali su nešto jednostavniji za obradu, na primjer podaci iz XML dokumenata.

Korištenjem suvremenih algoritama i metoda rudarenje podacima je posebno unaprijedilo analizu nestrukturiranih podataka. Najistaknutija metodologija planiranja projekta koji uključuje rudarenje podataka je CRISP DM metoda (eng. *Cross Industry Standard Process for Data Mining*). CRISP metodologija se dokazala kao vrlo uspješna pri planiranju ovakve vrste projekata, a predstavlja cikličko kretanje između aktivnosti prikazanih na sljedećoj slici.



Slika 4: Aktivnosti planiranja data mining procesa

Izvor: Prikaz autora

Što se tiče metoda analize, kod rudarenja podataka razlikujemo analizu koja koristi izlazne setove podataka (eng. *Output Sets*) za trening, odnosno učenje korištenog (eng. *Supervised Learning*) od učenja algoritma na temelju postojećeg seta podataka, koji izvršava kategorizaciju/klasteriranje podataka (eng. *Unsupervised Learning*). Prikupljeni podaci sadrže određene obrasce i informacije koje su prethodno bile skrivene zbog količine posla potrebnog za ekstrakciju takvih podataka i informacija.

U ovom radu će se koristiti operatori koji ne funkcioniraju na osnovu učenja iz primjera output seta podataka kako bi odgovarajući algoritam sam prepoznao povezanost među entitetima u bazi podataka no na temelju danih kriterija pa samim tim izvršenu analizu ne možemo definirati kao “*unsupervised learning*”.

Prepoznavajući skrivene obrasce u podacima, rudarenje podataka stvara i više nego značajnu dodanu vrijednost poduzećima i gospodarstvima koja primjenjuju ovu praksu. Pozitivni učinci premašuju nužne troškove što ostavlja analizu troškova i koristi (eng. *Cost-Benefit*) pozitivnom.

U početku je ova analiza bila dostupna isključivo velikim korporacijama zbog troška pohrane izuzetno velike količine podataka. Danas, u situaciji dostupnosti računalstva u oblaku (eng. *Cloud Computing*) i otvorenog koda (eng. *Open Source*) troškovi implementacije *Big Data*


koncepta postaju znatno manji. Svoj doprinos u poslovnom sustavu *Big Data* ostavlja ponajprije u pogledu prediktivne analize i plasiranja novih proizvoda o čemu će nešto više govora biti u nastavku. Kao kronološki najbliža analitička, rudarenje podataka postavilo je nove trendove u analizi podataka.

2.3. Koristi primjene koncepta poslovne inteligencije

Ako promatramo implementaciju poslovne inteligencije kao dugoročni projekt, a cilj tog projekta povećan profit za poslovni sustav u ekonomskim terminima, neto sadašnja vrijednost projekta bi trebala premašivati troškove istog, kako bi projekt bio isplativ. Koristi primjene poslovne inteligencije mnogo su teže mjerljive od koristi realizacije mnogih projekata koji imaju jasniji i direktniji utjecaj na profite i troškove. Unaprijeđenja koja poslovna inteligencija nudi suvremenim poduzećima uvelike ovise i o sposobnosti poslovnog sustava da iskoristi saznanja i mogućnosti BI alata i metoda na svim funkcijskim razinama u poduzeću, od operativne do strateške. Drugim riječima, dodana vrijednost koju stvara poslovna inteligencija leži u iskorištavanju mogućnosti iste unutar menadžerskih procesa koji utječu na operativnu razinu gdje se stvara prihod, reduciraju troškovi i optimizira poslovanje.

Iz šireg aspekta koristi primjene poslovne inteligencije proističu iz vizije poslovnog sustava o korištenju prednosti poslovne inteligencije u:

- Unaprijeđivanju poslovnih procesa kao što su planiranje, organiziranje, kontroliranje i monitoring u svrhu maksimizacije profita.
- Unaprijeđivanju procesa na operativnoj razini, primjerice marketinških kampanja, odnosa s kupcima, detekcije prijevara i slično, također u svrhu povećanja prihoda i redukcije troška.



Slika 5: Koristi primjene poslovne inteligencije u praksi

Izvor: Prikaz autora

Postoji niz prednosti i nedostataka implementacije poslovne inteligencije u poslovni sustav, promatrano s tehnološkog i organizacijskog aspekta. U vremenu kada informacija postaje jedan od ključnih resursa u turbulentnoj poslovnoj okolini, poslovna inteligencija otklanja mnoge nejasnoće o događajima na tržištu te omogućava poduzeću da brže i efikasnije reagira na promjene u poslovnoj okolini. Donošenje odluka na temelju pravovremenih, objektivnih i relevantnih informacija uz unaprijeđenje poslovnih procesa znatno utječe na performanse poslovnog sustava. Najistaknutije koristi primjene tehnika i metoda poslovne inteligencije navedene su u nastavku:

- Eliminiranje nedoumica o stanju u poslovnoj okolini uzrokovanih manjkom relevantnih informacija.
- Mogućnost predviđanja promjena i trendova na tržištu.
- Brži odgovori na novonastale poslovne situacije bez nepotrebnog trošenja vremena na iščitavanje povijesnih izvještaja.

- Mogućnost pristupanja ključnim informacijama u svakom trenutku i na svakom mjestu, s obzirom da mnogi proizvođači nude rješenja za pristupanje ključnim izvještajima sa mobilnih uređaja.
- Prepoznavanje potreba za promjenom te optimizacija poslovnih procesa bez koje implementacija poslovne inteligencije neće biti efikasna.
- Povećanje efikasnosti usred centraliziranosti informacija koje su dostupne onda kada su potrebne.
- Bolji uvid u rashode poslovanja, efikasnija alokacija resursa i upravljanje zalihama.
- Brzo detektiranje eventualnih nedostataka proizvoda i usluga rezultira većim zadovoljstvom korisnika.
- Efikasno otkrivanje ilegalnih radnji.
- Praćenjem i analiziranjem profitabilnosti klijenta smanjuju se poslovni rizici te se efikasnije određuje kreditni rejting klijenata primjerice u financijskoj industriji.
- Unaprijeđenje prodaje. Determiniranjem kombinacija proizvoda i usluga koje će klijenti najvjerojatnije kupiti direktno se povećavaju prihodi.
- Diverzifikacija ponude. Analizom potreba i želja klijenata generiraju se ideje ponude poduzeća u budućnosti.
- Određivanje uzroka donošenja odluke klijenta da se prikloni konkurenciji omogućuje otklanjanje istog i sprječavanje smanjenja broja klijenata u nadolazećem periodu.
- Unaprijeđenje odnosa s klijentima. Relevantnim oblicima analize poduzeća mogu klasificirati svoje korisnike, identificirati najprofitabilnije klijente te njihove potrebe. Također, analizom prodaje u poslovnicama te klikova korisnika pri online prodaji otvara se mogućnost unaprijeđenja prodajnih strategija.
- Efikasniji marketing menadžment. Osim klasifikacije i targetiranja određene skupine klijenata, koristeći suvremene alate poslovne inteligencije zaposlenici mogu iskoristiti svoje poslovno znanje u unaprijeđivanju performansi kao što je povećanje stope odgovora na direktne elektronske poruke u marketinškim kampanjama.
- Jasnija vizija povijesnog, trenutnog i željenog stanja poslovnog sustava.

Implementacija poslovne inteligencije u poduzeće obuhvaća planiranje projekta implementacije od strane projektnog menadžmenta, nabavku potrebne opreme, realizaciju projekta i održavanje komponenti novoimplementiranog sustava te zahtjeva izvrstan uvid u poslovne procese poduzeća, restrukturiranje istih te poznavanje dostupnih tehnoloških rješenja i potreba poslovnog sustava.

Uspješna realizacija ovakvih projekata donosi niz navedenih pogodnosti poduzeću, no pogrešno izvedena implementacija poslovne inteligencije može nositi izuzetno visoke gubitke u terminima vremena i financijskog troška. Sama nabavka potrebne tehnološke opreme, hardvera i softvera te održavanja istih predstavlja značajan trošak za poduzeće. Posljedično su velike korporacije u prednosti pred manjim poduzećima, kad su u pitanju projekti ove vrste.

Kao što je već spomenuto, iniciranje ovakvog projekta zahtjeva potpuno razumijevanje dostupne tehnologije i poslovnih procesa u organizaciji, kako bi se izbjegao tehnološki i poslovni rizik projekta. Većina neuspjelih BI projekata vezuju se uz loš projektni menadžment i menadžment promjena, neophodan kod restrukturiranja poslovnih procesa. Zaključno bi svakoj inicijaciji BI projekta trebala prethoditi faza pomnog planiranja realizacije.

2.4. Poslovna inteligencija na makroekonomskoj razini

U istraživanjima provedenima na regionalnoj ili nacionalnoj razini primjenjuju su se različite metode poslovne inteligencije i ekonometrije. Poslovna inteligencija i ekonometrija kao koncepti odgovaraju istom generičkom pojmu, jer se u oba slučaja radi o analitičkoj obradi podataka. Nadalje, statistika kao grana matematičke znanosti podupire ekonometrijske metode i metode poslovne inteligencije teorijskim i empirijskim saznanjima.

Bilo da se radi o matematičkim modelima, strojnom učenju (eng. *machine learning*), rudarenju podataka ili analitičkoj obradi, alati poslovne inteligencije pružaju nezamjenjivu podršku prediktivnoj analizi. Primjerice modeli neuronskih mreža su se pokazali izuzetno uspješnima i korisnima pri predviđanju financijskih kriza u prethodnim razdobljima.

Nedavna kriza 2008. godine ukazala je na opasnost nepravovremenog prepoznavanja i reagiranja na negativne trendove. Subjekti koji takve indikatore prepoznaju na vrijeme, saznanja mogu iskoristiti i posljedično spriječiti implikacije na društvo, a posebno na one dijelove gospodarstva na koje se kriza najviše reflektira.

Osim efikasnijoj analitičkoj obradi poslovna inteligencija doprinosi nizu drugih poslovnih procesa na makroekonomskoj razini na način sličan unaprijeđivanju poslovnih procesa mikroekonomskih jedinica. Navedeno se odnosi na sve sektore gospodarstva, pri čemu je najveći naglasak na prikupljanju, skladištenju, integriranju i obradi podataka i informacija.

Ako govorimo o poslovnoj inteligenciji na makroekonomskoj razini potrebno se osvrnuti i na zastupljenost prakse korištenja alata i metoda poslovne inteligencije u hrvatskim tvrtkama

budući da je tema rada upravo istraživanje poslovnih subjekata Splitsko-dalmatinske županije i mogućnosti primjene BI alata poslovne inteligencije u definiranju gospodarskog profila istih. Nesporno je da primjena poslovne inteligencije utječe na ključne indikatore performansi u svakom poduzeću.

Prema anketnom istraživanju iz 2012. godine doneseni su zaključci o korištenju poslovne inteligencije hrvatskih tvrtki s obzirom na veličinu tvrtke, djelatnost, konkurentnost te sjedište tvrtke, pri čemu su tvrtke prethodno grupirane u ovisnosti o pripadnosti jednoj od tri NUTS-2³ (fra. *Nomenclature des unités territoriales statistiques*) regije:

- sjeverozapadna,
- središnja i istočna,
- južna ili jadranska.

Sukladno rezultatima istraživanja (Bilandžić, 2012) 19% hrvatskih tvrtki ima zaseban BI odjel, 57% tvrtki prakticira neke aktivnosti poslovne inteligencije, dok 24% tvrtki nije uvelo praksu poslovne inteligencije ni u kom smislu.

Rezultati su, očekivano, pokazali da je u velikim tvrtkama najveći broj institucionaliziranih odjela za aktivnosti poslovne inteligencije (32%), što je znatno više od poduzeća manje (13%) i srednje veličine (11%). Zanimljiv podatak je da srednja poduzeća rjeđe imaju zaseban odjel za poslovnu inteligenciju od malih poduzeća, te češće ne koriste nikakve metode poslovne inteligencije.

Također je očekivano, da je najveći udio tvrtki s institucionaliziranim odjelom za aktivnosti poslovne inteligencije te tvrtki koje primjenjuju neke od aktivnosti ovog sustava smješten u sjeverozapadnoj regiji (78%), u kojoj se nalazi glavni grad, kao i velik dio stanovništva Republike Hrvatske. Južna regija koja uključuje u Splitsko-dalmatinsku županiju pak bilježi najveći broj tvrtki koje ne primjenjuju poslovnu inteligenciju (31%).

BI aktivnostima najviše se služe tvrtke u sektoru bankarstva i financija (84%) te u sektoru informacija i komunikacija (82%). Uočljivo je kako tržišni udio u najmanjoj mjeri pada upravo u tvrtkama koje imaju institucionalizirani odjel poslovne inteligencije, dok u najvećoj mjeri raste, odnosno ostaje konstantan u tvrtkama koje primjenjuju barem neke od BI aktivnosti.

³ NUTS ili Nomenklatura prostornih jedinica za statistiku je hijerarhijski sustav za identifikaciju i klasifikaciju prostornih jedinica za potrebe službene statistike u zemljama članicama Europske unije.



Slika 6: Kategorije prikupljenih podataka u hrvatskim tvrtkama koje primjenjuju barem neke BI aktivnosti ili imaju institucionalizirani BI odjel

Izvor: Bilandžić, M. et al. (2012): Business intelligence u hrvatskog gospodarstvu, Poslovna izvrsnost, 6 (1), str. 23.


Bitno je istaknuti da većina tvrtki, koje imaju institucionalizirani odjel za business intelligence aktivnosti ili primjenjuju neke aktivnosti iz ovog sustava, smatra kako taj sustav znatno pridonosi u predviđanju i upravljanju rizicima, prepoznavanju isplativih tržišnih niša, prepoznavanju snage i slabosti konkurenata, razvijanju novih profitabilnih proizvoda, praćenju vanjskih faktora koji utječu na poslovanje (politički, ekonomski, sociokulturni, tehnološki), povećanju produktivnosti, boljoj komunikaciji i suradnji unutar poduzeća, većoj sigurnosti vlastitih informacija, povećanju tržišnog udjela, ostvarenju većeg profita, uštedi vremena, razvitku, održavanju i upravljanju odnosa s krajnjim potrošačima, upravljanju ljudskim resursima, profiliranju poslovnih partnera (Bilandžić, 2012).

3. KLASITERIRANJE IZVORNIH PODATAKA

3.1. Pregled izvornih podataka

Set podataka koji označava izvorne podatke potječe iz Amadeus baze podataka te je ekstrahiran u MS Excel document koji broji 12645 opservacija. Iz seta podataka izuzeto je 5835 subjekata s najvećim brojem nedostajućih vrijednosti pokazatelja potrebnih za analizu. Prvenstveni razlog tome je nemogućnost faze klasterizacije podataka u programu RapidMiner Studio u slučaju kada set podataka prelazi 10000 opservacija. Za analizu većeg broja podataka program zahtjeva kupnju licence za poslovne subjekte, što nije bilo dostupno za provedbu ovog istraživanja. Nadalje, postoje i ograničenja u obradi te interpretaciji podataka, što će biti dodatno pojašnjeno u nastavku. Navedena aproksimacija ne bi trebala dovesti do većih oscilacija i pogrešaka u rezultatu, jer su iz razmatranja izbačeni oni subjekti koji su imali manjak podataka u odnosu na ostale, ponajviše zbog nedostupnih obračuna za neka od obračunskih razdoblja iz perioda 2009. – 2013. god. Broj preostalih opservacija za analizu iznosi 6810.

Nad tim opservacijama pomoću adekvatnog operatora zamijenjene su nedostajuće vrijednosti. Za uklanjanje nedostajućih vrijednosti RapidMiner Studio nudi *Replace Missing Values* operator, pomoću kojeg su nedostajuće vrijednosti zamijenjene prosječnim kako ne bi uzrokovale greške u narednim analizama. Podaci su prethodno iz MS Excel dokumenta u XLS formatu uvezeni u alat za rudarenje podataka, RapidMiner Studio u svrhu klasterizacije.



Slika 7: Operator Replace Missing Values

Izvor: Prikaz autora (screenshot unutar RapidMiner sučelja)

Navedene opservacije prikazane u redovima seta podataka predstavljaju tvrtke koje posluju na području Splitsko – dalmatinske županije, a razlikuju se s obzirom na sljedeće attribute:

- Ime tvrtke (s naznakom radi li se o obrtu ili određenoj vrsti trgovačkog društva)
- Grad (sjedište)

- Brojčani kod
- Slovna oznaka
- Zadnje obračunsko razdoblje
- Broj zaposlenih
- Ime vlasnika
- Datum osnivanja
- Broj dostupnih obračunskih razdoblja
- Vrsta djelatnosti
- Ukupna imovina kroz pet obračunskih razdoblja (2009. – 2013.)
- Vlasnički kapital kroz pet obračunskih razdoblja (2009. – 2013.)
- Pokazatelj tekuće likvidnosti kroz pet obračunskih razdoblja (2009. – 2013.)
- Profitna margina kroz pet obračunskih razdoblja (2009. – 2013.)

Promatrajući dane attribute u *datasetu*, može se zaključiti da se radi o organizacijskim podacima koji su nastali sumiranjem i obradom operativnih podataka pojedinih poduzeća. Agregacija podataka iz transakcijskih sustava, često je korisna upravo kod analize trendova, bilo u cjelokupnom gospodarstvu ili na pojedinim tržištima. Organizacijski podaci su, zapravo, sekundarni podaci i samim time su manje detaljni od primarnih podataka. U takvim se setovima podataka češće pojavljuju pogreške, zbog čega je potrebna detaljna priprema podataka u svrhu uklanjanja irelevantnih vrijednosti.

3.2. Odabir alata za klasteriranje

Za fazu klasterizacije odabran je alat RapidMiner Studio 7.2. Iako se samo filtriranje velikog seta podataka može obaviti i unutar MS Excel sučelja, pomoću opcije Filter, RapidMiner nudi intuitivnija i praktičnija rješenja u ovom slučaju, posebice ako se podaci grupiraju na temelju određene vrijednosti ili određenog intervala vrijednosti više atributa.

RapidMiner je open-source softverska platforma, razvijena od strane istoimene tvrtke, koja pruža integriranu razvojnu okolinu za strojno učenje, rudarenje podataka, rudarenje teksta, prediktivnu analizu i poslovnu analitiku. Nakon ETL procesa, odnosno povlačenja, transformacije i punjenja lokalne baze podataka izvornim podacima pomoću dostupnih operatora, dizajniraju se i pokreću procesi obrade. Kao izražene predosti navedenog alata potrebno je istaknuti:

- Jednostavnu instalaciju i niske zahtjeve hardverskih komponenti računala.

- Besplatnu licencu alata za krajnje korisnike.
- Intuitivno i korisnički orijentirano grafičko sučelje, koje uvelike olakšava manipulaciju podacima krajnjim korisnicima netehničkih zanimanja.
- Mogućnost instalacije dodatnih proširenja.
- Mogućnost kreiranja vlastitih algoritama pomoću Python i R skripti.


Nedostaci primijećeni tijekom obrade podataka u navedenom alatu su:

- Nemogućnost besplatne analize podataka ukoliko set podataka prelazi 10 000 opservacija.
- Eventualno duže vrijeme potrebno za finaliziranje pokrenutog procesa ukoliko se radi o većem setu podataka.

Iako RapidMiner Studio nudi veliki broj različitih algoritama i pripadajućih operatora za analizu. Za potrebe ovog istraživanja korišteno je svega nekoliko operatora. Prvi korišteni operator je spomenuti Replace Missing Values operator koji otklanja nedostajuće vrijednosti i zamjenjuje ih prosječnom vrijednošću niza ili nultom vrijednošću, ovisno o preferencijama istraživača. Za potrebe ovog istraživanja odabrana je zamjena prosječnim vrijednostima.

3.3. Izbor algoritma

Kod izbora algoritma postavlja se pitanje kojim operatorom najefikasnije razdijeliti cjelokupni set podataka na skupine po određenim kriterijima. Kada ti kriteriji nisu poznati, poseže se za “*unsupervised learning*” metodama u rudarenju podataka kako bi algoritam sam otkrio povezanost opservacija u setu po određenom obrascu koji nije prethodno definiran. Za kreiranje klastera, u ovom slučaju za grupiranje poduzeća Splitsko-dalmatinske županije, po poznatim kriterijima, takve metode neće biti potrebne. Stoga je u ovom slučaju odabran operator Filter Examples.



Slika 8: Operator Filter Examples

Izvor: Prikaz autora (screenshot unutar RapidMiner sučelja)

Filter Examples operator filtrira podatke po određenim kriterijima. U padajućem izborniku su dostupni svi atributi koje set podataka sadrži te se unosi relevantna vrijednost ili interval vrijednosti prema kojima se set filtrira. Dakle, za numeričke podatke mogu se odabrati one opservacije koje imaju vrijednost određenog atributa:

- Jednaku definiranoj vrijednosti unutar postavki operatora.
- Različitu od definirane vrijednosti unutar postavki operatora.
- Manju od definirane vrijednosti unutar postavki operatora.
- Manju ili jednaku definiranoj vrijednosti unutar postavki operatora.
- Veću od definirane vrijednosti unutar postavki operatora.
- Veću ili jednaku definiranoj vrijednosti unutar postavki operatora.

Unutar operatora može biti definiran niz različitih filtera, ovisno o potrebama istraživanja. Isto vrijedi i za kvalitativne podatke.

Potreban je poseban oprez kod definiranja filtera kako se podaci ne bi filtrirali po pogrešnom atributu, ukoliko postoji nekoliko atributa sličnih naziva, kao što je to kod skupine podataka korištene u istraživačkom dijelu rada.

Razlog tome su atributi, koji predstavljaju isti pokazatelj mjerjen u različitom periodu od pet godina. Također, ukoliko postoji pogreška kod definiranja odabranog atributa za filter, program ga neće prepoznati, te će doći do greške.

3.4. Izrada modela

Prvi korak u izradi je izvršavanje ETL, procesa gdje se podaci povlače iz MS Excel baze. Nakon što sustav prepozna podatke potrebno je definirati vrstu svih atributa u skupini podataka. Podaci mogu biti kvalitativni ili kvantitativni. Tekstualni tj. kvalitativni podaci mogu biti:

- polinomialni (eng. *Polynomial*)
- binomialni (eng. *Binomial*).

Polinomialni podaci poprimaju različite tekstualne vrijednosti atributa kao što je primjerice vrsta djelatnosti poduzeća. Binomialni podaci pak mogu poprimiti samo jednu od dvije vrijednosti atributa kao što su “Da” i “Ne”, no takvi atributi ne postoje u danoj skupini podataka.

Brojčani podaci mogu predstavljati:

- Cijele brojeve (eng. *Integer*)
- Decimalne brojeve (eng. *Real*)
- Vrijeme i datum
- Vrijeme
- Datum

Numerički podaci unutar promatrane skupine podataka poprimaju oblik cijelih brojeva kod atributa broja zaposlenih, ukupne imovine i vlasničkog kapitala, dok su pokazatelji likvidnosti i profitabilnosti izražene decimalnim brojevima.


Prilikom učitavanja podataka moguće je isključiti nepotrebne attribute, te promijeniti ime nekih atributa, ukoliko je to potrebno.

Nakon ETL procesa dizajnira se proces obrade podataka, počevši s dodavanjem relevantnog izvora podataka, koji u ovom slučaju predstavlja MS Excel datoteka.

Kao što je već navedeno, kako bi se zamijenile nedostajuće vrijednosti dodaje se *Replace Missing Values* operator koji je dio skupine operatora za čišćenje podataka (eng. *Cleansing*) obrascem cleansing → missing → replace missing values.

Slijedi dodavanje operatora *Filter Examples* za filtriranje podataka (eng. *Blending*), odnosno opservacija dostupnog unutar grupacije “*blending*” operatora (blending → examples → filter → filter examples) koji je prethodno pobliže opisan kao temeljni operator na kojem počiva kreirani proces.

Posljednji operator – *Write Excel* omogućava zapisivanje podataka direktno u MS Excel datoteku, a dostupan je unutar grupacije operatora za ispis rezultata dizajniranog procesa (data access → files → write → write excel), što uvelike olakšava daljnju analizu tih podataka.



Slika 9: Dizajnirani model procesa obrade podataka

Izvor: Prikaz autora (screenshot unutar RapidMiner sučelja)

Kreiranim modelom omogućeno je da se od cjelokupne skupine podataka kreiraju zasebne tablice, odnosno MS Excel proračunske tablice po prethodno definiranim kriterijima unutar operatora za filtriranje podataka.

3.5. Formiranje klastera

Zadatak faze klasterizacije je grupiranje opservacija koje imaju istu ili sličnu vrijednost određenog atributa u klastere, kako bi se analizirali pokazatelji svake od zasebnih grupacija.

S obzirom na dostupne attribute u skupini podataka, formirani su klasteri prema vrijednosti sljedećih atributa:

- Djelatnost poduzeća
- Mjesto sjedišta poduzeća (šest naselja s najvećim brojem stanovnika)
- Veličina poduzeća

Kako bi grupirali poduzeća s obzirom na djelatnost, operator za filtriranje podataka postavljen je na način da izdvaja opservacije, čija vrijednost atributa djelatnost poduzeća poprima određeni nominalni oblik. Atribut djelatnosti poduzeća poprima sljedeće oblike (u zagradama su dani originalni nazivi iz seta podataka, te skraćenice korištene u daljnjem radu):

- Poljoprivreda (Agriculture – AGR.)
- Rudarenje i ekstrakcija (Mining and quarrying – MIN.)
- Proizvodnja (Manufacturing – MAN.)
- Industrije vezane uz izvore energije (Electricity, gas, steam and air conditioning supply – ELEC.)

- Industrija vode i gospodarenja otpadom (Water supply; sewerage, waste management and remediation activities – WATER)
- Građevinarstvo (Construction – CON.)
- Maloprodaja i veleprodaja, te popravka motornih vozila i motocikala (Wholesale and retail trade; repair of motor vehicles and motorcycles – WHO&RET)
- Transport i skladištenje (Transportation and storage – TRA.)
- Turizam i ugostiteljstvo (Accommodation and food service activities – ACC.)
- Pružanje informacijskih i komunikacijskih usluga (Information and communication – INF.)
- Pružanje financijskih i osiguravajućih usluga (Financial and insurance activities – FIN.)
- Posredovanje u trgovini nekretninama (Real estate activities – R.E.)
- Pružanje profesionalnih, znanstvenih i tehničkih usluga (Professional, scientific and technical activities – PROF.)
- Administracija (Administrative and support service activities – ADM.)
- Javna uprava (Public administration and defence; compulsory social security – P.A.)
- Edukacija (Education – EDU.)
- Pružanje zdravstvenih i socijalnih usluga (Human health and social work activities – HEA.)
- Umjetnost, zabava i rekreacija (Arts, entertainment and recreation – ART.)
- Ostale usluge (Other service activities – OTHER)



Grafikon 1: Distribucija poduzeća s obzirom na djelatnost poduzeća iz cjelokupnog seta podataka

Izvor: Prikaz autora (screenshot grafikona izrađenog unutar sučelja alata MS Excel)

Analogno klasteriranju s obzirom na djelatnost poduzeća, grupiraju se opservacije, tj. poduzeća s obzirom na mjesto sjedišta. Pritom se, s najvećim brojem registriranih poduzeća, izdvajaju najveći gradovi u Splitsko-dalmatinskoj županiji:

- Split
- Kaštela
- Solin
- Makarska
- Sinj
- Trogir



Grafikon 2: Distribucija poduzeća po mjestu sjedišta poduzeća iz cjelokupnog seta podataka


Izvor: Prikaz autora (screenshot grafikona izrađenog unutar sučelja alata MS Excel)

Pri grupiranju poduzeća s obzirom na veličinu potrebno je uzeti u obzir dva od tri kriterija. U danom *datasetu* nema dostupnih informacija o prihodima poduzeća, pa se veličina poduzeća određuje s obzirom na kriterij broja zaposlenih i ukupne aktive, sukladno sa Zakonom o računovodstvu. Dakle, za razliku od prethodna dva slučaja, ovdje je potrebno postaviti dva filtera za kvantitativne podatke.

Tablica 3: Kriteriji kategorizacije poduzeća po veličini

Veličina poduzeća	Kriteriji	Iznos u kunama
Mala poduzeća (trebaju imati ispunjena dva od navedena tri kriterija)	Ukupna aktiva	< 32.500.000,00 kn
	Ukupan prihod	< 65.000.000,00 kn
	Broj zaposlenih	< 50
Srednja poduzeća (trebaju imati ispunjena dva od navedena tri kriterija)	Ukupna aktiva	< 130.000.000,00 kn
	Ukupan prihod	< 260.000.000,00 kn
	Broj zaposlenih	< 250
Velika poduzeća (trebaju premašiti barem dva kriterija za srednja poduzeća)		

Izvor: Ramljak, B.(2009): Stanje i perspektive razvoja financijskog izvještavanja za mala i srednja poduzeća u Hrvatskoj, Ekonomski fakultet, Split



Grafikon 3: Distribucija poduzeća s obzirom na djelatnost poduzeća iz cjelokupnog seta podataka

Izvor: Prikaz autora (screenshot grafikona izrađenog unutar sučelja alata MS Excel)

4. ANALIZA EKONOMSKIH POKAZATELJA PO KLASITERIMA

4.1. Izbor alata za analizu

Za analizu podataka odabran je program MS Excel, koji predstavlja vodeći softver za kreiranje proračunskih tablica. MS Excel nudi mnoštvo opcija i mogućnosti, od samog kreiranja tablica, analize istih, grafičkog prikazivanja pa do rudarenja podataka, ukoliko su dodana potrebna proširenja i alati. Za ovo istraživanje su posebno važne funkcije MS Excel alata, koje su unutar sučelja podijeljene ovisno o namjeni. Za potrebe ovog istraživanja, dovoljan je ručni unos formula za potrebne proračune, te osnovne formule navedenog alata za izračun prosjeka, minimuma, maksimuma i zbroja vrijednosti željenih pokazatelja. Koristit će se i "IF" funkcija pri izračunu određenih vrijednosti kako sustav ne bi detektirao grešku, konkretno prilikom dijeljenja s nulom. Takvi primjeri su malo zastupljeni nakon eliminacije nekonzistentnih podataka, no za ostatak takvih podataka je neizbježno dodavanje funkcije.

4.2. Analiza ekonomskih pokazatelja za klastere formirane s obzirom na djelatnost poduzeća

U ovom djelu rada komentirat će se vrijednosti pokazatelja u određenom vremenskom trenutku, dok će trendovi biti pojašnjeni uz grafički prikaz kretanja tih pokazatelja u sljedećem dijelu istraživanja. Ispituju se razlike u vrijednosti pokazatelja promatranih klastera u ovisnosti o djelatnosti tj. klasteru kojem opservacije pripadaju.

4.2.1. Zaposlenost

Prvenstveno se ispituju željeni pokazatelji klastera podijeljenih s obzirom na djelatnost poduzeća. Sumiran je broj zaposlenih za svaki zasebni klaster koristeći funkciju SUM unutar sučelja alata MS Excel, te maksimalan i minimalan broj zaposlenih pomoću funkcija MIN i MAX, kako bi se otkrilo u kojoj industriji je zaposleno najviše, a u kojoj najmanje djelatnika. Sljedeće tablice prikazuju rezultat sumiranja i uprosječivanja vrijednosti za pokazatelje ukupne i prosječne zaposlenosti.

Tablica 4: Broj zaposlenih u klasterima poduzeća formiranim s obzirom na djelatnost

	Broj zaposlenih
ACC.	6379
ADM.	3507
AGR.	1058
ART.	1083
CON.	11533
WHO&RET	21867
WATER	1949
TRA.	4240
R.E.	3233
P.A.	10
PROF.	5619
OTHERS.	1117
MIN.	327
MAN.	12157
INF.	1609
HEA.	550
FIN.	132
ELEC.	67
EDU.	528

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Prema rezultatima MAX funkcije u Excelu, najviše djelatnika je zaposleno u sektoru maloprodaje i veleprodaje (21867 zaposlenih) čiji dio je i djelatnost popravka motornih vozila. Sljedeće po broju djelatnika je proizvodnja (12157 zaposlenih), pa zatim sektor građevinarstva (11533 zaposlena). Najmanje ih je, pak, uposleno u djelatnosti pružanja informacijskih i komunikacijskih usluga što je vidljivo i u tablici (10 zaposlenih).

Tablica 5: Prosječan broj zaposlenih u klasterima poduzeća formiranim s obzirom na djelatnost

	Prosječan broj zaposlenih po poduzeću
ACC.	12.10
ADM.	11.30
AGR.	10.50
ART.	16.20
CON.	11.50
WHO&RET	11.30
WATER	39.80
TRA.	14.00
R.E.	9.20
P.A.	3.30
PROF.	6.10
OTHERS.	7.70
MIN.	14.90
MAN.	15.80
INF.	9.80
HEA.	8.70
FIN.	5.30
ELEC.	9.60
EDU.	11.20

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Najmanji prosječan broj zaposlenih broji djelatnost pružanja informacijskih i komunikacijskih usluga (3.30 ~ 3 zaposlena), a najveći industrija vode i gospodarenja otpadom (39.80 ~ 40 zaposlenih).

4.2.2. Stopa rasta vrijednosti imovine

Vrijednost imovine u danom setu podataka predstavlja trenutni vremenski niz promatranog pokazatelja za pet vremenskih razdoblja (razdoblja od 2009. – 2013. godine). Vremenski niz je skup kronološki uređenih vrijednosti pojave. Kod trenutačnog vremenskog niza vrijednost pojave mjeri se u trenutku vremena (Pivac et al., 2009). Postotna promjena vrijednosti nekog pokazatelja kroz vrijeme može se mjeriti na dva načina:

- Verižnim indeksima
- Baznim indeksima.

Verižni indeksi ukazuju na postotnu promjenu vrijednosti nekog pokazatelja u tekućem razdoblju u odnosu na prethodno razdoblje, dok bazni indeksi pokazuju promjenu vrijednosti

pokazatelja u odnosu na vrijednost tog pokazatelja u odabranom baznom razdoblju. Osim verižnih i baznih indeksa promjena vrijednosti nekog pokazatelja kroz vrijeme može se pratiti i pomoću stope promjene. Upravo je stopa promjene u odnosu na bazno razdoblje odabrana za analizu stope rasta vrijednosti imovine u ovom istraživanju kako bi što jasnije prikazali promjenu pokazatelja u odnosu na postrecesijsko razdoblje 2009. godine. Formula za izračun stope promjene je sljedeća:

$$S_t = \left(\frac{Y_t}{Y_b} - 1 \right) \cdot 100, \quad t = 1, 2 \dots N$$

Pri čemu S_t predstavlja stopu promjene s obzirom na bazno razdoblje, odnosno postotnu promjenu vrijednosti u odnosu na bazno razdoblje, Y_t predstavlja vrijednost pokazatelja za tekuće razdoblje, a Y_b vrijednost pokazatelja za bazno razdoblje. Formula za stopu promjene unesena je u dodani stupac za svaku od promatranih tablica odnosno klastera koji su prethodno definirani, te je izračunata prosječna stopa promjene vrijednosti imovine za svaki klaster pomoću funkcije AVERAGE. Uobičajeno se prosječna stopa promjene računa geometrijskom sredinom niza za verižne indekse, zbog nedostatka prve vrijednosti u nizu, kada se razmatraju verižni indeksi. Kako su u ovom slučaju odabrani bazni indeksi, tj. stopa promjene u odnosu na bazno razdoblje, zbog analize post-recesijskih kretanja, navedeno neće biti potrebno.

Tablica 6: Stopa rasta vrijednosti imovine u klasterima poduzeća formiranim s obzirom na djelatnost

	Stopa rasta vrijednosti imovine 2010.	Stopa rasta vrijednosti imovine 2011.	Stopa rasta vrijednosti imovine 2012.	Stopa rasta vrijednosti imovine 2013.
ACC.	639.98	968.73	1865.82	2873.96
ADM.	135.48	829.57	1665.53	2714.37
AGR.	32.73	524.25	618.22	811.42
ART.	482.26	906.77	835.19	2345.15
CON.	512.42	890.67	1758.52	2431.11
WHO&RET	518.07	893.70	1178.60	1918.21
WATER	821.03	1279.21	1346.66	2045.89
TRA.	618.12	755.23	774.22	1298.90
R.E.	1258.03	2431.68	3000.06	4447.25
P.A.	4.07	-2.98	2.48	7.27
PROF.	468.35	732.10	1166.32	2209.86
OTHERS.	729.59	1046.85	2382.84	3377.85
MIN.	596.98	1317.93	2357.99	2394.19
MAN.	487.15	1992.37	2525.01	3028.66
INF.	74.17	552.45	866.00	1251.52
HEA.	82.43	193.60	251.60	368.83
FIN.	40.43	-14.74	1997.69	2153.77
ELEC.	2.75	-1.70	5755.64	15270.11
EDU.	16.79	832.32	2425.18	3027.33

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Najveći rast vrijednosti imovine u 2010. godini bilježi djelatnost posredovanja u trgovanju nekretninama u odnosu na prethodnu i ujedno baznu 2009. godinu što se eventualno može objasniti naglim padom cijena nekretnina u recesijskom razdoblju, dok u posljednjem promatranom razdoblju industrija energetike, prvenstveno električne energije bilježi najveći porast vrijednosti imovine u odnosu na recesijsko razdoblje.

Najuravnoteženiji rast ovog pokazatelja primjećen je u djelatnosti turizma i ugostiteljstva, administraciji i građevinarstvu.

Recesijskim razdobljem je naizgled najviše pogođena javna uprava, no ako pogledamo utjecaj recesije sa šireg aspekta vidljivo je da su djelatnosti pružanja financijskih usluga i energetike doživjele rast vrijednosti imovine u prvoj promatranjoj godini, te pad vrijednosti imovine u 2012. godini u odnosu na baznu 2009.

4.2.3. Stopa rasta vlastitog kapitala

Tablica 7: Stopa rasta vlastitog kapitala u klasterima poduzeća formiranim s obzirom na djelatnost

	Stopa rasta vlastitog kapitala 2010.	Stopa rasta vlastitog kapitala 2011.	Stopa rasta vlastitog kapitala 2012.	Stopa rasta vlastitog kapitala 2013.
ACC.	564.67	820.24	1594.13	2943.79
ADM.	49.91	548.75	736.79	1432.86
AGR.	61.87	-444.06	821.95	1097.53
ART.	165.11	477.69	380.75	1430.99
CON.	325.32	491.24	772.61	1409.90
WHO&R	259.30	510.80	800.63	1501.29
WATER	310.96	500.75	466.85	1120.40
TRA.	510.06	575.63	656.35	1057.82
R.E.	1741.52	1602.34	1998.21	3305.40
P.A.	5.97	-3.29	2.04	-7.63
PROF.	317.55	339.96	640.43	1307.78
OTHERS	153.10	341.18	1002.24	1857.32
MIN.	785.43	985.70	2007.86	2371.36
MAN.	263.16	1004.36	1192.18	1756.80
INF.	130.71	670.36	645.21	1138.15
HEA.	30.56	236.57	215.07	606.36
FIN.	15.57	-37.84	573.23	712.03
ELEC.	-115.23	-175.46	1715.71	5204.10
EDU.	221.78	498.39	1084.59	1312.37

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Iz tablice je vidljivo da su kretanja i vrijednosti stope rasta vlastitog kapitala analogne kretanjima i vrijednostima stope rasta vrijednosti imovine. I u ovom slučaju pad vrijednosti imovine u odnosu na vrijednost iz bazne godine bilježe javna uprava, te djelatnosti energetike i pružanja financijskih usluga. Međutim, stopa rasta kapitala za industriju poljoprivrede u 2011. godini se vidno razlikuje od stopa za ostale opervacije, te trendova kretanja stope rasta vrijednosti vlastite imovine za istu industriju s izraženim padom vrijednosti kapitala u odnosu na baznu godinu.

Iz dosadašnje analize se može zaključiti da je kod djelatnosti turizma i ugostiteljstva zabilježen najstabilniji rast tijekom svih razdoblja što je i očekivano s obzirom da se istraživanje temelji na analizi poduzeća iz županije orijentirane turizmu kao primarnoj djelatnosti.

4.2.4. Analiza likvidnosti

Pokazatelj tekuće likvidnosti je najrelevantniji indikator likvidnosti, odnosno sposobnosti poduzeća da svojom kratkotrajnom imovinom podmiri kratkotrajne obveze. Računa se

dijeljenjem kratkotrajne imovine (koja obuhvaća gotovinu, utržive dionice, potraživanja i zalihe) s kratkoročnim obvezama.

$$\text{Pokazatelj tekuće likvidnosti} = \frac{\text{Kratkotrajna imovina}}{\text{Kratkoročne obveze}}$$

Ocjena vrijednosti pokazatelja vrši se usporedbom s prosjekom industrije i analizom trenda. Pokazatelj mora iznositi minimalno vrijednost 1.0, kako bi poduzeće bilo u mogućnosti podmiriti svoje kratkoročne obveze. Preporučuje se da pokazatelj iznosi minimalno 1.5 kako se ne bi pojavili problemi nelikvidnosti. No, ponekad ni pokazatelj od 1.0 ne mora predstavljati poteškoću ako tvrtka uspješno upravlja potraživanjima i zalihama, dok u nekim slučajevima prevelika vrijednost pokazatelja likvidnosti može kao uzrok imati loše upravljanje kratkoročnom imovinom (Vidučić, 2006).

Prosječna stopa likvidnosti izračunata je uprosječivanjem vrijednosti za sva pojedina razdoblja korištenjem funkcije AVERAGE.

Tablica 8: Prosječna likvidnost u klasterima poduzeća formiranim s obzirom na djelatnost

	Prosječna stopa likvidnosti 2013.	Prosječna stopa likvidnosti 2012.	Prosječna stopa likvidnosti 2011.	Prosječna stopa likvidnosti 2010.	Prosječna stopa likvidnosti 2009.
ACC.	4.90	5.41	4.95	4.61	4.36
ADM.	4.27	3.62	3.56	3.96	3.31
AGR.	2.98	3.12	2.24	2.57	1.92
ART.	4.40	4.48	2.55	4.59	2.54
CON.	2.99	2.71	2.95	3.47	2.92
WHO&RET	2.95	2.69	2.71	3.10	2.77
WATER	1.77	1.76	1.73	2.01	1.70
TRA.	2.90	3.20	2.81	2.81	3.22
R.E.	4.24	5.07	5.21	6.20	5.18
P.A.	21.49	4.23	15.76	16.04	2.44
PROF.	4.00	3.80	4.49	4.69	3.92
OTHERS.	2.58	2.91	3.13	2.58	2.56
MIN.	2.92	1.61	2.13	1.94	4.12
MAN.	3.61	3.03	2.92	3.09	2.66
INF.	3.14	2.81	2.82	2.57	2.58
HEA.	3.74	2.36	3.08	3.63	4.25
FIN.	4.37	3.69	4.85	3.93	5.16
ELEC.	4.03	2.30	7.59	1.90	6.94
EDU.	1.95	2.00	1.66	3.10	2.60

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

U 2009. godini najlikvidnija industrija je industrija energetike. Kroz promatrana razdoblja najniže pokazatelje likvidnosti prikazuje industrija vode i gospodarenja otpadom, no ni jedna industrija ne ukazuje na nelikvidnost.

Kod većine opservacija nema većih oscilacija vrijednosti pokazatelja likvidnosti osim kod javne uprave na temelju čega možemo zaključiti da se s obzirom na djelatnost poduzeća likvidnost nije znatno mijenjala u postrecesijskom razdoblju. Djelatnosti s najboljim i najstabilnijim pokazateljem likvidnosti su: djelatnost turizma i ugostiteljstva te pružanja financijskih usluga, administracija, sektor zdravstva i djelatnost pružanja profesionalnih, znanstvenih i tehničkih usluga.

4.2.5. Analiza profitnih marži

Profitna marža jedan je od pokazatelja profitabilnosti poduzeća, a mjeri se u odnosu na obujam prodaje. Niska profitabilnost, ukoliko se trenutno stanje ne promijeni u narednim periodima, zasigurno ukazuje na propast poduzeća u budućnosti, pa je svakom pojedinom gospodarskom subjektu u interesu imati što veću profitnu maržu (Vidučić, 2006). Formula za izračunavanje profitne marže je sljedeća:

$$\text{Profitna marža} = \frac{\text{Vrijednost prodaje} - \text{Troškovi za prodano}}{\text{Vrijednost prodaje}}$$

Tablica 9: Prosječna profitna marža u klasterima poduzeća formiranim s obzirom na djelatnost

	Prosječna profitna margina 2013.	Prosječna profitna margina 2012.	Prosječna profitna margina 2011.	Prosječna profitna margina 2010.	Prosječna profitna margina 2009.
ACC.	5.18	0.88	0.65	0.03	2.54
ADM.	1.62	0.83	0.76	3.04	6.88
AGR.	-4.75	-0.61	-0.03	-1.15	2.88
ART.	0.00	1.09	5.44	1.11	7.33
CON.	2.00	0.36	1.08	0.41	6.31
WHO&RET	1.89	0.40	0.40	0.68	2.61
WATER	2.81	1.31	0.56	0.08	0.22
TRA.	4.20	3.88	2.42	2.59	4.12
R.E.	1.38	2.39	1.89	2.45	8.56
P.A.	27.35	49.76	28.92	33.44	63.53
PROF.	8.41	7.05	8.25	9.47	13.01
OTHERS.	1.47	-3.13	-0.92	-1.17	0.72
MIN.	5.09	11.32	7.44	4.49	10.69
MAN.	2.26	0.83	0.29	1.62	4.81
INF.	7.56	6.94	5.74	6.47	8.63
HEA.	4.39	1.74	7.84	9.84	9.04
FIN.	9.15	12.96	5.88	7.78	11.59
ELEC.	5.32	9.56	-1.40	10.84	13.97
EDU.	3.14	1.36	-0.18	2.73	0.75

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Kao najprofitabilnija djelatnost tijekom promatranih vremenskih razdoblja izdvaja se javna uprava, dok je najneprofitabilnija poljoprivreda sa negativnim pokazateljem profitne marže u postrecesijskom razdoblju od 2010. godine do 2013. godine uključujući početnu i završnu godinu. Visoke stope profitabilnosti pokazuje i financijska industrija, te djelatnost pružanja informatičkih i komunikacijskih usluga kao i djelatnost pružanja profesionalnih, znanstvenih i tehničkih usluga.

Djelatnost turizma i ugostiteljstva do posljednjeg razdoblja trpi vrlo nizak pokazatelj profitabilnosti kao posljedicu negativnog utjecaja recesije.

Uz poljoprivredu najneprofitabilnija djelatnost u posljednjem promatranom razdoblju je umjetnost, zabava i rekreacija.

4.3. Analiza ekonomskih pokazatelja za klastere formirane s obzirom na mjesto sjedišta poduzeća

Za šest najvećih mjesta u Splitsko-dalmatinskoj županiji izvršena je zasebna analiza željenih pokazatelja, na temelju koje se donose zaključci o uspješnosti poslovanja poduzeća Splitsko-dalmatinske županije s obzirom na mjesto sjedišta.

4.3.1. Zaposlenost

Tablica 10: Broj zaposlenih u klasterima poduzeća formiranim s obzirom na mjesto sjedišta

	Broj zaposlenih
KAŠTELA	2916
MAKARSKA	2092
SINJ	1554
SOLIN	4296
SPLIT	38799
TROGIR	1662

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Najveći broj zaposlenih je očekivano zabilježen u Splitu (38799 zaposlenih) odnosno u tvrtkama čije je sjedište u Splitu, sukladno činjenici da je Split najveći grad u županiji i po površini i po broju stanovnika. Najmanji broj zaposlenih broje tvrtke sa sjedištem u gradu Sinju (1554 zaposlena).

Tablica 11: Prosječan broj zaposlenih u klasterima poduzeća formiranim s obzirom na mjesto sjedišta

	Prosječan broj zaposlenih po poduzeću
KAŠTELA	13.81
MAKARSKA	9.40
SINJ	9.80
SOLIN	16.50
SPLIT	10.90
TROGIR	8.90

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Naspram apsolutnog broja zaposlenih, najveći broj zaposlenih po poduzeću (16.50 ~ 17 zaposlenih) broji grad Solin, dok najveći grad županije Split ima manje (10.90 ~ 11 zaposlenih) po poduzeću. Navedeno se može objasniti manjim brojem poduzeća na području grada Solina, te činjenicom da u Solinu, među manjim brojem poduzeća (262 poduzeća), sjedište imaju tri velika poduzeća, a to su AD Plastik d.d. (894 zaposlena), Građa d.d. (413 zaposlenih) i Market Svaguša (250 zaposlenih). Najniža prosječna zaposlenost zabilježena je u klasteru poduzeća sa sjedištem u Trogiru (8.90 ~ 9 zaposlenih).

4.3.2. Stopa rasta vrijednosti imovine

Tablica 12: Stopa rasta vrijednosti imovine u klasterima poduzeća formiranim s obzirom na mjesto sjedišta

	Stopa rasta vrijednosti imovine 2010.	Stopa rasta vrijednosti imovine 2011.	Stopa rasta vrijednosti imovine 2012.	Stopa rasta vrijednosti imovine 2013.
KAŠTELA	5.04	10.71	5.20	84.95
MAKARSKA	443.93	591.83	747.73	1318.66
SINJ	129.21	510.44	1391.82	1947.78
SOLIN	284.23	812.62	1585.32	2322.31
SPLIT	548.36	889.92	1255.23	2073.31
TROGIR	230.36	1199.89	1566.76	2337.53

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Ni jedan od promatranih gradova ne bilježi pad imovine u odnosu na baznu 2009. godinu no Kaštela zasigurno bilježe najsporiji rast vrijednosti imovine u 2010. godini. Ne možemo govoriti o odnosu vrijednosti i brzini promjene pokazatelja među promatranim razdobljima jer se analiza temelji na istraživanju promjene vrijednosti pokazatelja u odnosu na bazno razdoblje 2009. godine. Međutim kada bi se stopa promjene računala za prethodno razdoblje a ne baznu godinu, vidljivo je da bi samo Kaštela bilježila pad, i to u 2012. godini.

4.3.3. Stopa rasta vlastitog kapitala

Tablica 13: Stopa rasta vlastitog kapitala u klasterima poduzeća formiranim s obzirom na mjesto sjedišta

	Stopa rasta vlastitog kapitala 2010.	Stopa rasta vlastitog kapitala 2011.	Stopa rasta vlastitog kapitala 2012.	Stopa rasta vlastitog kapitala 2013.
KAŠTELA	-13.72	-63.11	-78.15	-54.69
MAKARSKA	254.08	231.95	631.88	1165.29
SINJ	147.95	316.39	707.80	1548.56
SOLIN	699.70	1139.55	1346.78	2160.05
SPLIT	373.14	566.23	741.53	1450.29
TROGIR	74.04	936.84	1214.41	2328.35

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Slično kao i u prethodnom slučaju, Kaštela imaju najnepovoljnije pokazatelje s ubrzanim padom vrijednosti vlastitog kapitala u odnosu na bazno razdoblje, koji se počinje smanjivati tek u 2013. godini.

4.3.4. Analiza likvidnosti

Tablica 14: Prosječna likvidnost u klasterima poduzeća formiranim s obzirom na mjesto sjedišta

	Prosječna stopa likvidnosti 2013.	Prosječna stopa likvidnosti 2012.	Prosječna stopa likvidnosti 2011.	Prosječna stopa likvidnosti 2010.	Prosječna stopa likvidnosti 2009.
KAŠTELA	3.27	2.68	3.76	3.35	1.62
MAKARSKA	3.85	3.29	4.12	3.86	3.41
SINJ	3.83	3.33	3.01	2.57	3.00
SOLIN	2.82	3.00	2.88	3.48	2.72
SPLIT	3.36	3.24	3.33	3.63	3.27
TROGIR	3.22	2.96	4.35	4.91	3.40

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Prosječna stopa likvidnosti za svaki od gradova u razmatranju je vrlo slična te nema većih oscilacija što je i vidljivo u tablici. Eventualno se može napomenuti da u post-recesijskoj godini poduzeća u Kaštelima bilježe prosječno najnižu stopu likvidnosti, u usporedbi s drugim klasterima.

4.3.5. Analiza profitnih marži

Tablica 15: Prosječna profitna marža u klasterima poduzeća formiranim s obzirom na mjesto sjedišta

	Prosječna profitna margina 2013.	Prosječna profitna margina 2012.	Prosječna profitna margina 2011.	Prosječna profitna margina 2010.	Prosječna profitna margina 2009.
KAŠTELA	1.74	0.28	-0.44	-0.76	5.56
MAKARSKA	3.31	0.56	0.25	1.38	3.57
SINJ	2.11	0.45	2.74	3.98	0.90
SOLIN	3.04	2.07	2.06	3.55	4.89
SPLIT	4.17	2.58	2.72	3.18	6.82
TROGIR	1.22	0.67	2.50	1.41	7.56

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Najprofitabilniji grad s obzirom na prosječnu profitnu marginu svih poslovnih subjekata je grad Split, a Kaštela i u ovoj analizi ukazuju na najnepovoljniji trend s negativnim pokazateljem profitabilnosti od 2010. Godine, koji postaje pozitivan tek u predzadnjem promatranom razdoblju.

4.4. Analiza ekonomskih pokazatelja za klastere formirane s obzirom na veličinu poduzeća

Poduzeća su prethodno podijeljena po veličini s obzirom na kriterije definirane Zakonom o računovodstvu te je provedena analiza financijskih pokazatelja za novonastale klastere.

4.4.1. Zaposlenost

Tablica 16: Broj zaposlenih u klasterima poduzeća formiranim s obzirom na veličinu

	Broj zaposlenih
MALA PODUZEĆA	49428.00
SREDNJA PODUZEĆA	13326.00
VELIKA PODUZEĆA	14611.00

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Najviše djelatnika u Splitsko – dalmatinskoj županiji zaposleno je u malim poduzećima (49428 zaposlenih). Zatim slijede velika poduzeća (14611 zaposlenih), te naposljetku srednja poduzeća (13326 zaposlenih).

Tablica 17: Broj zaposlenih u klasterima poduzeća formiranim s obzirom na veličinu

	Prosječan broj zaposlenih po poduzeću
MALA PODUZEĆA	7.40
SREDNJA PODUZEĆA	104.90
VELIKA PODUZEĆA	562.00

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Prosječno je najviše djelatnika po poduzeću zaposleno u velikim poduzećima (562 zaposlena), zatim u srednjim (104.90 ~ 105 zaposlenih), dok je u malim poduzećima prosječan broj zaposlenih po poduzeću najniži (7.40 ~ 7 zaposlenih), što je očekivano s obzirom da su, od ukupno 6810 promatranih poslovnih subjekata, 6661 promatranih subjekata mala poduzeća.

4.4.2. Stopa rasta vrijednosti imovine

Tablica 18: Stopa rasta vrijednosti imovine u klasterima poduzeća formiranim s obzirom na veličinu

	Stopa rasta vrijednosti imovine 2010.	Stopa rasta vrijednosti imovine 2011.	Stopa rasta vrijednosti imovine 2012.	Stopa rasta vrijednosti imovine 2013.
MALA PODUZEĆA	466.76	1008.01	1553.97	2374.89
SREDNJA PODUZEĆA	3434.93	3663.82	3496.18	3315.28
VELIKA PODUZEĆA	-3.57	-5.40	-0.31	9.50

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Stopa vrijednosti imovine ukazuje na najpovoljniji trend kod malih poduzeća, a najnepovoljniji kod velikih poduzeća, koja tek u 2012. godini počinju s oporavkom od recesije, da bi u 2013. godini ovaj pokazatelj za velika poduzeća konačno poprimio pozitivan predznak. Vrijednost imovine srednjih poduzeća, nakon prvog promatranog razdoblja, bilježi neznatne promjene.

4.4.3. Stopa rasta vlastitog kapitala

Tablica 19: Stopa rasta vlastitog kapitala u klasterima poduzeća formiranim s obzirom na veličinu

	Stopa rasta vlastitog kapitala 2010.	Stopa rasta vlastitog kapitala 2011.	Stopa rasta vlastitog kapitala 2012.	Stopa rasta vlastitog kapitala 2013.
MALA PODUZEĆA	372.54	614.46	946.78	1680.47
SREDNJA PODUZEĆA	203.81	320.80	66.70	589.28
VELIKA PODUZEĆA	-14.92	-24.41	-20.13	23.33

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Kao i u dosadašnjim primjerima, kretanje stope rasta kapitala vjerno prati trendove kretanja stope rasta vrijednosti imovine, pa i u ovom slučaju mala poduzeća imaju izraženi rast ovog pokazatelja, dok velika poduzeća, kao i kod prethodnog pokazatelja, bilježe pad vrijednosti kapitala do razdoblja 2013. godine.

4.4.4. Analiza likvidnosti

Tablica 20: Prosječna likvidnost u klasterima poduzeća formiranim s obzirom na veličinu

	Prosječna stopa likvidnosti 2013.	Prosječna stopa likvidnosti 2012.	Prosječna stopa likvidnosti 2011.	Prosječna stopa likvidnosti 2010.	Prosječna stopa likvidnosti 2009.
MALA PODUZEĆA	3.50	3.33	3.40	3.70	3.26
SREDNJA PODUZEĆA	1.76	1.72	1.58	1.84	1.75
VELIKA PODUZEĆA	1.73	1.73	1.93	1.77	1.58

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Iz rezultata je vidljivo da svi klasteri zadovoljavaju minimalan iznos stope likvidnosti kako bi mogli podmiriti dospelje obveze s tim da velika i srednja poduzeća bilježe vrijednosti na donjoj granici prihvatljive stope likvidnosti dok su mala poduzeća likvidnija.

4.4.5. Analiza profitnih marži

Tablica 21: Prosječna profitabilnost u klasterima poduzeća formiranim s obzirom na veličinu

	Prosječna profitna margina 2013.	Prosječna profitna margina 2012.	Prosječna profitna margina 2011.	Prosječna profitna margina 2010.	Prosječna profitna margina 2009.
MALA PODUZEĆA	3.30	1.90	2.09	2.46	5.75
SREDNJA PODUZEĆA	0.50	-0.78	-2.62	-1.28	0.81
VELIKA PODUZEĆA	2.25	5.24	2.94	1.94	2.38

Izvor: Izračun autora (screenshot proračunske tablice unutar MS Excel sučelja)

Prema rezultatima analize može se uvrđiti da su prosječne profitne marže vrlo slične u malim i velikim poduzećima, s tim da mala poduzeća imaju nekoliko postotnih poena prednosti. Sukladno tome, zaključujemo da su mala poduzeća najprofitabilnija u Splitsko – dalmatinskoj županiji. S druge strane, srednja poduzeća u tri razdoblja bilježe negativne pokazatelje. Sumarno, mala poduzeća bilježe najpovoljnije pokazatelje u postrecesijskom razdoblju.

5. Vizualizacija

5.1. Odabir alata

Za vizualizaciju rezultata dobivenih u fazi analize odabran je alat Tableau, kao jedan od vodećih alata za vizualizaciju podataka, koji se ističe interaktivnim i korisnički orijentiranim sučeljem, kao i širokim spektrom mogućnosti obrade i vizualizacije podataka.

Izvršno dizajnirano grafičko korisničko sučelje omogućuje analizu i kreiranje grafičkih prikaza korištenjem jednostavne *drag&drop* tehnike. Nakon povezivanja s izvorom podataka i otvaranja nove proračunske tablice moguće je dodavati mjere i dimenzije u redove ili stupce tabelarnog prikaza, ovisno o preferencijama korisnika.

Za proračunske tablice koristi se samo jedna dimenzija, no Tableau nudi rješenja i za mnogo složenije izvore podataka mogućnošću povezivanja sa relacijskim bazama podataka, Hadoop-om⁴, pa čak i podacima u oblaku.

Najveća prednost je upravo interaktivno sučelje i direktna vizualizacija analiziranih podataka, što omogućava korisniku jednostavniju uporabu alata i prepoznavanje trendova kretanja analiziranih pokazatelja


5.2. Vizualizacija analize ekonomskih pokazatelja za klastere formirane s obzirom na djelatnost poduzeća

5.2.1. Zaposlenost

U grafikone koji prikazuju apsolutni i relativni broj zaposlenih kategorije poduzeća su prikazane hijerarhijski, počevši s klasterom poduzeća s najvećim brojem zaposlenih i ujedno najbližim osi apscise.

⁴ Hadoop je besplatna programska okolina temeljena na Java programskom jeziku koja podržava procesiranje velikih setova podataka.


Zaposlenost s obzirom na djelatnost poduzeća



Grafikon 4: Broj zaposlenih s obzirom na djelatnost poduzeća

Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)

Prosječan broj zaposlenih s obzirom na djelatnost poduzeća




Grafikon 5: Prosječan broj zaposlenih s obzirom na djelatnost poduzeća

Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)

5.2.2. Stopa rasta vrijednosti imovine

Stopa rasta imovine



Grafikon 6: Stopa rasta vrijednosti imovine s obzirom na djelatnost poduzeća

Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)


Iz grafikona je vidljiv uzlazni trend promjene vrijednosti imovine za većinu industrija u odnosu na 2009. godinu. Potrebno je napomenuti da se vizualizacija, kao i analiza ovog pokazatelja, odnosi na rast prosječne vrijednosti promatranog pokazatelja za svaki klaster, u odnosu na vrijednost istog u baznom razdoblju.

Grafikon nije reprezentativan jer industrija energetike bilježi nagli rast vrijednosti imovine u 2012. godini, što produžuje os apscise do vrijednosti od 16000, dok ostale opservacije dostižu 5000 kao maksimalnu vrijednost pokazatelja.

Negativne vrijednosti bilježe finansijska industrija i energetika u 2011. godini te javna uprava, no ni jedna djelatnost ne ukazuje na negativan trend kretanja stope rasta imovine u dugom roku.

5.2.3. Stopa rasta vlastitog kapitala

Stopa rasta vlastitog kapitala




Grafikon 7: Stopa rasta vlastitog kapitala s obzirom na djelatnost poduzeća

Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)

Analogno stopi rasta vrijednosti imovine, najveći dio poduzeća prati uzlazni trend rasta u odnosu na bazno razdoblje.

5.2.4. Analiza likvidnosti

Analiza likvidnosti



Grafikon 8: Likvidnosti s obzirom na djelatnost poduzeća


Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)

Kao što je već navedeno u analitičkom dijelu istraživanja, poduzeća ne pokazuju veće oscilacije osim djelatnosti pružanja profesionalnih, znanstvenih i tehničkih usluga.

Bitno je spomenuti da isključivo djelatnost turizma i ugostiteljstva ukazuje na kontinuiran trend rasta, dok sektor zdravstva ukazuje na kontinuiran pad pokazatelja tekuće likvidnosti do posljednjeg razdoblja.

5.2.5. Analiza profitnih marži

Analiza profitnih margina



Grafikon 9: Profitna marža s obzirom na djelatnost poduzeća

Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)


Analogno prosječnom pokazatelju tekuće likvidnosti, ni za jednu od promatranih djelatnosti se ne može uočiti dugoročni trend kretanja vrijednosti promatranog pokazatelja za razdoblje od pet promatranih godina.

Zanimljivo je da prosječna profitna marža u prva dva razdoblja nakon recesije 2008. godine opada u svim djelatnostima, osim u sektoru obrazovanja i zdravstva.

5.3. Vizualizacija analize ekonomskih pokazatelja za klastere formirane s obzirom na mjesto sjedišta poduzeća

5.3.1. Zaposlenost


Zaposlenost s obzirom na mjesto sjedišta



Grafikon 10: Broj zaposlenih s obzirom na mjesto sjedišta poduzeća

Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)

Prosječan broj zaposlenih s obzirom na mjesto sjedišta




Grafikon 11: Prosječan broj zaposlenih s obzirom na mjesto sjedišta poduzeća

Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)

5.3.2. Stopa rasta vrijednosti imovine

Stopa rasta imovine



Grafikon 12: Stopa rasta imovine s obzirom na mjesto sjedišta poduzeća

Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)


Iz grafikona je vidljivo da poduzeća sa sjedištem u svakom od promatranih gradova pokazuju pozitivan trend kretanja stope rasta vrijednosti imovine, u odnosu na vrijednost iz 2009. godine, osim u slučaju Kaštela, koji rast bilježe tek u posljednjem promatranom razdoblju.

Također je vidljivo da vrijednost pokazatelja, za poduzeća koja imaju sjedište u Makarskoj, Splitu i Trogiru naglo raste u posljednjem razdoblju, dok se za poduzeća s područja grada Sinja, rast pokazatelja u odnosu na bazno razdoblje usporava.

Pokazatelj za solinske tvrtke, pak, neprekidni i nagli rast bilježe od kraja 2011. godine.

5.3.3. Stopa rasta kapitala

Stopa rasta vlastitog kapitala



Grafikon 13: Stopa rasta vlastitog kapitala s obzirom na mjesto sjedišta poduzeća

Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)

Kod stope rasta kapitala, prvi uočeni trend je negativni trend kretanja navedenog pokazatelja za poduzeća sa sjedištem u Kaštelima, kao i vrijednosti pokazatelja u negativnom kvadrantu koordinantne osi. Padajući trend u odnosu na baznu godinu prestaje tek u posljednjem promatranom razdoblju.


Poduzeća sa sjedištem u Solinu i Trogiru imaju gotovo identično kretanje promatranog pokazatelja s opadajućom dinamikom rasta vlastitog kapitala u 2012. godini, no, u svim razdobljima vrijednosti vlastitog kapitala premašuju one u baznoj godini.

Klasteri poduzeća sa sjedištem u Sinju i Splitu bilježe nešto sporiji, a zatim nagli rast vrijednosti vlastitog kapitala u posljednjem razdoblju kao i prethodne dvije opservacije.

Stopa vlastitog kapitala za poduzeća sa sjedištem u Makarskoj opada do razdoblja 2012. godine, kada počinje ukazivati na pozitivan trend.

5.3.4. Analiza likvidnosti

Analiza likvidnosti



Grafikon 14: Likvidnost s obzirom na mjesto sjedišta poduzeća


Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)

Za pokazatelj likvidnosti ne može se uočiti trend ni za jedan od razmatranih klastera, ako uzmemo u obzir da je razdoblje od tri godine minimalno, kako bi se kretanje pokazatelja moglo definirati kao trend.

Ipak, zanimljivo je da tvrtke sa sjedištem u Kaštelima i Makarskoj bilježe rast stope likvidnosti od kraja razdoblja 2009. godine, koji prestaje u 2012. godini, dok poduzeća sa sjedištem u Sinju, nakon pada, karakterizira rast pokazatelja tekuće likvidnosti u posljednja dva razdoblja.

5.3.5. Analiza profitnih marži

Analiza profitnih margina



Grafikon 15: Profitna marža s obzirom na mjesto sjedišta poduzeća

Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)

Ovdje se također ne može govoriti o trendu, jer ni jedan od klastera ne pokazuje konstantan pad ili rast prosječne vrijednosti profitnih marži.

Međutim, ono što možemo primjetiti je opetovano pojavljivanje negativnih vrijednosti za poduzeća sa sjedištem u Kaštelima te pad profitabilnosti svih poduzeća u 2010. godini, osim onih sa sjedištem u Sinju.


Pad prosječne profitne marže i u sljedećoj, 2012. godini, bilježe Makarska i Solin, a možemo primjetiti i da je linijski prikaz prosječne profitne marže za poduzeća u Splitu većim dijelom iznad drugih opservacija.

Uz sva priložena razmatranja različitih pokazatelja i ograničenja ovog istraživanja može se zaključiti da su poduzeća sa sjedištem u Splitu najprofitabilnija.

5.4. Vizualizacija analize ekonomskih pokazatelja za klastere formirane s obzirom na veličinu poduzeća

5.4.1. Zaposlenost


Broj zaposlenih s obzirom na veličinu poduzeća



Grafikon 16: Broj zaposlenih s obzirom na veličinu poduzeća

Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)

Prosječan broj zaposlenih s obzirom na veličinu poduzeća




Grafikon 17: Prosječan broj zaposlenih s obzirom na veličinu poduzeća

Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)

5.4.2. Stopa rasta imovine

Stopa rasta imovine



Grafikon 18: Stopa rasta imovine s obzirom na veličinu poduzeća

Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)


Iz grafikona je vidljivo da samo mala poduzeća imaju ekponencijalni trend rasta vrijednosti imovine u promatranim razdobljima, u odnosu na baznu 2009. godinu.

Srednja poduzeća bilježe rast do 2012. godine, a nakon toga stopa rasta imovine opada.

Velika poduzeća do posljednjeg razdoblja ukazuju na trend pada vrijednosti imovine u odnosu na baznu godinu, uz neznatan rast u 2013. godini.

5.4.3. Stopa rasta kapitala

Stopa rasta vlastitog kapitala



Grafikon 19: Stopa rasta vlastitog kapitala s obzirom na veličinu poduzeća


Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)

Za velika i mala poduzeća trendovi su identični onima za pokazatelj stope rasta imovine. Analogno, vidljivo da samo mala poduzeća imaju ekponencijalni trend rasta vrijednosti kapitala u promatranim razdobljima u odnosu na baznu 2009. godinu, dok velika poduzeća do posljednjeg razdoblja imaju trend pada vrijednosti imovine u odnosu na baznu godinu, uz neznatan rast u 2013. godini.

Za srednja poduzeća ne može se utvrditi trend kretanja stope rasta vlastitog kapitala.

5.4.4. Analiza likvidnosti

Analiza likvidnosti



Grafikon 20: Likvidnost s obzirom na veličinu poduzeća


Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)

Mala poduzeća su vidno najlikvidnija, dok su srednja i velika poduzeća ispod poželjne granice likvidnosti od 2.0, no prelaze donju granicu prihvatljivog iznosa pokazatelja tekuće likvidnosti od 1.5.

Trend kretanja prosječne likvidnosti se ne može uočiti.

5.4.5. Analiza profitnih marži

Analiza profitnih margina



Grafikon 21: Profitna margina s obzirom na veličinu poduzeća

Izvor: Prikaz autora (screenshot grafičkog prikaza unutar Tableau sučelja)

Nakon razdoblja recesije, vidljiv je pad profitabilnosti u svim klasterima poduzeća, pri čemu se negativni utjecaj recesije više reflektirao na mala i srednja poduzeća, nego na velika.

Srednja poduzeća su uvjerljivo najneprofitabilnija s negativnim profitnim maržama u čak tri razdoblja.

Mala poduzeća su najprofitabilnija s najvećom prosječnom profitnom maržom u tri promatrana razdoblja te rastućom vrijednošću iste u posljednjem razdoblju.

Uz sva priložena razmatranja različitih pokazatelja i ograničenja ovog istraživanja, može se zaključiti da su najpovoljniji pokazatelji poslovanja malih poduzeća.

6. USPOREDBA REZULTATA

6.1. Sažeti rezultati analize

Analizom željenih pokazatelja za klastere poduzeća generirane s obzirom na djelatnost poslovnih subjekata iz prethodno reduciranog izvornog seta podataka najveći broj zaposlenika zabilježen je u poduzećima koja se bave maloprodajom i veleprodajom te djelatnošću popravka motornih vozila s ukupno 21867 zaposlenih, dok najmanji broj zaposlenih broji djelatnost pružanja informatičkih i komunikacijskih usluga s ukupno 10 zaposlenih. Pokazatelj prosječnog broja zaposlenih u tvrtkama, s obzirom na djelatnost, pak, daje drugačije rezultate. Najmanji prosječan broj zaposlenih zabilježen je u poduzećima koja se bave djelatnošću pružanja informacijskih i komunikacijskih usluga s prosječno 3 zaposlenika po poduzeću, a najveći u poduzećima koja su dio industrije vode i gospodarenja otpadom s prosječno 40 zaposlenih.

Vrijednost imovine u odnosu na vrijednost iste iz bazne 2009. godine je rasla za gotovo sve djelatnosti, u svim promatranim razdobljima, s izuzetkom javne uprave, energetike te djelatnosti pružanja financijskih usluga. Najstabilniji rast bilježe djelatnost turizma i ugostiteljstva, administracija i građevinarstvo. Pokazatelj rasta vlastitog kapitala ukazuje na kretanja analogna prethodno spomenutom pokazatelju, izuzev djelatnosti poljoprivrede čija vrijednost vlastitog kapitala u 2011. godini drastično pada u odnosu na baznu godinu.

Za prosječni pokazatelj likvidnosti u klasterima nema većih oscilacija u post-recesijskom razdoblju. Najstabilnije djelatnosti s obzirom na navedeni pokazatelj su sljedeće: djelatnost turizma i ugostiteljstva te pružanja financijskih usluga, administracija, sektor zdravstva i djelatnost pružanja profesionalnih, znanstvenih i tehničkih usluga no djelatnost turizma i ugostiteljstva specifično bilježi dugoročni trend rasta ovog pokazatelja. Za razliku od prethodno negativnih pokazatelja, javna uprava bilježi uvjerljivo najviše godišnje profitne marže. Stabilne profitne marže primjećene su i kod financijske industrije, djelatnosti pružanja informatičkih i komunikacijskih usluga kao i djelatnosti pružanja profesionalnih, znanstvenih i tehničkih usluga. Poljoprivreda je pak najneprofitabilnija djelatnost u županiji.

Najveći broj zaposlenih je očekivano zabilježen u tvrtkama sa sjedištem u Splitu, gdje je zaposleno 38799 djelatnika, dok najmanji broj zaposlenih broje tvrtke sa sjedištem u gradu Sinju, s 1554 zaposlena. Zbog prisutnosti tri velika poduzeća sa sjedištem u gradu Solinu, od kojih jedno poduzeće broji preko 800 zaposlenika, Solin sa prosječno 17 zaposlenih ima

najveću vrijednost promatranog pokazatelja, dok Trogir ima najnižu, s prosječno 9 zaposlenih po poduzeću.

Svi klasteri bilježe pozitivna kretanja stopa rasta vrijednosti imovine i vlastitog kapitala te pozitivne trendove kretanja istog, u odnosu na baznu godinu, s izuzetkom klastera poduzeća sa sjedištem u Kaštelima.

U post-recesijskom razdoblju nema većih oscilacija pokazatelja likvidnosti u klasterima poduzeća formiranim s obzirom na mjesto sjedišta. Međutim, primijećeno je da su poduzeća sa sjedištem u Kaštelima prosječno nelikvidna, dok su najlikvidnija poduzeća iz Splita i Makarske.

Analogno pokazatelju tekuće likvidnosti, poduzeća sa sjedištem u Kaštelima bilježe negativne vrijednosti prosječne profitne marže, te su najveće vrijednosti istog pokazatelja zabilježene u gradu Splitu.

Razmatranjem broja zaposlenih s obzirom na veličinu poduzeća zaključeno je sljedeće: najviše djelatnika u Splitsko – dalmatinskoj županiji zaposleno je u malim poduzećima s ukupno 49428 zaposlenih, zatim slijede velika poduzeća s 14611 zaposlenih, te srednja poduzeća koja ukupno broje 13326 zaposlenih. Najveća prosječna zaposlenost zabilježena je u velikim poduzećima, s prosječno 562 zaposlena. Slijede srednja poduzeća s 105 zaposlenih, te mala poduzeća sa prosječno 7 zaposlenih po poduzeću.

Stopa rasta vrijednosti imovine i stopa rasta vlastitog kapitala najmanje idu u korist velikim poduzećima, koja bilježe padove vrijednosti imovine i vlastitog kapitala u odnosu na bazno razdoblje. Srednja poduzeća, nakon značajnog rasta u početnom razdoblju stagniraju, dok mala poduzeća bilježe rast vrijednosti imovine u svim promatranim razdobljima, u odnosu na baznu 2009. godinu.

Mala poduzeća su također najlikvidnija i najprofitabilnija. Slične pokazatelje profitabilnosti bilježe i velika poduzeća dok srednja u tri razdoblja posluju s gubitkom. Velika i srednja poduzeća tek prelaze donju granicu prihvatljive tekuće likvidnosti od 1.5.

6.2. Interpretacija rezultata

Na temelju izvršene analize vrijednosti pokazatelja, te trenda kretanja istih za formirane klastere, zaključeno je da se recesija vidno odrazila na poslovni rezultat poduzeća Splitsko-dalmatinske županije. Tome ponajviše svjedoče opadajuće profitne marže na početku prvih

nekoliko razdoblja nakon recesije, s izuzetkom klastera velikih poduzeća, kao i niži pokazatelji tekuće likvidnosti početkom recesijskog razdoblja.

Sukladno rezultatima analize pokazatelja tekuće likvidnosti i profitabilnosti utvrđeno je da su najstabilnije djelatnosti na području Splitsko-dalmatinske županije sljedeće:

- Administracija
- Djelatnost pružanja financijskih i osiguravajućih usluga
- Djelatnost pružanja zdravstvenih i socijalnih usluga
- Djelatnost pružanja profesionalnih, znanstvenih i tehničkih usluga
- Djelatnost pružanja informatičkih i komunikacijskih usluga
- Turizam i ugostiteljstvo

U klasterima poduzeća formiranim s obzirom na mjesto sjedišta, poduzeća sa sjedištem u gradu Splitu su u prosjeku nešto uspješnija od ostalih, dok poslovni subjekti, kojima je mjesto sjedišta Kaštela, imaju najnepovoljnije financijske pokazatelje.

Analogno, temeljem provedenog istraživanja uz dana ograničenja, zaključeno je da na području Splitsko-dalmatinske županije najbolje posluju mala poduzeća, a najlošije srednja poduzeća.

7. ZAKLJUČAK

U suvremenim uvjetima poslovanja te sukladno karakteristikama suvremene poslovne okoline primjena BI metoda i alata nije opcija, već nužnost. Poslovna inteligencija je postala svojevrsni standard, te primjena iste jedinstveni indikator uspješnosti poslovanja.

Rastuća potreba za implementacijom poslovne inteligencije vrijedi za sve gospodarske subjekte, pa tako i za državne agencije pri profiliranju gospodarstva županija, regija ili, pak, cjelokupnog nacionalnog gospodarstva.

Ovim istraživanjem ukazani su trendovi kretanja pet različitih ekonomskih i financijskih pokazatelja te vrijednosti prosječnih pokazatelja za klastere poduzeća generirane s obzirom na djelatnost, mjesto sjedišta te veličinu poduzeća u post-recesijskom razdoblju, pri čemu je utvrđeno da u Splitsko-dalmatinskoj županiji najbolje posluju poduzeća s područjem djelatnosti u administraciji, pružanju financijskih i osiguravajućih usluga, zdravstvenih i socijalnih usluga, profesionalnih, znanstvenih i tehničkih usluga, informatičkih i komunikacijskih usluga te turizam i ugostiteljstvo. Najnepovoljnije pokazatelje bilježi djelatnost poljoprivrede. Poduzeća s mjestom sjedišta u Splitu su nešto uspješnija od poduzeća sa sjedištem u ostalim razmatranim gradovima, dok klaster poduzeća sa sjedištem u Kaštelima ima negativne trendove poslovanja.

Temeljem rezultata analize zaključeno je da gospodarstvo Splitsko-dalmatinske županije počiva na poslovanju malih poduzeća. Pokazatelji tekuće likvidnosti i profitne marže za srednja poduzeća ističu nelikvidnost i neprofitabilnost navedenog klastera.

Također je primjećen izrazit negativan utjecaj recesije na veći dio financijskih pokazatelja formiranih klastera. Primjenom metoda poslovne i umjetne inteligencije prijetnje u poslovnoj okolini se mogu predvidjeti te potonji utjecaj istih ukloniti ili reducirati. Analogno, poslovni sustav koji prepoznaje prilike u svojoj okolini, posjedovanjem pravih će informacija, u pravo vrijeme povećati mogućnosti iskorištavanja tih prilika.

Svi navedeni rezultati dobiveni su analizom pročišćenih izvornih podataka zbog niza nekonzistentnosti u istima. Kako je analiza izvršena na reduciranoj skupini podataka, koji nije slučajni uzorak, što predstavlja znatno ograničenje istraživanja, rezultati ne moraju vjerno prikazivati realno stanje. Eventualni podaci za usporedbu nisu javno dostupni.

Drugo, ali ne manje bitno ograničenje, broj je financijskih i ekonomskih pokazatelja. Za relevantno profiliranje gospodarskog subjekta potrebna je dostupnost najmanje glavnih elemenata bilance poslovnog subjekta, te računa dobiti i gubitka. Unatoč ograničenjima istraživanja različitim vrstama analize, može se ukazati širok spektar mogućnosti, koje nudi poslovna inteligencija čak i kod analiziranja podataka, čak is a samo nekoliko danih atributa.

8. POPIS TABLICA

Tablica 1: Temeljne razlike relacijskih baza podataka i skladišta podataka	17
Tablica 2: Temeljne razlike između OLTP i OLAP analize podataka	21
Tablica 3: Kriteriji kategorizacije poduzeća po veličini	38
Tablica 4: Broj zaposlenih u klasterima poduzeća formiranim s obzirom na djelatnost41	
Tablica 5: Prosječan broj zaposlenih u klasterima poduzeća formiranim s obzirom na djelatnost.....	42
Tablica 6: Stopa rasta vrijednosti imovine u klasterima poduzeća formiranim s obzirom na djelatnost	44
Tablica 7: Stopa rasta vlastitog kapitala u klasterima poduzeća formiranim s obzirom na djelatnost	45
Tablica 8: Prosječna likvidnost u klasterima poduzeća formiranim s obzirom na djelatnost.....	46
Tablica 9: Prosječna profitna marža u klasterima poduzeća formiranim s obzirom na djelatnost.....	48
Tablica 10: Broj zaposlenih u klasterima poduzeća formiranim s obzirom na mjesto sjedišta.....	49
Tablica 11: Prosječan broj zaposlenih u klasterima poduzeća formiranim s obzirom na mjesto sjedišta	49
Tablica 12: Stopa rasta vrijednosti imovine u klasterima poduzeća formiranim s obzirom na mjesto sjedišta	50
Tablica 13: Stopa rasta vlastitog kapitala u klasterima poduzeća formiranim s obzirom na mjesto sjedišta	50
Tablica 14: Prosječna likvidnost u klasterima poduzeća formiranim s obzirom na mjesto sjedišta	51
Tablica 15: Prosječna profitna marža u klasterima poduzeća formiranim s obzirom na mjesto sjedišta	51
Tablica 16: Broj zaposlenih u klasterima poduzeća formiranim s obzirom na veličinu .	52
Tablica 17: Broj zaposlenih u klasterima poduzeća formiranim s obzirom na veličinu .	52
Tablica 18: Stopa rasta vrijednosti imovine u klasterima poduzeća formiranim s obzirom na veličinu.....	53
Tablica 19: Stopa rasta vlastitog kapitala u klasterima poduzeća formiranim s obzirom na veličinu.....	53
Tablica 20: Prosječna likvidnost u klasterima poduzeća formiranim s obzirom na veličinu	54
Tablica 21: Prosječna profitabilnost u klasterima poduzeća formiranim s obzirom na veličinu	54

9. POPIS GRAFIKONA

Grafikon 1: Distribucija poduzeća s obzirom na djelatnost poduzeća iz cjelokupnog seta podataka.....	37
Grafikon 2: Distribucija poduzeća po mjestu sjedišta poduzeća iz cjelokupnog seta podataka.....	38
Grafikon 3: Distribucija poduzeća s obzirom na djelatnost poduzeća iz cjelokupnog seta podataka.....	39
Grafikon 4: Broj zaposlenih s obzirom na djelatnost poduzeća.....	56
Grafikon 5: Prosječan broj zaposlenih s obzirom na djelatnost poduzeća	56
Grafikon 6: Stopa rasta vrijednosti imovine s obzirom na djelatnost poduzeća	57
Grafikon 7: Stopa rasta vlastitog kapitala s obzirom na djelatnost poduzeća.....	58
Grafikon 8: Likvidnosti s obzirom na djelatnost poduzeća	59
Grafikon 9: Profitna marža s obzirom na djelatnost poduzeća	60
Grafikon 10: Broj zaposlenih s obzirom na mjesto sjedišta poduzeća	61
Grafikon 11: Prosječan broj zaposlenih s obzirom na mjesto sjedišta poduzeća	61
Grafikon 12: Stopa rasta imovine s obzirom na mjesto sjedišta poduzeća	62
Grafikon 13: Stopa rasta vlastitog kapitala s obzirom na mjesto sjedišta poduzeća	63
Grafikon 14: Likvidnost s obzirom na mjesto sjedišta poduzeća.....	64
Grafikon 15: Profitna marža s obzirom na mjesto sjedišta poduzeća	65
Grafikon 16: Broj zaposlenih s obzirom na veličinu poduzeća	66
Grafikon 17: Prosječan broj zaposlenih s obzirom na veličinu poduzeća	66
Grafikon 18: Stopa rasta imovine s obzirom na veličinu poduzeća	67
Grafikon 19: Stopa rasta vlastitog kapitala s obzirom na veličinu poduzeća	68
Grafikon 20: Likvidnost s obzirom na veličinu poduzeća.....	69
Grafikon 21: Profitna margina s obzirom na veličinu poduzeća	70

10. POPIS SLIKA

Slika 1: Struktura poslovnog informacijskog sustava prema Luhn-u.....	13
Slika 2: Iterativni procesi u BI arhitekturi.....	18
Slika 3: Tijek obrade izvornih podataka pomoću BI metoda i alata	20
Slika 4: Aktivnosti planiranja data mining procesa	23
Slika 5: Koristi primjene poslovne inteligencije u praksi	25
Slika 6: Kategorije prikupljenih podataka u hrvatskim tvrtkama koje primjenjuju barem neke BI aktivnosti ili imaju institucionalizirani BI odjel	29
Slika 7: Operator Replace Missing Values	30
Slika 8: Operator Filter Examples	32
Slika 9: Dizajnirani model procesa obrade podataka	35

11. LITERATURA

11.1. Knjige

1. Biere, Mike.(2003): Business intelligence for the enterprise, IBM press, IBM
2. Ćukušić M., Željko G. (2011): Višedimenzijski informacijski sustavi: Koncept skladišta podataka i OLAP sustava, Ekonomski fakultet, Split
3. Garača, Ž.(2008): Poslovni informacijski sustavi: Objektna orijentacija, Ekonomski fakultet, Split
4. Garača, Ž.(2009): ERP sustavi: Poslovna inteligencija, Ekonomski fakultet, Split
5. Grossman, W., Rinderle S.(2015): Fundamentals of business intelligence, Springer-Verlag, Berlin
6. North, M. (2012): Data Mining For The Masses, Amazon
7. Ramljak, B.(2009): Stanje i perspektive razvoja financijskog izvještavanja za mala i srednja poduzeća u Hrvatskoj, Ekonomski fakultet, Split
8. Vidučić LJ., (2006): Financijski Menadžment, RriF-plus, Zagreb
9. Williams, S., Williams N.(2007): The profit impact of business intelligence, Elsevier Inc.

11.2. Časopisi

1. Bartels, J.(1994): A comparison between relational and object oriented databases for object oriented application development, Poet Software Corporation, str 3.-10.
2. Bilandžić, M. et al. (2012): Business intelligence u hrvatskog gospodarstvu, Poslovna izvrsnost Zagreb, 6 (1), str. 9. - 28.
3. Cheng, Z. (2014): Regional economic indicators analysis based on data mining, Intelligent systems design and engineering applications (ISDEA), str. 726.-730.
4. Dilek, A., Cavdar, S.(2015): Prediction of financial crisis with artificial neural network, International journal of financial research, 6(4), str. 36.-45.
5. Gams, M., Vidulin, V. (2011): Impact of high-level knowledge on economic welfare trough Interactive data nining, Applied artificial intelligence, str.267.-291.
6. Hoover, K., Perez, S. (2000): Three Attitudes towards Data Mining, Journal of economic methodology 7(2), str. 195.-210.
7. Jayanthi, R. (2009): Business Intelligence: Concepts, components, techiques and benefits, Journal of theoretical and applied information technology, 9 (1), str. 60.-70.
8. Kumari, N.(2013): Business intelligence in a nutshell, International journal of innovative research in computer and communication engineering, 1(4), str. 969.-975.
9. Luhn, H.P. (1958): A Business Intelligence System, IBM Journal, October 1958, str. 314. – 319.
10. Negash, S. (2014): Business Intelligence, Communications of the association for information systems, 13 (1), str. 177.-195.
11. Pivac, S. et al.(2009): Uporaba statistike u ekonomije: Analiza vremenskih serija, Ekonomski fakultet, Rijeka
12. Ranjan, J.(2009.): Business intelligence: concepts, components, techniques and benefits, Journal of theoretical and applied information technology, 9(1), str. 60.-70.

11.3. Web izvori

1. <http://businessintelligence.com/>
2. <https://msdn.microsoft.com/>
3. <https://rapidminer.com/>
4. www.fina.hr
5. www.hgk.hr
6. <https://support.microsoft.com/>
7. <http://www.tableau.com/>
8. www.zakon.hr

12. SAŽETAK

Poslovna inteligencija kao koncept predmet je mnogih istraživanja, uslijed konstantnog razvitka pripadajućih alata i metoda, kao i cjelokupnog tehnološkog rasta. Ovim istraživanjem nastoji se istaknuti potreba konstantne primjene alata i metoda poslovne inteligencije u gospodarskim subjektima, uz prikaz mogućnosti i koristi primjene poslovne inteligencije na primjeru profiliranja gospodarstva Splitsko-dalmatinske županije. Istraživanje se temelji na analizi financijskih i ekonomskih pokazatelja poslovnih subjekata. Izvor podataka je set podataka iz Amadeus baze u MS Excel formatu. Izvorni set podataka je reduciran, nakon čega su opservacije grupirane u klastere s obzirom na tri kriterija: djelatnost, mjesto sjedišta i veličina poduzeća. Analizom i vizualizacijom glavnih obilježja uz postojeća ograničenja doneseni su zaključci o profilu gospodarstva na navedenom prostoru, uključujući trendove kretanja istih, te ponašanju gospodarskih subjekata nakon razdoblja recesije.

Ključne riječi: poslovna inteligencija, gospodarski profil, analiza podataka

13. ABSTRACT

Business intelligence, as a concept, is the subject of many studies, due to the constant development of its tools and methods, considering technological growth as well as the growing business need to use business intelligence. This study aims to highlight the need of constant application of business intelligence tools and methods in companies. It analyzes features and benefits of business intelligence in case of profiling the economy of the Split-Dalmatia County. The study is based on analysis of financial and economic indicators of businesses. The data source is a set of data from the Amadeus database in MS Excel format. The original data set is reduced, after which observations are grouped into clusters based on three criteria: business, headquarters location and size of the company. With existing constraints, analysis and visualization of the main features have adopted conclusions on the profile of the economy in the analyzed region, including trends, and behavior of companies after a period of recession.

Key words: business intelligence, economy profiling, data analysis