

AUGUSTIN BARTOLIĆ

**PRIMJENA PROŠIRENE INTELIGENCIJE U ALATIMA
POSLOVNE INTELIGENCIJE**

DIPLOMSKI RAD

Augustin Bartolić

**PRIMJENA PROŠIRENE INTELIGENCIJE U ALATIMA
POSLOVNE INTELIGENCIJE**

DIPLOMSKI RAD

Sveučilište u Zagrebu

Ekonomski fakultet

Kolegij: Otkrivanje znanja u bazama podataka

Mentor: Prof. dr. sc. Mirjana Pejić Bach

Broj indeksa: 0067527543, D10730R18

Zagreb, rujan 2019.

AUGUSTIN BARTOLIĆ

Ime i prezime studenta/ice

IZJAVA O AKADEMSKOJ ČESTITOSTI

Izjavljujem i svojim potpisom potvrđujem da je DIPLOMSKI RAD
(vrsta rada)

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

Student/ica:

U Zagrebu, 26.09.2019.

Bartolić A.
(potpis)

Sažetak i ključne riječi

Proširena inteligencija je kombinacija ljudske i strojne inteligencije. Treba ju razlikovati od umjetne inteligencije koja po svojoj definiciji zamjenjuje ljudsku inteligenciju, dok proširena nadopunjuje. U ovom radu cilj je prikazati dio ponude mogućnosti proširene inteligencije u alatima poslovne inteligencije na tržištu kako bi se prikazao kratak uvid u što danas sve mogu alati poslovne inteligencije. Napravljena je studija slučaja sa jednom od prikazanih aplikacija gdje se pokušalo doći do detaljnih zaključaka o tome što i u kojoj mjeri je jedan alat poslovne inteligencija sposoban. Rezultati su pokazali da postoje određena ograničenja u radu ovog alata, no isto tako da postoji veliki potencijal da se jednog dana aplikacija unutar tog alata počne koristiti u realnom svijetu u mjeri u kojoj se koriste i druge aplikacije unutar istog alata.

Ključne riječi: proširena inteligencija, poslovna inteligencija, umjetna inteligencija, strojno učenje, alati poslovne inteligencije

Abstract and keywords

Augmented intelligence is a combination of human and machine intelligence. It should be distinguished from artificial intelligence, which by definition replaces the human intelligence, while the augmented complements it. In this paper, the aim is to present part of the augmented intelligence offering in business intelligence tools in the market to give a brief overview of what all business intelligence tools can do today. A case study was made with one of the applications presented, where detailed conclusions were drawn as to what and to what extent a business intelligence tool is capable. The results have shown that there are some limitations to the usability of this tool, but there is also a great potential that the application within this tool could be used in the real world to the extent that other applications within the same tool are used.

Keywords: augmented intelligence, business intelligence, artificial intelligence, machine learning, business intelligence tools

Sadržaj

1.	Uvod.....	1
1.1.	Predmet i cilj rada.....	1
1.2.	Izvori podataka i metode prikupljanja.....	1
1.3.	Sadržaj i struktura rada.....	2
2.	OSNOVNI POJMOVI POSLOVNE I PROŠIRENE INTELIGENCIJE.....	3
2.1.	Poslovna inteligencija.....	3
2.1.1.	Povijest poslovne inteligencije.....	3
2.1.2.	Tehnološke značajke poslovne inteligencije.....	5
2.2.	Proširena inteligencija.....	7
2.3.	Mogućnosti povezivanja poslovne i proširene inteligencije.....	9
3.	PRIMJERI APLIKACIJA PROŠIRENE INTELIGENCIJE U ALATIMA POSLOVNE INTELIGENCIJE.....	10
3.1.	IBM Cognos Analytics Exploration.....	10
3.2.	Microsoft Power BI.....	11
3.3.	Qlik Sense.....	14
3.4.	Tableau.....	16
4.	STUDIJA SLUČAJA KORIŠTENJA PROŠIRENE INTELIGENCIJE U ALATU POSLOVNE INTELIGENCIJE.....	18
4.1.	Metodologija.....	18
4.2.	Opis korištenog alata.....	21
4.3.	Rezultati.....	27
5.	ZAKLJUČAK.....	33
	Popis literature.....	34
	Popis tablica.....	37
	Popis slika.....	37
	Životopis studenta.....	39

1. Uvod

1.1. Predmet i cilj rada

Proširena inteligencija (eng. augmented intelligence) je kombinacija ljudske i strojne inteligencije. Treba ju razlikovati od umjetne inteligencije koja po svojoj definiciji zamjenjuje ljudsku, dok proširena nadopunjuje. Proširena inteligencija, u perspektivi poslovne inteligencije, omogućuje npr. puno bržu obradu podataka pomoću koje čovjek donosi zaključke. Stroj zamjenjuje samo one zadatke kojima uštedi čovjeku vrijeme, kao npr. napredne statističke i matematičke izračune. U ovom diplomskom radu će se govoriti kako proširena inteligencija pomaže korisnicima određenih aplikacija koje se koriste u svijetu poslovne inteligencije tj. za analizu i obradu podataka te prezentaciju rezultata tih analiza. Aplikacije koje će se opisivati su Cognos Analytics Report Studio od IBM-a, Power BI od Microsofta, Qlik Analytics Platform i Tableau. Sve te aplikacije su u posljednjih godinu dana izdale inačice u kojima su predstavile svoje izvedbe proširene inteligencije, među kojima je pomoćnik u radu i korištenju aplikacije. Ostale mogućnosti imaju za cilj pomoći korisnicima tih aplikacija od otkrivanja zanimljivih informacija koje na prvi pogled nisu dostupne, pa do prezentacije rezultata na brži i drugačiji način. Također opisat će se i procesi, matematički i statistički izračuni koji se događaju u pozadini pomoću kojih proširena inteligencija radi u navedenim aplikacijama.

Ciljevi ovog rada su prikazati način rada aplikacije Exploration u IBM Cognos Analytics Report Studiu te izvesti zaključak na temelju istraživanja gdje će se predočiti predviđanja i pretpostavke o daljnjem razvoju tehnologije proširene inteligencije, u svijetu poslovne inteligencije, pokušati će se dati odgovor na pitanja kao što su trebaju li podaci biti dobro pripremljeni ili je proširena inteligencija sposobna raditi sa zadanim, koliko je vjerodostojan rezultat kojeg aplikacija izbaci, kakvo znanje je potrebno za tumačenje tih rezultata i slično.

1.2. Izvori podataka i metode prikupljanja

Kao izvor podataka za teorijski dio koristit će se literatura poput knjiga, članaka i pojedinih web izvora. Za praktični dio koristit će se aplikacija IBM Cognos Analytics Report Studio kojeg je na korištenje ustupila tvrtka Megatrend poslovna rješenja čiji je zaposlenik autor ovog rada. Set podataka na kojem će se vršiti analize su demo podaci poduzeća Megatrend Poslovna Rješenja d.o.o., koji sadrže informacije o kupcima, artiklima koji se prodaju,

profitnim centrima poduzeća i referentima. Podaci su razvrstani po godinama i mjesecima, grupama proizvoda i klasama kupaca, a sastoje se od količine prodaje, vrijednosti prodaje, marže i troškovima prodaje.

1.3. Sadržaj i struktura rada

U drugom poglavlju rada se opisuju osnovni pojmovi, prepričavaju se stavovi drugih autora i radi se pregled literature kako bi se dobio dojam odakle je započelo sve. U trećem poglavlju se predstavljaju nekih od svjetskih primjera alata koji se mogu pronaći na tržištu, a nude funkcionalnosti proširene inteligencije. U četvrtom poglavlju se prikazuje studija slučaja rada jedne od aplikacija iz trećeg poglavlja te njene mogućnosti po pitanju proširene inteligencije na temelju čega se na kraju izvlači sve opći zaključak donesen na temelju čitanja literature i provođanja studije slučaja.

2. OSNOVNI POJMOVI POSLOVNE I PROŠIRENE INTELIGENCIJE

2.1. Poslovna inteligencija

Informacija je danas jedan od najvažnijih resursa svake kompanije. Kako bi se informacija bolje iskoristila kroz povijest razvitkom tehnologije su se razvijali sustavi i načini korištenja tih informacija iz čega je naposljetku i proizašla poslovna inteligencija.

2.1.1. Povijest poslovne inteligencije

Pojam „poslovna inteligencija“ (eng. business intelligence) prvi put koristi Devens (1865) kojim opisuje način na koji je bankar po imenu Sir Henry Furnese iskoristavao informacije kako bi ostvario zaradu.

Po mnogima otac poslovne inteligencije, Hans Peter Luhn (1958) u svojem radu povezuje dva pojma posao i inteligenciju. Posao objašnjava kao: „... skup aktivnosti izvršenih u svrhu znanosti, tehnologije, ...“, a inteligenciju kao: „... sposobnost uviđanja međusobnog odnosa prezentiranih činjenica na način da usmjerava akciju prema željenom cilju.“ (Luhn, 1958, str. 314).

Pojavom informacijskih sustava upravljanja (eng. management information systems – MIS) 1960-ih očekivalo se da će oni predstavljati centralni sustav za organizacije, ali su samo proširili sustav izvještavanja niže rangiranih menadžera (Watson et al., 1991).

Početak 1970-ih razvili su se koncepti za sustave potpore odlučivanju koje se može objasniti kao pretečim sustavima poslovne inteligencije. U tablici 1. se prikazuje okvir kojeg su Gorry i Scott-Morton predstavili 1971. godine za sustav potpore odlučivanju.

Scott-Morton je definirao sustav potpore odlučivanju (eng. decision support system – DSS) kao: „... interaktivan računalno utemeljen sustav, koji pomaže donositeljima odluka da koriste podatke i modele u rješavanju nestrukturiranih problema.“ (Gorry i Scott-Morton, 1971). Iz ove definicije i tablice 1. može se zaključiti kako je svrha takvog sustava bila da računalo pomaže korisnicima koristiti podatke kojima bi donijeli bolje odluke pri npr. odobravanju zajmova, pregovaranju ili planiranju istraživanja i razvoja.

Tablica 1. Okvir potpore odlučivanju

Tip odluke	Tip kontrole		
	Operativna kontrola	Menadžerska kontrola	Strateško planiranje
Strukturirana	- Potraživanja - Obveze - Naredba unosa	- Analiza budžeta - Kratkoročno prognoziranje - Izvješća o osoblju - Napravi-ili-kupi	- Financijski menadžment - Portfelj investicija - Lokacija skladišta - Distributivni sustav
Polu-strukturirana	- Planiranje proizvodnje - Kontrola zaliha	- Procjena kredita - Pripremanje budžeta - Raspored tvornice - Planiranje projekta - Dizajniranje sustava nagrađivanja - Kategorizacija zaliha	- Izgradnja nove tvornice - Spajanja i pripajanja - Planiranje novog proizvoda - Planiranje nadoknada - Osiguranje kvalitete - Politike ljudskih resursa - Planiranje zaliha
Nestrukturirana	- Kupovina softwarea - Odobranje zajmova - Upravljanje službe za podršku - Odabir naslovnice za časopis	- Pregovaranje - Zapošljavanje direktora - Kupovina hardwarea - Lobiranje	- Planiranje istraživanja i razvoja - Razvoj novih tehnologija - Planiranje društvene odgovornosti

Izvor: Obrada autora prema Gorry i Scott-Morton (1971)

Prema Power (2008, str. 235), Howard Dresner je 1989. izraz „poslovna inteligencija“ opisao kao skup koncepata i metoda koji se koriste za poboljšanje poslovnog odlučivanja pomoću sustava podrške utemeljenog na činjenicama.

U posljednjem desetljeću prošlog stoljeća počeli su se razvijati sustavi namijenjeni vrhovnim menadžerima. Do tada su se oslanjali na niže rangirane menadžere da identificiraju probleme (Elam et al., 1995). Izvršni informacijski sustav (eng. Executive information system – EIS) su Elam et. al (1995, str. 89) definirali kao informacijski sustav na računalu dizajniran tako da vrhovnom menadžeru omogući pristup informacijama važnim za njegove aktivnosti.

Vedder et al. (1999) su poistovjetili pojam „konkurentska inteligencija“ (eng. competitive intelligence – CI) sa pojmom „poslovne inteligencije“. Konkurentsku inteligenciju su definirali kao proces, koji čini skup pravnih i etičkih metoda koje kompanija koristi za skupljanje informacije koje joj pomažu ostvariti uspjeh na globalnom okruženju, te kao proizvod gdje se on definira kao informacija o konkurentskim aktivnostima iz javnih i privatnih izvora.

Poslovna inteligencija je prema Foley et al. (2010) kombinacija procesa, politika, kultura i tehnologija za skupljanje, manipulaciju, pohranu i analizu podataka prikupljenih iz internih i eksternih izvora sa svrhom komuniciranja informacije, stvaranja znanja i informiranja donošenje odluka.

Sharda et al. (2014, str. 14) kaže:

„...poslovna inteligencija je pojam koji kombinira arhitekture, alate, baze podataka, analitičke alate, aplikacije i metodologije, ali da je, isto kao i DSS, slobodan pojam tj. različitim ljudima predstavlja različito značenje. ... Glavni cilj poslovne inteligencije je da omogućiti interaktivan pristup podacima, manipulaciju istih i da daje poslovni menadžerima i analitičarima mogućnost sprovesti odgovarajuće analize. ... Proces poslovne inteligencije se svodi na transformaciju podatka u informaciju, zatim u odluku i na posljetku u akciju.“

Iz svih ovih navedenih definicija može se primijetiti kako se u srži nalazi poznavanje prave informacije. S vremenom su se te informacije negdje morale zapisati zbog čega su se razvili informacijski sustavi pomoću kojih su se podaci sakupljali, spremali, obrađivali i analizirali kako bi se na kraju dobila određena informacija koja je poduzećima donijela prednost nad konkurencijom.

2.1.2. Tehnološke značajke poslovne inteligencije

Kako bi sve definicije iz prošlog pod poglavlja bile i empirijski potvrđene u ovom pod poglavlju će se opisati tehnološka podloga poslovne inteligencije.

Podaci prema strukturi mogu biti strukturirani, polu-strukturirani ili nestrukturirani (Varga, 2016). Strukturirani podaci su tipično poslovni transakcijski ili analitički podaci koji se zapisuju u bazama i skladištima podataka. Polu-strukturirani podaci su pretežno tekstni dokumenti poput članaka. Nestrukturirani podaci su nečitljivi i primjer je slika, glazba i multimedijски sadržaj (Varga, 2016). Neovisno o njihovoj vrsti prema strukturi oni se moraju negdje pohraniti. Za ovaj rad su bitniji strukturirani podaci pa će se pri sljedećem spominjanju podataka misliti na strukturirane podatke.

Podaci se pohranjuju u skladište podataka putem procesa ETL (eng. extract, transform and load). ETL označuje proces izvlačenja podataka iz jedne baze podataka, zatim transformaciju tj. prilagodbu podataka za čitanje i na posljetku pohranu podataka u ciljnu bazu tj. skladište podataka (Kimball et al., 2004).

Skladište podataka definirano prema Inmonu (2002, str 31) je „subjektno-orijentirana, integrirana, neizbrisiva i vremensko-definirana zbirka podataka kao podrška odlukama menadžmenta“. Svaki podatak se odnosi na određeni subjekt, npr. 100kn samo po sebi ništa ne znači, ali 100kn je određena osoba dužna banci već ukazuje na to da određeni subjekt je vezan za podatak od 100kn. Skladište podataka zapisuje podatke iz više izvora. Svaki izvor ima svoj način zapisivanja podataka, a skladište podataka ih integrira u


unificiranu zbirku svih tih podataka koji imaju bilo kakvu vremensku oznaku. Podaci se ne ažuriraju nego se svaki novi zapis zapisuje posebno (Inmon, 2002).

Podaci iz skladišta podataka se koriste u alatima poslovne inteligencije za izradu izvještaja, npr. IBM Cognos Analytics Report Studio. Ukoliko podaci u skladištu nisu organizirani na poslovni način može se koristiti alat po nazivu IBM Cognos Framework Manager u kojem se izrađuje model podataka najčešće u tri sloja. Prvi sloj predstavlja izvorni sloj podataka iz skladišta podataka. Drugi sloj predstavlja sloj poslovne logike gdje se podaci prilagođavaju poslovnom zahtjevu, a treći i najviši sloj je prezentacijski sloj koji mora biti prilagođen krajnjim korisnicima za čitanje tih izvještaja. Nakon što se model izradi prema njemu se izrađuju izvještaji.

Izvori podataka mogu biti također iz OLAP (eng. online analytical processing) tehnologije koji mogu uključivati OLAP kocke npr. izrađene u alatu Cognos PowerPlay Transformer ili IBM Cognos Dynamic Cube Designer. OLAP tehnologija se koristi kod multidimenzijskog načina modeliranja podataka gdje se dimenzije slažu u hijerarhije (Chaudhuri et al., 1997). Tipična vremenska hijerarhija bila bi organizirana kao dan-mjeseć-kvartal-godina. OLAP operacije uključuju rollup (povećanje razine agregacije), drill-down (smanjenje razine agregacije ili povećanja detalja) između jedne ili više dimenzija hijerarhije, slice and dice (selekcija i projekcija) i pivotiranje (ponovno orijentiranje multidimenzijskog pogleda na podatke) (Chaudhuri et al., 1997).

Na slici 1. se vidi kako navedene tehničke značajke mogu biti povezane i što je sve potrebno da bi nastao jedan izvještaj u alatu poslovne inteligencije.

Slika 1. Primjer tehničke arhitekture sustava poslovne inteligencije



Izvor: Foley i Guillemette (2010)

2.2. Proširena inteligencija

Rani koncept proširene inteligencije spominje Engelbart (1962) gdje kaže da proširenjem ljudske inteligencije podrazumijevamo povećanje sposobnosti čovjeka da pristupi složenoj problematici, da shvati što odgovara njegovim potrebama i da pronade rješenja za njih.

Prema Pasquinelli (2015, str. 203):


„Proširena inteligencija je krovni pojam korišten u medijskoj teoriji, kognitivnim znanostima, neuroznanostima, filozofiji uma i političkoj filozofiji kako bi se obuhvatio složen odnos između ljudske inteligencije na jednoj strani i mnemo tehnikama i računarskih mašina na drugoj – a obje se podrazumijevaju kao nadogradnja (društvenog i političkog stupnja) ljudskih kognitivnih sposobnosti.“

Dickson (2017) kaže da je proširena inteligencija komplement, a ne zamjena ljudske inteligencije kojoj je cilj pomoći ljudima brže i bolje u rješavanju zadataka.

Proširenu inteligenciju Pan (2016) definira kao hibridni inteligentni sustav koji je formiran kao kooperacija računala i ljudi koji stvaraju sinergiju „ $1 + 1 > 2$ “.

Zheng et al. (2017, str. 154) također definiraju proširenu inteligenciju kao hibridnu inteligenciju i proširuju je za čovjeka-u-petlji (eng. human-in-the-loop) što označava da je čovjek uvijek u interakciji sa sustavom gdje u slučaju slabo pouzdanog rezultata danog od strane sustava čovjek može donijeti konačnu odluku.

Slika 2. Gartner „Hype“ Ciklus 2019



Izvor: Gartner (2019)

Na slici 2. prikazan je Gartnerov „Hype“ ciklus kojim se vizualno reprezentira zrelost i prihvaćanje tehnologija i aplikacija te kako će se tehnologije razvijati kroz vrijeme (Gartner, N/A). Proširena inteligencija je 2019. godine prvi put doživjela pojavu na ovom grafikonu. Gartner (2019) prema grafikonu 1. kaže da se proširena inteligencija sada nalazi na uzlaznoj putanji krivulje gdje se uglavnom samo priča o toj tehnologiji i napuhuju se očekivanja. Uskoro će dostići vrhunac napuhanih očekivanja nakon kojih će ona naglo pasti jer će ljudi shvatiti da su imali prevelika očekivanja od ove tehnologije. Nakon toga se očekuje razdoblje davanja prilike toj tehnologiji i na posljetku treba doći do produktivnosti i vrhunca korištenja te tehnologije. Očekivanje trajanja „hype“ razdoblja je između dvije do pet godina za proširenu inteligenciju prema Gartneru (2019).

2.3. Mogućnosti povezivanja poslovne i proširene inteligencije

Proširena analitika (eng. augmented analytics) pojam je koji Gartner (2018) opisuje kao korištenje metoda strojnog učenja i umjetne inteligencije za proširenje ljudske inteligencije, transformaciju upravljanja podacima, analitike i poslovne inteligencije te mnoge druge poglede na znanost o podacima i modele strojnog učenja/umjetne inteligencije.

Castañón (2019) kaže da algoritam strojnog učenja, poznat kao i model, je matematički izraz koji predstavlja podatak u kontekstu problema, često poslovnog tipa koji ima cilj za doći od podatka do uvida u informaciju. Castañón (2019) predlaže sljedećih 10 metoda kao osnovu strojnog učenja:

- Regresija (eng. Regression)
- Klasifikacija (eng. Classification)
- Klasteriranje (eng. Clustering)
- Smanjenje dimenzija (eng. Dimensionality Reduction)
- Ensemble metode (eng. Ensemble Methods)
- Neuronske mreže i duboko učenje (eng. Neural Nets and Deep Learning)
- Prijenosno učenje (eng. Transfer Learning)
- Učenje ojačanja (eng. Reinforcement Learning)
- Obrada prirodnog jezika (eng. Natural Language Processing)
- Umetanja riječi (eng. Word Embeddings)

Opisom poslovne inteligencije u pod poglavlju 2.1. i proširene inteligencije u pod poglavlju 2.3. može se pretpostaviti kako bi alati poslovne inteligencije mogli na temelju metoda strojnog učenja/umjetne inteligencije ukazati korisnicima na neke podatke koji na prvo oko nisu vidljivi što će se pokušati prikazati u poglavlju 4. Iako nije jednostavno izraditi jedan takav alat ili nadograditi postojeći s funkcijama strojnog učenja i umjetne inteligencije, prvi pokušaji izlaze na vidjelo posljednjih godinu dana od strane IBM-a i Microsofta, a i drugih. U sljedećem poglavlju slijedi prikaz primjera aplikacija koje su na početku stvaranja sustava proširene inteligencije gdje koriste svoje alate poslovne inteligencije pomoću kojih čovjek, kao korisnik tih alata, dolazi do zaključaka uz pomoć računala koje u pozadini samo, bez ljudske kontrole i upravljanja, ponudi određene informacije čovjeku kao uvid na temelju algoritama pomoću kojih su te funkcije podešene.


3.2. Microsoft Power BI

Power BI je servis poslovne analitike od tvrtke Microsoft-a koji pruža u uvid kako bi se omogućile brze i informirane odluke. Pomoću njega je moguće transformirati podatke u vizualne prikaze i podijeliti ih s kolegama na bilo kojem uređaju, vizualno istražiti i analizirati podatke lokalno i u oblaku, surađivati i dijeliti dashboard-e i interaktivne izvještaje te proširiti platformu na cijelu organizaciju pomoću ugrađenog upravljanja i sigurnosnim postavkama.

(Microsoft, N/A)

Na slici 4. je prikazano kako se koristi ovaj alat, neke od njegovih funkcionalnosti i mogućnosti te kako izgleda izvještaj kad se jednom napravi.

Slika 4. Power BI alat



Izvor: Microsoft, N/A

Power BI koristi mogućnosti umjetne inteligencije poput obrade prirodnog jezika, gdje omogućuje korisnicima da dobe odgovor postavljanjem pitanja na engleskom jeziku te Quick Insight (hrv. Brzi Uvid), koji automatski traži povezani uzorak između podataka (Ulag, 2018). Generalni menadžer sektora inženjeringa u Microsoft-u Arun Ulag je u studenom 2018. godine na službenoj web stranici Microsoft Power BI-a objavio da se


sljedeće mogućnosti AI (artificial intelligence - AI, hrv. umjetna inteligencija) uvađaju u Power BI (Ulag, 2018):

- Prepoznavanje slika i analiza teksta
- Analiza ključnog pokretača (eng. Key driver analysis)
- Izrada modela strojnog učenja izravno u Power BI pomoću automatiziranog strojnog učenja
- Integracija Azure Machine Learning-a unutar Power BI-a

Azure Cognitive Services (hrv. Azure Kognitivne Usluge) su sofisticirani unaprijed obučeni modeli strojnog učenja koji mogu izvući uvid iz podataka. Cilj njihovi usluga u Power BI-u je izvlačenje informacija iz dokumenata, slika i povratnih informacija sa društvenih medija. Ovi algoritmi su sposobni identificirati imenovane entitete kao što su organizacije, ljudi i lokacije te mogu prepoznati objekte u slikama, prepoznati jezik i prepoznati ključne izraze. (Ulag, 2018)

Na slici 5. se može vidjeti kako izgleda primjena tih Azure Kognitivnih Usluga.


Slika 5. Primjena Azure Machine Learning u Power BI



Izvor: Ulag (2018)

Analiza ključnog pokretača pomaže shvatiti što donosi tj. utječe na rezultat. Na slici 6. se vidi kako bi se ta analiza mogla iskoristiti.


Slika 6. Analiza ključnog pokretača u Power BI



Izvor: Ulag (2018)

Na slici 7. je prikazan primjer izgradnje modela strojnog učenja bez da korisnik zna napisati ijednu liniju koda.

Slika 7. Prikaz izgradnje modela strojnog učenja u Power BI




Izvor: Ulag (2018)

3.3. Qlik Sense

Qlik Sense je alat poslovne inteligencije od tvrtke Qlik koji koristi asocijativni mehanizam analitike, sofisticirani AI te skalabilnu arhitekturu u više oblaka kojim je moguće uključiti svakog zaposlenika organizacije. Njime je moguće izrađivati interaktivne izvještaje, dashboard-e, prilagođene analitike, mobilne izvještaje i slično. Asocijativni mehanizam analitke (eng. The Qlik Associative Engine) indeksira i razumije sve odnose u podacima, otkrivajući pritom skrivene informacije koje u suprotnom ne bi bile vidljive što alati na temelju upita u bazu (eng. query-based tools) ne mogu omogućiti. (Qlik, 2019)

Na slici 8. je prikazan primjer izvještaja u Qlik Sense alatu.

Slika 8. Qlik Sense alat




Izvor: Qlik, N/Aa

Mogućnost proširene inteligencije koju Qlik Sense nudi je nazvana Qlik Insight Bot™ koji je zapravo programirani robot koji daje odgovor na postavljena pitanja. On nudi brz i jednostavan način postavljanja pitanja i otkrivanja informacija putem obrade prirodnog jezika. Sa svaki pitanje nudi relevantne grafove i informacije, uključujući i ključne pokretače (eng. key drivers), usporedbe, predviđanja i ostalo, a Qlik tvrdi i da je AI samoučeći što ga čini progresivno pametnijim. (Qlik, N/Ab)

Na slici 9. je prikaz kako radi Insight Bot™.

Slika 9. Insight Bot™ u Qlik Sense




Izvor: Qlik, N/Ab

Qlik zagovara kako njihov alat nudi „Smarter Analytics Experience“ (Qlik, N/Ac). Kažu kako većina kompleksnih poslovnih problema traži interakciju čovjeka sa strojem i zato su izgradili kognitivni mehanizam koji nudi kontekstualne prijedloge koji pomažu korisnicima uvidjeti skrivene informacije. Nazivaju ga formulom: (Qlik, N/Ac)

$$\text{Associative Indexing (x) Augmented Intelligence} = \text{AI}^2 \quad (1)$$

Na slici 10. je prikazano kako radi taj mehanizam.

Slika 10. Kognitivni (asocijativni) mehanizam u Qlik Sense



Izvor: Qlik, N/Ac


3.4. Tableau

Tableau je posljednji u nizu alata poslovne inteligencije koji će se opisati u ovom radu. Tableau nudi interaktivne, vizualne analize koje omogućuju davanje odgovor na teška poslovna pitanja. Baziraju ga na njihovoj patentiranoj VizQL tehnologiji. (Tableau, N/Aa)

VizQL je tehnologija koju je Tableau razvio 2003. godine sa Stanford sveučilišta, a koja omogućuje rad s podacima na način drag and drop (hrv. povuci i ispusti) kako bi se izradile sofisticirane vizualizacije. Temelj ove inovacije je patentirani query (hrv. upit) jezik koji prevodi akcije povlačenja i ispuštanja u upit u bazu podataka i zatim odgovara grafički. (Tableau, N/Ab)

Tableau je moguće koristiti kao desktop aplikaciju, preko browsera, mobitela ili ugrađenog u bilo koju aplikaciju. Na slici 11. je prikaz izvještaja u Tableau alatu.

Slika 11. Tableau alat




Izvor: Tableau, N/Aa

Tableau pod proširenu inteligenciju također nudi funkcionalnost za obradu prirodnog jezika kojeg su nazvali Ask Data gdje se postavi pitanje ili se upišu ključne riječi, a odgovor stigne u obliku vizualizacije. (Tableau, N/Ac)

Na slici 12. je prikazana Ask Data funkcionalnost.

Slika 12. Ask Data u Tableau




Izvor: Tableau, N/Ac

Explain data (eng. Objasni podatak) je druga funkcionalnost koju Tableau nudi, a ona se temelji na naprednim statističkim modelima kojim se prikazuje usredotočeni skup objašnjenja kako bi se izbjeglo gubljenje vremena na traženje odgovora.

Na slici 13. je prikazana funkcionalnost Explain data.

Slika 13. Explain data u Tableau



Izvor: Tableau, N/Ac

4. STUDIJA SLUČAJA KORIŠTENJA PROŠIRENE INTELIGENCIJE U ALATU POSLOVNE INTELIGENCIJE

4.1. Metodologija

S obzirom da ovi alati nisu besplatni, dapače vrlo su skupi, u studiji slučaja obradit će se samo IBM Cognos Analytics alat kojem autor ovog rada ima pristup jer je zaposlenik tvrtke Megatrend poslovna rješenja d.o.o. koja koristi alat za izradu izvještaja kod klijenata.

Opisat će se svaki korak, mogućnost, način rada i ostalo kako bi se dobio potpuni uvid u mogućnosti koje nudi aplikacija proširene inteligencije u alatu poslovne inteligencije.

Općenito, za optimiziranje korisničkog iskustva u Exploration aplikaciji potrebno je odraditi obogaćivanje (eng. enrich) paketa podataka. Proces obogaćivanja povezuje karakteristike podataka u Cognos Analytics okruženju, poput vremena i zemljopisne lokacije, sa podacima koji se dohvaćaju upitima u bazama podataka. Informacije iz postupka obogaćivanja dopunjuju informacije, poput tipa podataka, naziva stupca ili vrstu korištenju podatka, dobivenih iz meta podataka paketa. Obogaćeni paket uključuje podatkovne karakteristike koje su neophodne za funkcionalnosti Exploration aplikacije temeljenih na umjetnoj inteligenciji (AI), poput preporuka za vizualizaciju i inteligentno postavljenih vrijednosti na svojstvima stupaca, u suprotnom se dijagram veza neće prikazivati. Važno je napomenuti da je obogaćivanje potrebno napraviti ukoliko su paketi podataka napravljeni u Framework Manager-u (IBM, N/Ab). Kod obogaćivanja paketa, minus je to što on uzima samo prvih maksimalno 10.000 (moguće je ručno odrediti koliko) zapisa, što u slučaju baze podataka tj. skladišta podataka sa mjernom tablicom od milijun zapisa, rezultati mogu biti nevjerodostojni i nereprezentativni jer taj uzorak zapisa može imati vrlo visoke ili vrlo niske vrijednosti mjerni podataka, a ostatak tablice drugačije rezultati što će prikazivati potpuno neistinite informacije na temelju tog uzorka od maksimalno 10.000 zapisa. S obzirom da će se u istraživanju ovog rada koristiti Excel tablica, obogaćivanje paketa nije potrebno.

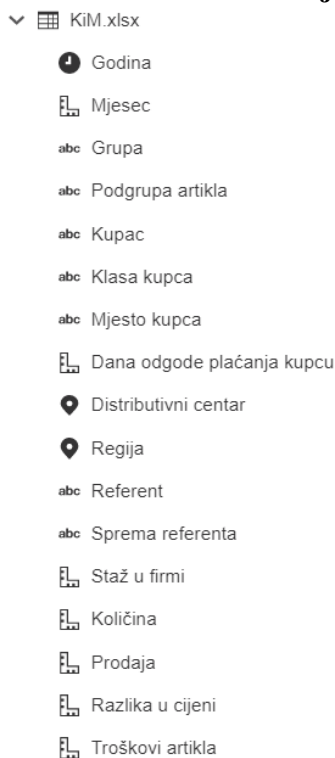
Za izvor podataka nad kojim će se raditi analiza napravljena je Excel tablica, a sastoji od sljedećih stupaca:

- Godina
- Mjesec
- Grupa artikla
- Podgrupa artikla
- Kupac

- Klasa kupca
- Mjesto kupca
- Dani odgode plaćanja kupcu
- Distributivni centar
- Regija
- Referent
- Sprema referenta
- Staž u firmi
- Količina
- Prodaja
- Razlika u cijeni
- Troškovi artikla

Set podataka sastoji se od ukupno 34.405 zapisa (redova) u Excel tablici. Excel tablice je moguće učitati i koristiti kao izvor podataka. Postoje zapisi za 2010., 2011. i 2012. godinu za svih 12 mjeseci u godini. Grupe artikala su kruh, mlijeko, mrvice, ostalo, peciva i sendviči, pivo, sokovi i toaletni pribor. Podgrupa artikla može biti hrana, piće ili kućne potrepštine. Postoje zapisi za 77 različitih kupaca. Klase kupaca mogu biti javne ustanove, trgovačka poduzeća, trgovački obrti i ugostitelji. Mjesto kupaca je unutar Republike Hrvatske. Distributivni centar može biti Bjelovar, Dubrovnik, Karlovac, Osijek, Pula, Rijeka, Sisak, Split, Varaždin, Vinkovci, Zagreb. Regija može biti Bjelovar, Osijek, Rijeka, Split, Zagreb. Postoje zapisi za 21 različitog referenta. Sprema može biti srednja, visoka i viša.

Slika 14. Prvotno stanje podataka u IBM Cognos Analytics



Izvor: Autorski uradak

Kao što je vidljivo iz slike 14., određene podatke je prepoznao ispravno, a druge nije. Godinu je prepoznao ispravno kao vremenski identifikator. Mjesec je prepoznao kao mjeru, što je krivo, stoga je potrebno promijeniti vrstu korištenja podatka iz mjere u vremenski identifikator. Grupa, podgrupa artikla, kupac, klasa kupca i mjesto kupca su ispravno prepoznati kao tekstualne identifikatore jer se oni mogu grupirati ili sumirati po mjernom stupcu s kojim imaju vezu. Dane odgode plaćanja kupcu je prepoznao kao mjeru, što ovisi o poslovnoj perspektivi kako će se gledat. U slučaju ovog istraživanja ostaviti će se kao mjera. Distributivni centar i regiju je ispravno prepoznao kao geografske lokacije. Referent i sprema referenta je također ispravno prepoznata kao tekstualni identifikatori. Staž u firmi ima isti slučaj kao dani odgode plaćanja kupcu stoga će biti ostavljen kao mjera. Količina, prodaja, razlika u cijeni i troškovi artikla su prepoznati kao mjera što je ispravno. Zaključak je da je svaku vrstu podataka koja je u brojanom obliku prepoznao kao mjeru što nije uvijek ispravno, osim godine koju je ispravno prepoznao.

Za svaki stupac iz Excel tablice moguće je u postavkama promijeniti vrstu njegovog korištenja, način agregiranja i što predstavlja. Na slici 15. je prikazan prozor postavki u kojem se gore navedeno može napraviti te je prikazan potrebna promjena koje se trebala odraditi na podacima o Mjesecu.

Slika 15. Postavke podataka

Properties		×
Label	Mjesec	
Usage	Identifier	▼
Aggregate	Count Distinct	▼
Data type	Integer	
Represents	Time	▼
	Month	▼
Sorting		
Sort options	Disabled	▼
Sort by	Mjesec	▼
Order	Ascending	▼
<div style="border: 1px solid blue; padding: 2px 10px; display: inline-block;">Close</div>		

Izvor: Autorski uradak

Ukoliko set podataka nije ispravno pripremljen AI funkcije koje se odrađuju u pozadini Exploration aplikacije će iznijeti krive zaključke i krivo će povezati podatke što može dovesti do neželjenih rezultata stoga je potrebno znati što podaci predstavljaju.

4.2. Opis korištenog alata


Kada su podaci jednom pripremljeni, moguće je početi koristiti samu aplikaciju.

U sučelju početne stranice s lijeve strane nalazi se 8 alata za korištenje, prikazanih na slici 16. Alati su redom:

- Save – spremanje Exploration-a ili izmjena na postojećem
- Undo – vraćanje do 8 koraka unazad
- Redo – ponovi zadnje napravljeno
- Home – predstavlja povratak na početnu stranice cijelog IBM Cognos Analytics
- Explorations – predstavlja kartice koje je najbolje opisati kao Sheet-ove u Excel tablici. Kartica je moguće dodavati više, a postoje zasebne ili usporedne. U usporednim karticama moguće je usporediti dvije vizualizacije jednu pored druge.
- Source – predstavlja odabiranje izvora podataka
- Pins – predstavlja spremljene vizualizacije koje se možda trenutno koriste ali bi se mogle koristiti kasnije, pa je svrha da se već napravljeni uradci ne rade više puta nego sprema sa strane dok ne bude potreba iste koristiti
- Assistant – predstavlja AI funkcionalnost. Ima istu svrhu kao Quick Insight u Power BI, Ask Data u Tableau i Insight Bot™ kod Qlik Sense gdje se „asistentu“ postavljaju pitanja na engleskom jeziku, nakon čega on obrađuje prirodni jezik i vraća odgovor u obliku teksta ili vizualizacije što će kasnije biti prikazano.

Sa desne strane stranice se također nalaze alati za dijeljenje izvještaja s drugima, notifikacije, postavke korisničkog računa i pomoć.


Slika 16. Alati na početnoj stranici



Izvor: Autorski uradak

Na početnoj stranici aplikacija automatski napravi dijagram veza gdje pokazuje jačinu veze između podataka. Dijagram iscrtava polja na temelju statističke procjene povezanih stavki (IBM, N/Ac). Odabire se polje interesa, u slučaju ovog istraživanja je to Količina na temelju koje Exploration aplikacija prikazuje koji podaci koliko ovise o Količini. Odabrano polje interesa je moguće mijenjati, kao i količina polja (maksimalno 50) na koje se radi potencijalna veza. U svrhu istraživanja odabran je maksimalna broj veza, točnije 17 koliko i ima stupaca u tablici. Na slici 17. je prikazan dijagram veza nakon što su napravljene izmjene na podacima. Debljina crte ukazuje na jačinu veze između podataka. Vidljivo je da je poveznica između Kupca i Klase kupca (90% jačina veze) te Kupca i Mjesta kupca (82% jačina veze) debela što označava jaku vezu, što je i po samim podacima poprilično logično da Klasa kupca ovisi o Kupcu, te da Mjesto kupca ovisi o Kupcu. Exploration je našao vezu u iznosu od 43% jačine između Kupca i Količine.

Slika 17. Dijagram veza

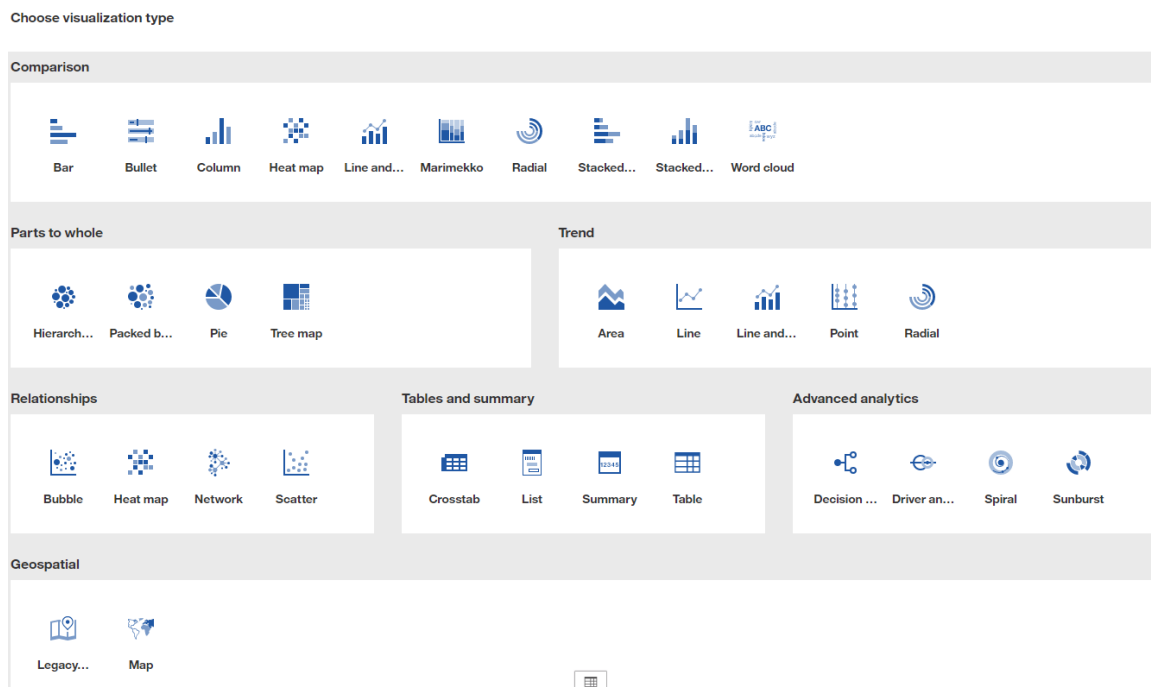


Izvor: Autorski uradak

U Exploration aplikaciji moguće je izraditi niz vizualizacija koje su podijeljene u kategorije, prikazano na slici 18. Pošto je dio teme ovog rada proširena inteligencija, koja koristi metode strojnog učenja i umjetne inteligencije, fokus će biti na vizualizacijama iz kategorije Napredne analitike (eng. Advanced analytics), a to su stablo odlučivanja (eng.

Decision tree), analiza pokretača (eng. Driver analysis), spiralni (eng. spiral) grafikon i sunburst grafikon.

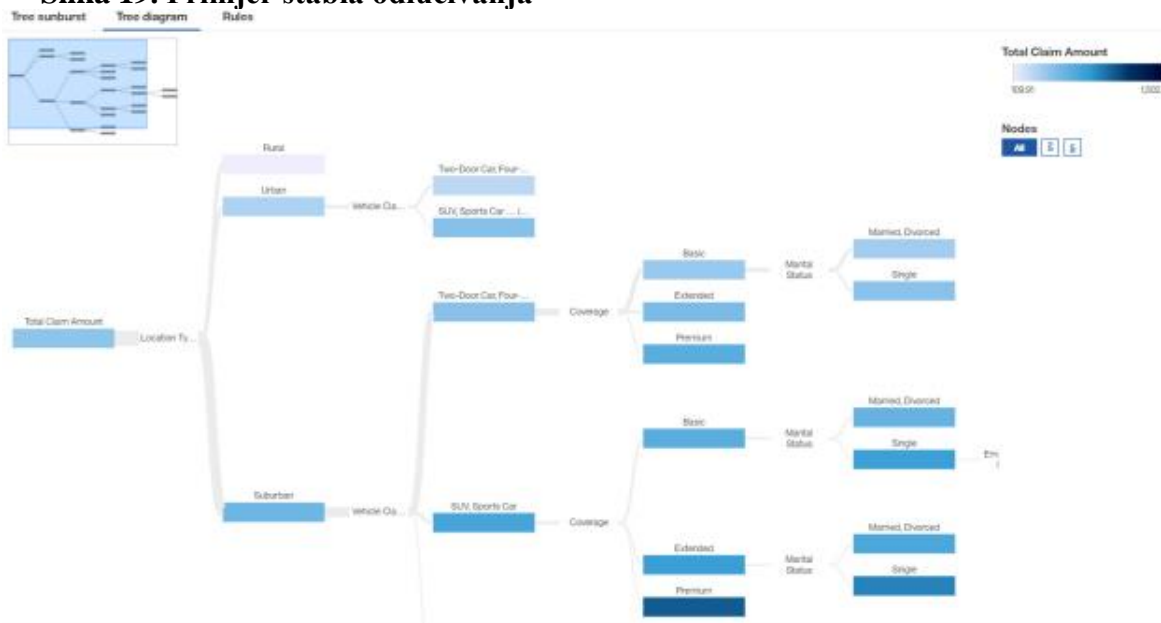
Slika 18. Vrste vizualizacije prema kategorijama u Exploration



Izvor: Autorski uradak

U nastavku će se opisati svaka od vizualizacija iz kategorije Napredne analitike.

Slika 19. Primjer stabla odlučivanja



Izvor: IBM, N/Ac

Primjer stabla odlučivanja prikazan je na slici 19. Stablo odlučivanja (eng. Decision tree) je vrsta grafikona koja prikazuje povezanu hijerarhiju okvira kako bi pokazalo

vrijednosti zapisa. Zapisi su segmentirani u grupe, koje se nazivaju čvorovi (eng. nodes). Svaki čvor sadrži zapise koji su statistički slični jedni drugima s obzirom na ciljno polje. Svaka grana u stablu odlučivanja odgovara pravilu odlučivanja. Pravilo odlučivanja predviđa ishod u ciljnom polju. Pregledavanje pravila za odlučivanje pomaže odrediti koji uvjeti mogu rezultirati određenim ishodom. Kako bi učinkovitost bila bolja, zbog broja redaka u izvoru podataka, analiza se temelji na reprezentativnom uzorku cjelokupnih podataka. Stablo odlučivanja koristi se za ilustraciju kako temeljni podaci predviđaju odabrani cilj i naglašava ključne uvide. Stablo odlučivanja ima jedan cilj kao što je vidljivo na slici 19. Ako je ciljno polje kontinuirano, pokazatelji uvida ističu neobično visoke ili niske skupine, a ako je ciljno polje kategorično, onda je ključni uvid mod čvora, što predstavlja najčešću pojavu kategorije. U slučaju kontinuirane mjere ciljnog polja boja pokazuje je li vrijednost čvora povezana s visokim, srednjim ili niskim vrijednostima cilja. Boja čvora temelji se na prosjeku cilja za mjeru. Što je viša prosječna vrijednost cilja za čvor, tamnija je boja. U slučaju kategorične mjere ciljnog polja boja pokazuje koje su vrijednost/i najviše predstavljene. (IBM, N/Ac)

Slika 20. Primjer sunburst grafikona




Izvor: IBM, N/Ac

Sunburst grafikon je prikazan primjerom na slici 20. On je poprilično povezan sa stablom odlučivanja gdje se može vidjeti da ako su mjere unutar stabla odlučivanja jake prediktore za ciljanu vrijednost/i tada boje prevladaju u tom čvoru, a neznčajne vrijednosti

se izostavljaju. Koristi se za ilustraciju kako temeljni podaci predviđaju odabrani cilj i ističu ključne uvide. (IBM, N/Ac)


Slika 21. Primjer analize pokretača



Izvor: IBM, N/Ac

Na slici 21. je prikazan primjer analize pokretača. Analiza pokretača (eng. driver analysis) pokazuje ključnog pokretača, ili prediktora, cilja. Što je pokretač više desno na grafikonu, to je on jači. Sofisticirani algoritmi koji se koriste u pozadini pružaju vrlo interpretativni uvid koji se temelji na složenom modeliranju. Za pokretanje ove analize nije potrebno znanje statističkih testova, koje Cognos Analytics automatski ispravno odabire, već je potrebno znanje kako interpretirati dobivene rezultate. Kako bi učinkovitost bila bolja, zbog broja redaka u izvoru podataka, analiza se temelji na reprezentativnom uzorku cjelokupnih podataka. (IBM, N/Ac)

Slika 22. Primjer spiralnog grafikona




Izvor: IBM, N/Ac

Na slici 22. je prikazan spiralni grafikon. Radi na istom principu kao i analiza pokretača. Prikazuje ključne pokretače, ili prediktore, za određeni cilj. Što je pokretač bliže centru, to je on jači. Kako bi učinkovitost bila bolja, zbog broja redaka u izvoru podataka, analiza se temelji na reprezentativnom uzorku cjelokupnih podataka. (IBM, N/Ac)

Statistički testovi koje se izvode u pozadini grafikona su: (IBM, N/Ac; IBM, N/Ad):

- Analiza varijance (ANOVA) (eng. Analysis of variance) – metoda linearnog modeliranja za procjenu odnosa među poljima. Za ključne pokretače i za uvide koji su povezani s većim brojem grafikona, ANOVA testira razlikuje se srednja ciljna vrijednost u kategorijama s jednim inputom ili kombinacijama kategorija s dva inputa.
- Stablo klasifikacije (eng. Classification tree) – vrsta stabla odlučivanja. Koristi Gini mjeru nečistoće za razvrstavanje zapisa u kategorije ciljanog polja. Predviđanja se temelje na kombinacijama vrijednosti u input polju.
- Regresijsko stablo (eng. Regression tree) – vrsta stabla odlučivanja. Koristi zbroj kvadrata i regresijsku analizu za predviđanje vrijednosti ciljnog polja. Predviđanja se temelje na kombinacijama vrijednost u input polju.
- Hi-kvadrat test jednakih frekvencija (eng. Chi-square test of equal frequencies) – provjerava jesu li frekvencije (broj vrijednosti) u svakoj kategoriji ili grupi statistički različite jedna od druge.
- Hi-kvadrat test neovisnosti (eng. Chi-square test of independence) – određuje jesu li dva kategorična polja neovisna. Ako nisu neovisna, tj. ako su ovisna, onda se pridružuju.
- Test utjecaja (eng. Influence test) – je hi-kvadrat test koji provjerava je li broj zapisa u grupi značajno različit od očekivane frekvencije. Grupa može biti kategorija ili kombinacija kategorija. Uzimajući u obzir vrijednost značaja i veličinu učinka, test identificira utjecajne skupine.
- T test utjecaja (eng. Influence t test) – uspoređuje srednju vrijednost mjere u grupi s ukupnom srednjom vrijednošću mjere.
- Višestruka linearna regresija (eng. Multiple linear regression) – predstavlja statistički model za procjenu odnosa kontinuiranog cilja i prediktora.
- Ispitani rezidualni test (eng. Studentized residual test) – izračunava se kao zaostali regresijski model podijeljen s prilagođenom standardnom greškom.
- Test usporedbe zbroja (eng. Sum comparison test) – je hi-kvadrat test koji provjerava je li zbroj određene mjere jednak u svim kategorijama objašnjenog polja.
- Test utjecaja zbroja (eng. Sum influence test) – uspoređuje zbroj mjere u kategoriji s prosječnom vrijednosti zbroja za mjere u svim kategorijama objašnjenog polja.


Slika 24. Top kupci prema analizi pokretača



Izvor: Autorski uradak

Na slici 25. je prikazan sunburst grafikon koji prikazuje isto kao i stablo odlučivanja samo na drugačiji vizualni prikaz.

Slika 25. Rezultati sunburst grafikona



Izvor: Autorski uradak

Na slici 26. je prikazan popis pravila koji su dobiveni ovom analizom, sa detaljima s desne strane slike, koje je umjetna inteligencija primijetila u ovom modelu i zaključila da mora napomenuti korisniku.

Slika 26. Popis pravila modela


Tree sunburst	Tree diagram	Rules	Records
▲▼ Predicted value		Rules	Records
8,194,130.00		Prodaja ≥ 7056 Grupa = KRUH, MLJEKO Kupac = VELIKA TRGOVINA D.D., TRŽNI CENTAR GAVRO	89 (<1%)
4,140,120.00		Prodaja ≥ 7056 Grupa = KRUH, MLJEKO Kupac = AAA TRGOVACKI OBRT, HOTEL DVOGLAV, MARIJA TRGOVACKI OBRT, MORE TRGOVINA D.O.O., TRGOVACIJA D.D., MARAĐONA TRGOVINA, VOGE TRGOVINA, TRGOVACKI OBRT SARMA	152 (1%)
2,577,810.00		Prodaja ≥ 7056 Grupa = KRUH, MLJEKO Kupac = ANITA D.D., DUBROVNIK HOTELI, MESNICE D.O.O., MINIMARKET PJEVAC, PANJ TRGOVINA, SOKO D.O.O., NIVES TRGOVINA, PINTA TRGOVACKI OBRT, SRECA TRGOVACKA RADNJA, TRGOVACKI OBRT MALINA, PAPAN D.O.O., Other	369 (3%)
2,511,540.00		Prodaja ≥ 7056 Grupa = OSTALO, PIVO, SOKOVI, TOALETNI PRIBOR Kupac = ANITA D.D., DUBROVNIK HOTELI, HOTEL DVOGLAV, MARIJA TRGOVACKI OBRT, MOJICA, HOTEL MALI MIR, SRECA TRGOVACKA RADNJA, TRGOVACKI OBRT LUNA, TRGOVACKI OBRT MALINA, ZORA D.O.O., PAPAN D.O.O., GAGA more...	306 (2%)
1,237,590.00		Prodaja ≥ 7056 Grupa = MRVICE, PECIVA I SENDVIČI Kupac = VELIKA TRGOVINA D.D., TRŽNI CENTAR GAVRO	90 (<1%)
1,223,320.00		Prodaja ≥ 7056 Grupa = OSTALO, PIVO, SOKOVI, TOALETNI PRIBOR Kupac = ANITA D.D., DUBROVNIK HOTELI, HOTEL DVOGLAV, MARIJA TRGOVACKI OBRT, MOJICA, HOTEL MALI MIR, SRECA TRGOVACKA RADNJA, TRGOVACKI OBRT LUNA, TRGOVACKI OBRT MALINA, ZORA D.O.O., PAPAN D.O.O., GAGA more...	105 (<1%)
1,141,630.00		Prodaja ≥ 7056 Grupa = KRUH, MLJEKO Kupac = BICIKLISTIČKO UGOSTITELJSTVO, ASTRID D.O.O., BELLA d.o.o., HOTEL TRIGLAV, HRAST D.D., NEBO more...	358 (3%)

Grupa, Kupac, Prodaja, and Regija predict Količina with a predictive strength of 82.9%.

Izvor: Autorski uradak

Analiza pokretača prikazuje na slici 27. da je kombinacija Grupe i Kupca glavni prediktor Količine sa prediktivnom snagom od 87%. Nakon što se klikne najdesnija kombinacija 2 pokretača, Grupa i Kupac, prikaže se automatski odabrana vrsta grafikona po nazivu Toplinska mapa (eng. Heat map) kao na slici 27.


Slika 27. Rezultati analize pokretača



Izvor podataka: Autorski uradak


Nakon što se odabere taj grafikon, otvara se isti u novoj kartici, gdje se prikazuju detalji kao na slici 29. Detalji daju na uvid sljedeće informacije. Prosjek količine vrijednosti svih Grupa i Kupaca je 466.859,32. Prosječna vrijednost svih kombinacija inputa (Grupa i Kupaca) ide od minimalno 154.236 do maksimalne prosječne vrijednosti od 11.507.098,46. Ta maksimalna vrijednost je neobična visoka pri razini povjerljivosti od 95% a odnosi na kombinaciju grupe „Kruh“ i kupca „Velika trgovina d.d.“. Zaključak koji bi se prema ovoj analizi mogao izvući je blizak zaključku stabla odlučivanja, iako na količinu ne utječe kombinacija kupaca već samo jedan, i to „Velika trgovina d.d.“. I dalje postoji isti problem o ograničenom uzorku podataka.

Slika 28. Kombinacija analize pokretača i toplinske mape



Izvor: Autorski uradak

Slika 29. Rezultati toplinske mape



Izvor: Autorski uradak

Slika 30. prikazuje isti rezultat kao analiza pokretača, tj. slika 26. samo na drugačiji vizualni način, u obliku spiralnog grafikona.

Slika 30. Rezultati spiralnog grafikona



Izvor: Autorski uradak

Posljednja analiza koja će se provesti je na asistentu kojemu je moguće postaviti pitanja. Prvo pitanje je bilo „show razlika u cijeni“ gdje nije prepoznao naredbu. Set podataka je zatim promijenjen gdje su naslovi napisani na engleskom jeziku. Ponovljen je upit samo u potpunosti na engleskom „show margin“ gdje asistent ponovno nije prepoznao naredbu. Nakon naredbe „help“ razgovor je tekao prema slici 31. Naredbe ručno napisane nisu funkcionirale. Radili su samo hyperlinkovi koje je asistent sam ponudio. Vidljivo je da postoji puno mjesta za napredak. Do kraja 2019. godine bi trebala izaći i nova inačica IBM Cognos Analyticsa gdje će možda ovakve stvari biti popravljene.

Slika 31. Razgovor s asistentom

The screenshots illustrate the following steps in the user's interaction:

- Initial State:** The user is on the 'KIM - eng.xlsx' dataset page. A 'help' button is visible.
- Request for Fields:** The user asks for relevant fields. The assistant provides a table:

Columns	Concepts
Margin	Continuous, HasOutlier, LowValueRepetition, Margin, PositiveValue
Quantity	Continuous, HasOutlier, LowValueRepetition, PositiveValue, Quantity
Sales	Continuous, HasOutlier, LowValueRepetition, PositiveValue, Revenue
COGS	Continuous, HasOutlier, LowValueRepetition, PositiveValue, Measure
Days of payment delay	Categorical, HasOutlier, Nominal, Delay, Monetary

- Request for Chart:** The user asks for a chart of 'Quantity and Buyer'. The assistant displays a word cloud titled 'Buyer and Quantity' with the text 'VELIKA TRGOVINA D.D.'.
- Request for Another Chart:** The user asks for a chart of 'Quantity and Group'. The assistant displays a bar chart titled 'Quantity by Group' with the following data:

Group	Quantity (Sum)
KUHIN	~7,500,000,000
MILJEVO	~1,000,000,000
MIRICE	~1,000,000,000
OTVALO	~1,000,000,000
PREVUNA BEOGRAD	~1,000,000,000
PIVO	~4,000,000,000
SUKRO	~1,000,000,000
TOALETNI PAPIRUK	~1,000,000,000

- Request for Influencing Fields:** The user asks 'what influences column Quantity'. The assistant provides a list of fields: Sales, Region, Buyer location, Distributive center, COGS, Days of payment delay, Margin, Buyer, Buyer type, Correspondent, Group, Qualifications, Subgroup, and Years on job.

Izvor: Autorski uradak

5. ZAKLJUČAK

Na temelju analize literature može se izvesti zaključak kako koncepti, teorijski okviri i definicije poslovne inteligencije, strojnog učenja i umjetne inteligencije postoje i pretvoreni su u praksu već dugi niz godina. No, pojam oko kojeg se diže prašina i razvijaju alati u posljednje vrijeme je proširena inteligencija. Proširena inteligencija je kombinacija ljudske sposobnosti razmišljanja i donošenja odluka u situacijama u kojima stroj to ne može. Ona nije isto što i umjetna inteligencija, već je umjetna inteligencija dio proširene inteligencije. Proširena inteligencija koristi mogućnosti umjetne inteligencije kako bi ljudima omogućila lakše i brže donošenje odluka i dobivanje prikriivenih informacija koje na prvo oko možda nisu vidljive. Provjerom ponude različitih ponuđača alata poslovne inteligencije, vidljivo je da u suštini svi nude iste stvari. Asistenta kojem se postavljaju pitanja, svi vode pridjevom „sophisticiranim“ kako bi opisali svoj alat, nude mogućnost mnoštvo vizualno privlačnih prikaza, grafikona, dijagrama i slično. U ovom radu je ispitano što sve trenutno može proširena inteligencija postići kada se stroj i čovjek ujedine da doznaju neke informacije. Dio u kojem je umjetna inteligencija u ovoj studiji slučaja pomogla je brzo računanje i davanje određenih informacija. Za korištenje ove aplikacije nije potrebno znanje statističkih izračuna već je potrebno znanje interpretiranja dobivenih rezultata na temelju tih izračuna, znanje interpretiranja grafikona napredne analitike. Dio u kojem nije pomogla je odgovaranje na pitanja kod asistenta, gdje nije mogao prepoznati ručno napisan zahtjev kojeg je on netom prije predstavio kao rezultat, te kvaliteta informacija. Postoji mogućnost da model, tj. set podataka nije bio dovoljno dobro postavljen, točnije da je bio prejednostavan. Problem je što većina grafikona napredne analitike za sada radi na uzorku podataka, a ne na cijelom setu podataka zbog performansi. Predlaže se nudenje mogućnosti odabir opsega podataka, sa zadanim minimum i neograničenim maksimum podatak kako bi se dobili realni rezultati određenih analiza. No, i dalje, određene informacije autor ne bi tako brzo dobio ručnim računanjem, koliko brzo je stroj uspio u par klika mišem prikazati. U realnim uvjetima u poslovanja, pretpostavka je da ova aplikacija trenutno ne može zaživjeti bez ulaganja puno resursa poduzeća u samo istraživanje srži aplikacije, metodama pokušaja i pogrešaka postaviti model koji odgovara algoritmima koji se u pozadini aplikacije vrte. Veliki potencijal je vidljiv i očekuju se samo koraci unaprijed za proizvođače ovakvih kompleksnih software-a. Suradnja strojeva i čovjeka je budućnost.

Popis literature

Knjige i znanstveni članci:

- 1) Chaudhuri, S., Dayal, U. (1997), „An overview of data warehousing and OLAP technology“, ACM Sigmod record, Vol. 26, No. 1, str. 65-74.
- 2) Elam, J. J., Leidner, D. G. (1995), „EIS adoption, use, and impact: the executive perspective“, Decision Support Systems, Vol. 14, No. 2, str. 89-103.
- 3) Engelbart, D. C. (1962), Augmenting human intellect: A conceptual framework, Menlo Park, CA.
- 4) Foley, É., Guillemette, M. G. (2010), „What is Business Intelligence?“, International Journal of Business Intelligence Research, Vol. 1, No. 4, str. 1-28.
- 5) Gorry, G. A., Scott-Morton, M. S. (1971), "A Framework for Management Information Systems", Sloan Management Review, Vol. 13, No. 1, str. 55-70.
- 6) Inmon, W. H. (2002), Building the Data Warehouse, Third Edition, Wiley.
- 7) Kimball, R., Caserta, J. (2004), The Data Warehouse ETL Toolkit - Practical Techniques for Extracting, Cleaning, Conforming, and Delivering Data, Wiley.
- 8) Luhn, H. P. (1958), „A business intelligence system“, IBM Journal of research and development, Vol. 2, No. 4, str. 314-319.
- 9) Pan, Y. (2016), „Heading toward artificial intelligence 2.0“, Engineering, Vol. 2, No. 4, str. 409-413.
- 10) Pasquinelli, M. (2015), Alleys of your mind: augmented intelligence and its traumas, meson press.
- 11) Power, D. J. (2008), „Decision Support Systems Concept“, u Adam, F., Humphreys, P. (Ur.), Encyclopedia of Decision Making and Decision Support Technologies, IGI Global, str. 232-235.
- 12) Sharda, R., Delen, D., Turban, E. (2014), Business Intelligence and Analytics: Systems for Decision Support, 10th edition, Pearson.
- 13) Varga, M. (2016), Baze podataka: Konceptualno, logičko i fizičko modeliranje podataka, Zagreb.
- 14) Vedder, R. G., Vanecek, M. T., Guynes, C. S., Cappel, J. J. (1999), „CEO and CIO perspectives on competitive intelligence“, Communications of the ACM, Vol. 42, No. 8, str. 108-116.
- 15) Watson, H. J., Rainer Jr., R. K., Koh, C. E. (1991), „Executive Information Systems: A Framework for Development and a Survey of Current Practices“, MIS Quarterly, Vol. 15, No. 1, str. 13-30.
- 16) Zheng, N.N., Liu, Z.Y., Ren, P.J., Ma, Y.Q., Chen, S.T., Yu, S.Y., Xue, J.R., Chen, B.D., Wang, F.Y. (2017), „Hybrid-augmented intelligence: collaboration and cognition“, Frontiers of Information Technology & Electronic Engineering, Vol. 18, No. 2, str. 153-179.

Web stranice:

- 17) Castañón, J. (2019), „10 Machine Learning Methods that Every Data Scientist Should Know“, dostupno na: <https://towardsdatascience.com/10-machine-learning-methods-that-every-data-scientist-should-know-3cc96e0eeee9> (22.09.2019).
- 18) Devens, R. M. (1865), „Cyclopædia of commercial and business anecdotes“, D. Appleton and company, New York, London, dostupno na: <https://archive.org/details/cyclopaediacomm00devegoog/page/n262> (06.09.2019).
- 19) Dickson, B. (2017), „What is the difference between artificial and augmented intelligence?“, dostupno na: <https://bdtechtalks.com/2017/12/04/what-is-the-difference-between-ai-and-augmented-intelligence/> (26.06.2019).
- 20) Gartner (2018), „Augmented Analytics Is the Future of Data and Analytics“, dostupno na: <https://www.gartner.com/en/conferences/emea/data-analytics-germany/why-attend/gartner-insights/research-augmented-analytics> (20.09.2019).
- 21) Gartner (2019), „5 Trends Appear on the Gartner Hype Cycle for Emerging Technologies, 2019“, dostupno na: <https://www.gartner.com/smarterwithgartner/5-trends-appear-on-the-gartner-hype-cycle-for-emerging-technologies-2019/> (18.09.2019).
- 22) Gartner (N/A), „Gartner Hype Cycle“, dostupno na: <https://www.gartner.com/en/research/methodologies/gartner-hype-cycle> (19.09.2019).
- 23) IBM (N/Aa), „IBM Cognos Analytics 11.1 : Introduction to Exploration“, dostupno na: <https://www.ibm.com/cloud/garage/dte/tutorial/ibm-cognos-analytics-111-introduction-exploration> (24.09.2019).
- 24) IBM (N/Ab), „Enriching packages“, dostupno na: https://www.ibm.com/support/knowledgecenter/en/SSEP7J_11.1.0/com.ibm.swg.ba.cognos.s.ag_manage.doc/t_gtsd_enrich_packg.html (24.09.2019).
- 25) IBM (N/Ac), „Explorations User Guide“, dostupno na: https://www.ibm.com/support/knowledgecenter/SSEP7J_11.1.0/com.ibm.swg.ba.cognos.ca_explorations.doc/ca_explorations.pdf (24.09.2019).
- 26) IBM (N/Ad), „Statistical tests“, dostupno na: https://www.ibm.com/support/knowledgecenter/en/SSEP7J_11.1.0/com.ibm.swg.ba.cognos.ug_ca_dshb.doc/c_wa_an_ovrvw_stat_tests.html (24.09.2019).
- 27) Microsoft (N/A), „Power BI“, dostupno na: <https://powerbi.microsoft.com/en-us/> (24.09.2019).
- 28) Qlik (N/Aa), „Qlik Sense“, dostupno na: <https://www.qlik.com/us/products/qlik-sense> (24.09.2019).
- 29) Qlik (N/Ab), „Qlik Insight Bot™“, dostupno na: <https://www.qlik.com/us/products/qlik-insight-bot> (24.09.2019).

- 30) Qlik (N/Ac), „Augmented intelligence and analytics“, dostupno na: <https://www.qlik.com/us/bi/augmented-intelligence-and-analytics> (24.09.2019).
- 31) Qlik (2019), „Data sheet - Modern, AI-powered Analytics - Qlik Sense“, dostupno na: <https://www.qlik.com/us/-/media/files/resource-library/global-us/direct/datasheets/ds-qlik-sense-datasheet-en.pdf> (24.09.2019).
- 32) Tableau (N/Aa), „Powerful Analytics“, dostupno na: <https://www.tableau.com/products> (24.09.2019).
- 33) Tableau (N/Ab), „Tableau Technology“, dostupno na: <https://www.tableau.com/products/technology> (24.09.2019).
- 34) Tableau (N/Ac), „Smart analytics“, dostupno na: <https://www.tableau.com/solutions/smart-analytics> (24.09.2019).
- 35) Ulag, A. (2018), „Announcing new AI Capabilities for Power BI to make AI Accessible for Everyone“, dostupno na: <https://powerbi.microsoft.com/en-us/blog/power-bi-announces-new-ai-capabilities/> (26.06.2019)

Popis tablica

Tablica 1. Okvir potpore odlučivanju	4
--	---

Popis slika

Slika 1. Primjer tehničke arhitekture sustava poslovne inteligencije	6
Slika 2. Gartner „Hype“ Ciklus 2019	8
Slika 3. Exploration aplikacija u IBM Cognos Analytics.....	10
Slika 4. Power BI alat	11
Slika 5. Primjena Azure Machine Learning u Power BI	12
Slika 6. Analiza ključnog pokretača u Power BI	13
Slika 7. Prikaz izgradnje modela strojnog učenja u Power BI.....	13
Slika 8. Qlik Sense alat	14
Slika 9. Insight Bot™ u Qlik Sense	15
Slika 10. Kognitivni (asocijativni) mehanizam u Qlik Sense.....	15
Slika 11. Tableau alat.....	16
Slika 12. Ask Data u Tableau	17
Slika 13. Explain data u Tableau	17
Slika 14. Prvotno stanje podataka u IBM Cognos Analytics.....	19
Slika 15. Postavke podataka	20
Slika 16. Alati na početnoj stranici.....	21
Slika 17. Dijagram veza.....	22
Slika 18. Vrste vizualizacije prema kategorijama u Exploration.....	23
Slika 19. Primjer stabla odlučivanja	23
Slika 20. Primjer sunburst grafikona	24
Slika 21. Primjer analize pokretača	25
Slika 22. Primjer spiralnog grafikona	25
Slika 23. Rezultati stabla odlučivanja.....	27
Slika 24. Top kupci prema analizi pokretača.....	28
Slika 25. Rezultati sunburst grafikona.....	28
Slika 26. Popis pravila modela	29
Slika 27. Rezultati analize pokretača	29
Slika 28. Kombinacija analize pokretača i toplinske mape	30

Slika 29. Rezultati toplinske mape	30
Slika 30. Rezultati spiralnog grafikona.....	31
Slika 31. Razgovor s asistentom	32

Životopis studenta

OSOBNNE INFORMACIJE

Ime i prezime: Bartolić Augustin
Adresa: Remete 57, 10000 Zagreb, Hrvatska
E-mail: bartolic.tin@gmail.com
Web adresa: www.linkedin.com/in/augustin-bartolic
Spol – Muški | Datum rođenja 01/12/1995 | Nacionalnost – Hrvat

RADNO ISKUSTVO

veljača 2019 - danas Konzultant za poslovna rješenja
Megatrend poslovna rješenja d.o.o., Zagreb - Odra, Hrvatska

veljača 2018 – danas Upravljački urednik
Business Systems Research Journal, Zagreb, Hrvatska

listopad 2017. – lipanj 2019. Demonstrator
Katedra za informatiku, Ekonomski fakultet Zagreb

srpanj 2017. – siječanj 2019. Suradnik na projektu prodaje potraživanja
Addiko Bank d.d.

OBRAZOVANJE

studeni 2018.- danas Magistar ekonomije
Ekonomski fakultet Zagreb

listopad 2014. – listopad 2018. Sveučilični Prvostupnik Ekonomije (Baccalaureus)
Ekonomski fakultet Zagreb

rujan 2010. – lipanj 2014. Ekonomist
Treća ekonomska škola

OSOBNNE VJEŠTINE

Materinski jezik / Strani jezici hrvatski/ engleski (samostalni korisnik)
španjolski (osnovni korisnik)

Poslovne vještine - Sposoban se brzo prilagoditi novim izazovima
- Kvalitetno vladam vremenskim ograničenjima stečenim radom na projektima
- Savjesno i predano pristupam zadacima koje rješavam temeljito i točno
- Smatram se povjerljivom osobom
- Težim osobnom i profesionalnom usavršavanju

Digitalne vještine MS Office, IBM Cognos Analytics Report Studio, IBM Cognos Framework Manager, SQL, Exasol

Vozačka dozvola B kategorija