Usporedba alata poslovne inteligencije: Tableau, Power BI i Qlik

Dubravac, Tomislav

Master's thesis / Diplomski rad

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Organization and Informatics / Sveučilište u Zagrebu, Fakultet organizacije i informatike**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:211:241759

Rights / Prava: Attribution 3.0 Unported/Imenovanje 3.0

Download date / Datum preuzimanja: **2024-04-17**

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN

Repository / Repozitorij:

Faculty of Organization and Informatics - Digital Repository

zir.nsk.hr

dabar
DIGITALNI AKADEMSKI ARHIVI I REPOZITORIJI

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Tomislav Dubravac

USPOREDBA ALATA POSLOVNE INTELIGENCIJE: TABLEAU, POWER BI I QLIK

DIPLOMSKI RAD

Varaždin, 2020.

SVEUČILIŠTE U ZAGREBU

FAKULTET ORGANIZACIJE I INFORMATIKE

V A R A Ž D I N

Tomislav Dubravac

Matični broj: 0246059564

Studij: Baze podataka i baze znanja

USPOREDBA ALATA POSLOVNE INTELIGENCIJE: TABLEAU, POWER BI I QLIK

DIPLOMSKI RAD

Mentor/Mentorica:

Prof. dr. sc. Kornelije Rabuzin

Varaždin, rujan 2020.

Tomislav Dubravac

Izjava o izvornosti

Izjavljujem da je moj diplomski rad izvorni rezultat mojeg rada te da se u izradi istoga nisam koristio drugim izvorima osim onima koji su u njemu navedeni. Za izradu rada su korištene etički prikladne i prihvatljive metode i tehnike rada.

Autor potvrdio prihvaćanjem odredbi u sustavu FOI-radovi

_____

Sažetak

Poslovanje je čin stvaranja nečega produktivnog kako bi isti taj proizvod uspio poslužiti nečijim potrebama, pridonio korisnosti u životu te samim time učinio svijet boljim mjestom. Time se najviše misli na poslovne aktivnosti koje se bilježe na papiru ili uz pomoć električnih medija te tako zapisi prerastaju u podatke. U poslovanjima, podaci se temelje na prikupljanju iskustva kupaca te o samoj industriji u cjelini. Navedeni podaci mogu se analizirati te „rudariti“ pomoću posebnih alata za poslovnu inteligenciju koji prvenstveno prikazuju kako pojedino poslovanje funkcionira. Spomenutim prikazima moguće je razviti daljnje ideje kako bi postale učinkovitije i imale utjecaj u budućim potrebama poslovanja.

Poslovna inteligencija uključuje alate i tehnike prikupljanja, analize te vizualizacije za pomoć pri donošenju izvršnih odluka u bilo kojoj vrsti industrije. Rudarenje podataka uključuje statističke i strojne tehnike učenja za izgradnju modela odlučivanja iz neobrađenih, odnosno nestrukturiranih podataka. Izgradnjom modela dolazi do strukturiranih podataka koji se pohranjuju u skladišta podataka koji uz povećavanje mogućnosti čišćenja podataka, povećane mogućnosti hardware-a i software-a te uz pojavu web arhitekture čine bogatije okruženje poslovne inteligencije.

Poznato je kako sustavi i alati poslovne inteligencije imaju širok pojas djelovanja te se istraživanje mora ograničiti. Tako će se u ovom diplomskom radu kompletno istražiti funkcionalnosti tri najpoznatija alata za poslovnu inteligenciju na primjeru novonastale epidemiološke situacije s COVID-19, a to su Tableau, Microsoft Power BI te Qlik.

Ključne riječi: poslovanje, poslovne aktivnosti, poslovna inteligencija, podaci, alati poslovne inteligencije, skladište podataka, statistika

Sadržaj

Sadržaj iii
1. Uvod 1
2. Poslovna inteligencija 3
2.1. Od podataka do poslovne inteligencije 3
2.2. Poslovna inteligencija 4
2.2.1. Definicija poslovne inteligencije 4
2.2.2. Poslovne vrijednosti poslovne inteligencije 6
2.2.3. Strategija poslovne inteligencije 7
2.3. Razvoj poslovne inteligencije 9
2.4. Pristupi razvoju poslovne inteligencije 10
3. Alati poslovne inteligencije 12
3.1. Prednosti alata poslovne inteligencije 12
3.2. Tableau Software 15
3.2.1. Tableau Desktop 16
3.2.2. Tableau Public 17
3.2.3. Tableau Online 17
3.2.4. Tableau Server 17
3.2.5. Tableau Reader 18
3.3. Microsoft Power BI 19
3.4. Qlik 22
3.4.1. QlikView 23
3.4.2. Qlik Sense 23
4. Baza podataka 26
4.1. Tipovi baza podataka 27
4.1.1. Relacijske baze podataka 27
4.1.2. Objektno orijentirane baze podataka 28
4.1.3. Distribuirane baze podataka 28
4.1.4. Skladišta podataka 29
4.1.5. NoSQL baze podataka 29
4.2. Sustav za upravljanje bazom podataka (SUBP) 30
5. Projektni zadatak – COVID-19 33
5.1. Baza podataka 33
5.2. Analiza podataka – Tableau 38

5.3. Analiza podataka – Microsoft Power BI 44
5.4. Analiza podataka – Qlik 48
6. Usporedba alata poslovne inteligencije 53
6.1. Prednosti i nedostatci – Tableau vs. Power BI vs. Qlik 54
6.1.1. Vizualizacija podataka 54
6.1.2. Analitika 54
6.1.3. Mrežna analitička obrada (OLAP) 55
6.1.4. Upravljanje dokumentima 56
6.1.5. Mogućnost odlučivanja 56
6.1.6. Integracija 57
6.1.7. Integracija velikih podataka 58
6.2. Konstatacija prednosti 59
7. Zaključak 60
Popis literature 61
Popis slika 63
Popis tablica 65

1. Uvod

U današnje vrijeme informacijskih tehnologija (eng. Information Techonology), poslovna inteligencija (eng. Business Intelligence) je i dalje u vrlo velikom porastu čak i uz činjenicu kako neki proizvodi spomenutih informacijskih tehnologija gube svoju potražnju na tržištu. Ipak, temeljem istraživanja informacijskih sustava na ovom polju, može se reći kako još uvijek ima mjesta za napredak.

Prije pedesetak godina pojavili su se prvi računalni sustavi koji su bili temelji poslovne inteligencije. To su sustavi koju su pružali podršku u odlukama, izvršni te upravljački informacijski sustavi, a danas su zamijenjeni novijim pojmom, poslovnom inteligencijom. Sa svakom novom iteracijom, mogućnosti su se povećavale kako su poduzeća postojala sve sofisticiranija u svojim računalnim i analitičkim potrebama te kako su se razvijali računalne komponente (eng. Hardware) i računalni programi (eng. Software). Na temelju takvih pretpostavki Negash S. [1] je opisao sustav poslovne inteligencije na sljedeći način: „*Sustavi poslovne inteligencije kombiniraju procese prikupljanja podataka, pohranu istih te upravljanje znanjem uz pomoć analitičkih alata kako bi se poslovnim analitičarima predstavile složene interne i konkurente informacije.*“ Ideja ove definicije podrazumijeva da sustavi poslovne inteligencije pružaju informacije, isporučene u pravo vrijeme, na pravom mjestu i u pravom obliku kako bi se poslovnim analitičarima i njihovim izvršnim ljudima pomoglo u donošenju konkretnih i ispravnih odluka. Cilj je poboljšati pravovremenost informacija i kvalitetu istih u procesu donošenja odluka koja će pri tome olakšavati poslovanje.

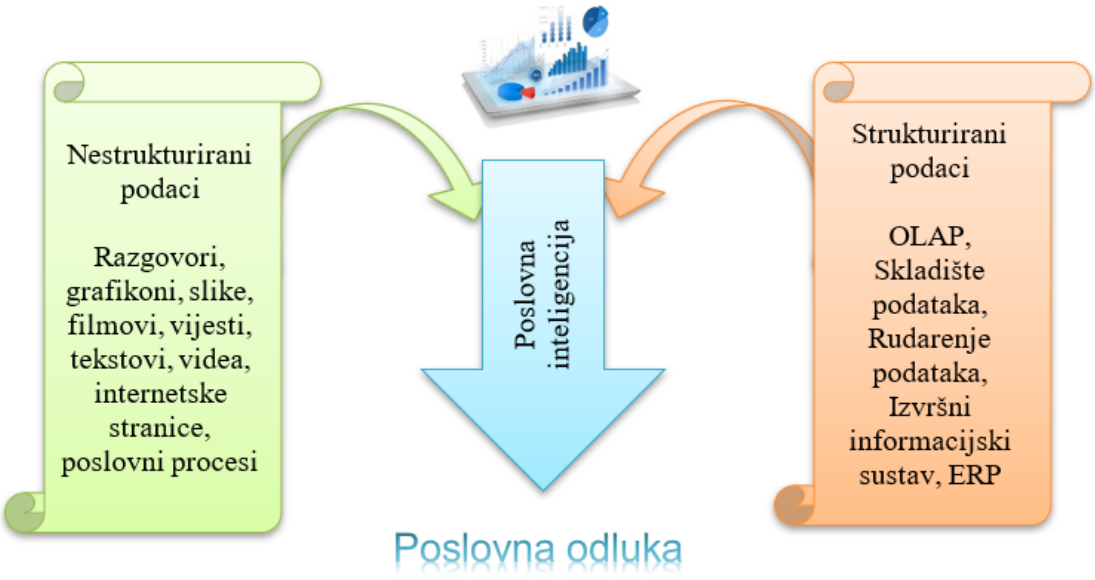

Slika 1. Proces sustava Poslovne inteligencije

Na slici 1. prikazana je raznolikost dostupnih izvora i podataka koje pružaju mogućnost provedbe poslovne inteligencije potrebne za donošenje odluka. Poslovni analitičari obično određuju što žele pratiti na temelju njihovih ključnih indeksa uspješnosti (eng. Key Performance Indexes, KPI) ili na temelju ključnih rezultata (eng. Key Results Area, KRA). Takva prilagođena izvješća moraju biti dizajnirana tako da pružaju tražene informacije svima koji sudjeluju u donošenju izvršnih odluka. Ta se izvješća mogu prikazati u prilagođenim nadzornim pločama koje isporučuju informacije vrlo brzo te u lako razumljivim formatima.

2. Poslovna inteligencija

U ovom dijelu se govori o teorijskoj pozadini diplomskog rada te prolazi kroz teorijske okvire koji izgrađuju i podržavaju poslovnu inteligenciju, odnosno poslovanje samo po sebi. Prvo poglavlje definira informacije koje su relevantne u poslovnom odlučivanju te zašto su one potrebne organizacijama. Zatim će biti predstavljeni koncepti poslovne inteligencije te njezine strategije. Na kraju ovog poglavlja, predstavit će se trenutno stanje te metodologije za razvoj same poslovne inteligencije, što je vrlo bitno dobro postaviti strategiju poslovne inteligencije kako bi krajnji rezultati, a u konačnici i proizvod bio što uspješniji.

2.1. Od podataka do poslovne inteligencije

U akademskoj literaturi postoji mnoštvo definicija i mišljenja o odnosu između podataka (eng. Data), informacija (eng. Information), znanja (eng. Knowledge) i inteligencije (eng. Intelligence). Najčešća ideja je da postoji hijerarhija u kojemu se podaci nalaze na dnu piramide prema znanju koje bi bilo na vrhu. Prema takvoj ideji, podaci se utjelovljuju kao skup jednostavnih opažanja i činjenica koje moraju postojati prije nego što se informacije mogu stvoriti. Tek nakon tih dviju faza, određeno znanje može biti stečeno putem inteligencije. Upravo zato se smatra da podaci imaju najmanju vrijednost, samim time što se sastoje samo od pukih numeričkih, tekstualnih i signalnih znakova. Može se slobodno reći kako u lancu informacijskih vrijednosti, djeluju kao sirovina za sofisticiranije razine informacijskih elemenata. Lako se prenose s operativnih sustava u različite baze podataka, bez da se izgubi njihov sadržaj. Prenošenjem u različite baze podataka, podaci sastavljaju skladišta podataka koje se kasnije koristi kao osnova za referencu ili analizu istih.

Informacije se smatraju jednom razinom više u spomenutoj hijerarhiji u odnosu na podatke. Informacije se definiraju kao podaci koji imaju određeni smisao. Također informacije uvijek sadrže neku vrste poruke, koja se može subjektivno interpretirati te se samim time može zaključiti da je informacija važnija od podataka. Informaciju je također teže prenositi putem informacijskog sustava, pa predstavlja određeni izazov za automatizaciju informacijskih procesa. Kada se informacija interpretira s određenim značenjem, u tom trenutku se pretvara u znanje. Znanje je određeno kao najvrjednija vrsta informacija u lancu vrijednosti jer se koristi kao osnova operativnih i strateških akcija te samim time je bliže procesu odlučivanja. Znanje također može biti strukturirano ili nestrukturirano te prešutno ili eksplicitno ovisno o tome, može li se lako širiti i predstavljati brojevima i tekstom ili je povezano s osobnim iskustvima i znanjem.

Poslovna inteligencija kao proces i kao organizacijska funkcija također sudjeluje u lancu vrijednosti informacija, i to tako da obrađuje procesirane podatke i informacije u inteligenciju koja se kasnije može iskoristiti na svim razinama organizacije što dovodi do boljih i pravovremenih poslovnih odluka. Jednostavnije se može reći kako je inteligencija zapravo znanje i predviđanje unutarnjeg i vanjskog okruženja poslovanja u kojemu određena organizacija djeluje. Kako bi se napravila razlika između znanja i inteligencije, inteligencija se stavlja u kontekst uključivanja informacija o kritičnim trendovima i obrascima kao i odnose između aktivnosti organizacije i kupaca koji označavaju određene uzročne slučajeve te očekivane promjene. Takvi slučajevi i promjene trebali bi ukazivati na nove mogućnosti i prijetnje u poslovanje koje su vrlo bitni za strateško usmjeravanje poslovnog odlučivanja. [2]

2.2. Poslovna inteligencija

Zadnjih godina, poslovna inteligencija je postala vrlo važna stavka u poslovnoj industriji, a pogotovo u industriji u kojoj se upravlja velikim brojem podataka i informacija. U početku se poslovnu inteligenciju smatralo samo kao konzultantski motiv koji bi mogao poboljšati trenutno poslovanje, no danas je smatraju kao potencijalni izvor prednosti nad konkurencijom. Organizacije danas prikupljaju podatke u većoj količini i s što većom preciznošću, tako da se izazov upravljanja informacijama promijenio iz „dovoljne“ količine podataka u učinkovitost analize sa što većom preciznošću te njezinim korištenjem. Podaci koji se prikupljaju u organizaciji obično se spremaju po različitim sustavima, upravo zbog toga što je izvora u današnjem svijetu vanjskih informacija u izobilju. Zbog toga, struktura informacija je često nespojiva i teško se može zajedno integrirati i koristiti što rezultira nedostatkom cjelokupnog zaključka. Međutim, uz pomoć poslovne inteligencije, moguće je takve fragmentirane i razbacane informacije integrirati, obraditi i distribuirati cijeloj organizaciji kako bi se podržala operativna, taktička i strateška odluka.

2.2.1. Definicija poslovne inteligencije

Kao što je već spomenuto, poslovna inteligencija se kao termin koristi prilično ambivalentno, odnosno ne može se objasniti samo na jedan način. Njezina definicija može varirati od koncepata koji se odnose na sustav podrške u odlučivanju (eng. Decision suport system, DSS) pa sve do sinonima za upravljanje znanje (eng. Knowledge managment, KM) ili konkuretnom inteligencijom (eng. Competitive Intelligence, CI). No najčešća definicija je ta da se poslovna inteligencija upotrebljava široko i obuhvaća sve koncepte koji se odnose na sustavno i kontinuirano prikupljanje, analizu i razmjenu internih i vanjskih poslovnih informacija.

U početcima se smatralo da se izraz poslovna inteligencija može upotrijebiti za označavanje tri različita koncepta: procesa, organizacijskih funkcija te proizvoda. Također smatralo se da je poslovna inteligencija aktivnost koju pojedinci koji rade u organizacijskoj funkciji kako bi proizveli određeni proizvod. Krenuvši s procesnog gledišta, poslovna inteligencija kombinira sustavne aktivnosti koje su izravno povezane s podrškom za donošenje odluka, poput prikupljanja, sastavljanja i pohrane podataka iz različitih izvora te ocjenjivanja i pretvaranja istih u djelotvorne informacije za daljnju upotrebu. Spomenuti procesi su uglavnom usmjereni na poboljšanje performansi primarnih i sekundarnih poslovnih aktivnosti. Radi zadovoljavanja jednokratnih potreba, procesi poslovne inteligencije prikazuje se kao kontinuirani ciklus od pet ključnih zadataka: specificiranje informacijskih potreba, prikupljanje, obrada, širenje i korištenje informacija. Specificiranjem potreba za informacijama, organizacija analizira kakve su informacije potrebne za rješavanje poslovnih problema i osigurava da se u odlučivanju koriste samo relevantne informacije. Bitno je naglasiti važnosti povratnih informacija (eng. Feedback) korisnika u optimizaciji svih faza ciklusa poslovne inteligencije. [2]

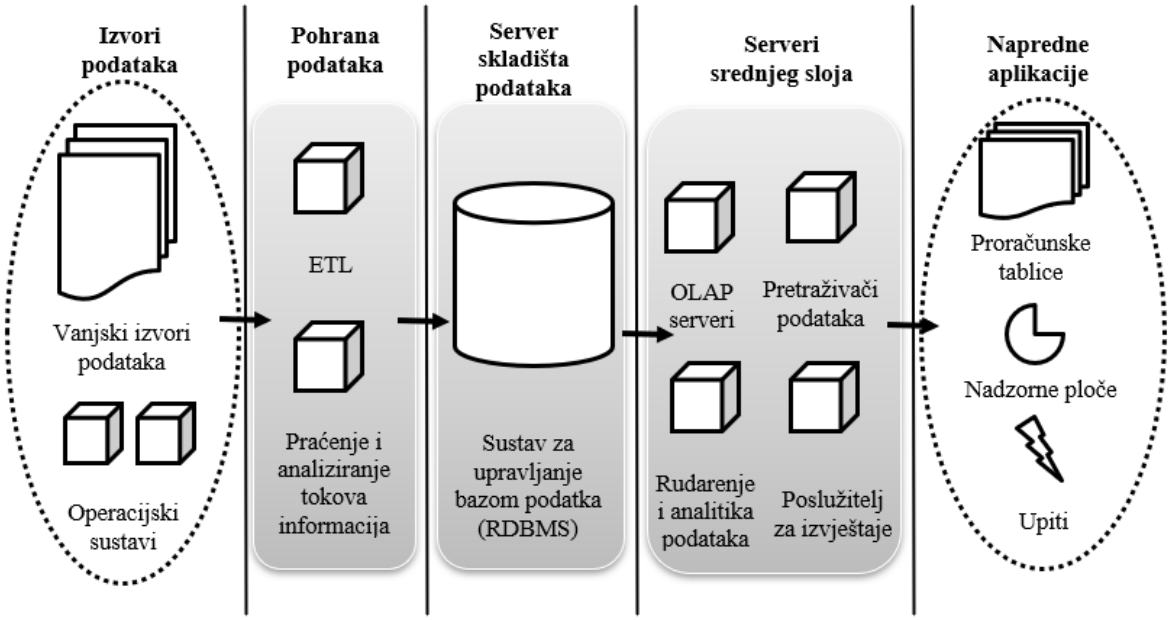

Slika 2. Arhitektura poslovne inteligencije [2]

Arhitektura poslovne inteligencije može se podijeliti u dva dijela: „back-end“ tehnologije skladištenja podataka i „front-end“ tehnologije pristupa podacima koje uključuju analizu podataka te alate za izradu izvještaja te njihovu distribuciju. Na početku samog procesa poslovne inteligencije, dolazi do skladištenja podataka koji integriraju, čiste i validiraju podatke koji su putem ETL (eng. Extract-transform-load) postupka preuzete, transformirane te učitane iz različitih izvora te se prema određenoj logici spremaju u bazu podataka, odnosno u skladište podataka. Nakon skladištenja skupa podataka koji će biti ključni za donošenje poslovnih odluka, dolazi navedena „front-end“ tehnologija koja pruža poslovnim korisnicima pristup

skladištu podataka putem alata kao što su proračunske tablice (eng. Spreadsheets), nadzorne ploče (eng. Dashboard) te SQL upiti (eng. SQL query). Tipična arhitektura poslovne inteligencije kao što je prikazano na Slici 2. u početku je ograničena na pristup raznim podacima te njezinoj analizi za kasniju implementaciju. Kao zasebna aktivnost tu je pohrana podataka koja uključuje ETL proces te dolazi do izrade dizajna i implementacije skladišta podataka. U daljnjem procesu, kroz sustav za upravljanje bazama podataka, podaci se pripremaju i spremaju za kasniju izradu izvještaja na temelju SQL upita te raznih nadzornih ploča.

Ukratko, poslovna inteligencija je zapravo filozofija upravljanja koja se često smatra tehnologijom, procesima, praksama te funkcijama koje analiziraju kritične poslovne podatke kako bi pomogli organizaciji da poveća poslovnu svijest, stekne cjelovit prikaz svojih mogućnosti i poslovnog okruženja te se time donesu bolje poslovne odluke. Sadrži metode kao što su strateško upravljanje performansama i konkurenta inteligencija te pruža alate za prikupljanje i vizualizaciju podataka koji pomažu u prikazivanju rezultata u obliku koji je bogat informacijskim sadržajem. Također, primarni ciljevi poslovne inteligencije su izbjegavanje iznenađenja, prepoznavanje prijetnji i prilika te razumijevanje gdje je organizacija ranjiva. Isto tako dolazi do smanjenja vremena reakcije na promjene u operativnom okruženju, do nadmetanja s konkurencijom te služi za zaštitu intelektualnog kapitala.

2.2.2. Poslovne vrijednosti poslovne inteligencije

U poslovnom svijetu postoje tri opće svrhe u koje se poslovna inteligencija implementira. Prva i osnovna svrha je ta da organizacija želi stvoriti opći uvid u svoje poslovanje. Također, pritisak konkurencije na tržištu povećava samu neizvjesnost organizacije te je poslovna inteligencija postala nužnost koja je potrebna kako bi poslovanje imalo što veću učinkovitost te omogućiti sve dinamičnije poslovno okruženje. Samim time poslovna inteligencija postala je ključna aktivnost koja pomaže poslovnim službenicima u prognoziranju ponašanja na tržištu, tako da se organizacija može prilagoditi promjenjivim uvjetima poslovanja. Uz to, poslovna inteligencija pruža menadžmentu (eng. Management) bolje razumijevanje osnovnih trendova tržišta te ovisnosti koji utječu na okruženje u kojem djeluju.

Druge dvije svrhe poslovne inteligencije odnose se na koherentnost organizacijskih podataka. Poslovna inteligencija može olakšati i organizacijsku transformaciju, bilo to na način da se radi reorganizacija funkcija ili o spajanju i akviziciji dviju organizacija u kojemu se razmjenjuje velika količina podataka. Takve organizacijske promjene dovode nove klijente s potpuno novim potrebama i zahtjevima. Dobivanjem jedinstvene verzije skupa informacija, olakšava se komunikacija između pojedinaca u organizaciji, a samim time i kvaliteta podataka te ušteda vremena pri izradi analize. Također, poslovna inteligencija, organizacijama

omogućava da se nose s novim zakonskim regulativama te omogućava bolje upravljanje informacijama koje se dijele u tri kategorije. Prva kategorija se odnosi na povećanu učinkovitost u kojoj se postiže veća razina automatizacije, brži pristup informacijama i bolje korištenje samog informacijskog kapitala. Druga kategorija koju navode je poboljšanje kvalitete informacija te upravljanje rizikom u kojoj poslovna inteligencija omogućava smanjenje pogrešaka te bolje usklađivanje s potrebnim standardima, a samim time i sigurnost sustava. Zadnja kategorija je kategorija koja omogućava usluge na puno višoj razini u kojoj se dodaju nove vrijednosti postojećim uslugama, veća dostupnost te brži procesi obrade podataka. Također, dodaju kako poslovna inteligencija omogućava učinkovitiju upotrebu informacija o kupcima, identifikaciju najprofitabilnije segmente kupaca te na temelju toga razvoj cjenovnih struktura i strategija kako bi se proširio i poboljšao odnos s kupcima. [3]

2.2.3. Strategija poslovne inteligencije

Razvoj organizacijskih ciljeva, struktura i procesa ima za cilj održavanje konkurentnosti organizacije i poboljšanje njezinog učinka kako bi se ispunili zahtjevi tržišta, odnosno same industrije te ih u budućnosti i nadmašili. Bez sustavnog korporacijskog planiranja, poslovanju je zajamčeno putovanje iz krize u krizu. Upravo iz tog razloga, potrebna je strategija kojom se organizacija može unaprijed pripremiti na nadolazeće promjene u svom poslovnom okruženju te tako smanjiti improviziranje poslovnih procesa koji često mogu stvoriti velike troškove te ometati trenutno poslovanje.

Postoji nekoliko akademskih modela i okvira koji definiraju i ukazuju na razvoj poslovne strategije. Među najraširenijim su Porterov model pet konkurentskih sila (eng. Porter's five-forces), Porterov lanac vrijednosti (eng. Porter value chain model) i teorija ključnih kompetencija (eng. Core competency theory). Prema Mintzberg-ovom dobro poznatom 5P modelu strategija se može definirati kao:

- plan (eng. Plan) → odlučeni tijek akcije
- trik (eng. Ploy) → posebna akcija koja se koristi za postizanje konkurentske prednosti
- uzorak (eng. Pattern) → popis radnje i logike koja stoji iza njih
- položaj (eng. Position) → naglasak na položaj unutar vanjskog okruženja
- perspektiva (eng. Perspective) → način percepcije posla koji se dijeli među članovima organizacije

Poslovna strategija usklađuje se s trendovima vanjskog okruženja i djeluje kao nacrt organizacijske strukture. [4]

Promjenama u poslovnoj strategiji stvaraju se i nove potrebe za informacijama, što dovodi do promjena u upravljanju informacijama te u konačnici i u arhitekturi informacijske tehnologije (eng. Information techology, IT). Stoga se podrazumijeva da bi trebala postojati razlika između zahtjeva za informacijom i kapaciteta koliko se informacija može obraditi. Razlika je u tome što se zahtjevi za informacijama prevode i strategije poslovne inteligencije koja se zatim usklađuje s opsežnijom IT strategijom, dok se kapacitet za obradu informacija odražava i na arhitekturi poslovne inteligencije i IT-a.

Kao što postoji mnogo izraza za opisivanje različitih aktivnosti u organizaciji, tako postoji i mnoštvo termina za različite strategije koje se tiču informacija. Organizacije čije se poslovanje temelji na znanju i inteligenciji, dijele strategije na tri kategorije. Prva kategorija je strategija za ono što treba učiniti te se ta kategorija odnosi na informacijske sustave (IS). Sljedeća kategorija je strategija kako to treba učiniti te opisuje kako postupati s informacijskom tehnologijom (IT) te posljednja kategorija je strategija za određivanje tko bi to trebao raditi i odnosi se strategiju upravljanja informacijama (IM). Strategija poslovne inteligencije je zapravo okvir upravljanja koji vodi organizaciju aktivnosti poslovne inteligencije te je usklađen s tri spomenute strategije povezane s informacijama. Također, može se reći kako ona usmjerava resurse organizacije u pravom smjeru i pomaže navedenim aktivnostima da održavaju pravi fokus te izgrade pravu kulturu upravljanja informacijama te da pronađu prave kupce za svoje proizvode. Najveća pitanja koja se tiču upravljanja informacijama proizašla su upravo zbog toga što organizacije nisu imale strategije koje će usmjeravati poslovnu inteligenciju ili organizacijsku strukturu kako bi mogli ponuditi nove proizvode koji će moći konkurirati na tržištu.

Poslovna strategija organizacije je glavni kontekst za utvrđivanje potrebnih inicijativa poslovne inteligencije. Pomaže u predviđanju potreba poslovanja za budućim resursima te pruža okvir za određivanje prioriteta u inicijativama koje najviše podržavaju misiju organizacije. Stoga, strategija poslovne inteligencije može se uzeti u obzir u sljedećim granama organizacije: [3]

- poslovno okruženje (eng. Business environment) → industrija, dionice, vlasnička struktura, konkurencija
- ciljevi (eng. Objectives) → strategija, vizija
- službena organizacijska struktura (eng. Offical organizational structure) → organizacijska shema, veličina organizacije, globalna disperzija
- neslužbena organizacijska struktura (eng. Unofficial organizational structure) → kultura, vrijednosti zakoni i standardi (eng. Laws and standards)

2.3. Razvoj poslovne inteligencije

Razvoj i implementacija strategije za koordinaciju poslovne inteligencije na razini cijele organizacije zahtijeva opsežan proces planiranja koji uzima u obzir socijalne, organizacijske i tehničke aspekte upravljanja informacijama. Socijalna i organizacijska stajališta prema poslovnoj inteligenciji stavljaju fokus na razvoj procesa i praksi u organizaciji, umjesto dosadašnjih loših tehnoloških inicijativa. Na temelju toga dolazi do upotrebe takozvanog dijamantskog modela koji prikazuje koordinaciju planiranja kod upravljanja informacijama. Princip samog modela je poprilično jasan jer se koristi kao popis za provjeru da li su sve komponente strategije poslovne inteligencije uzete u obzir tijekom same izrade strategije poduzeća. U modelu se informacije nalaze u organizacijskom i tehnološkom okviru te su u središtu tri komponente koje su potrebne za samo upravljanje, a to su procesi, uloge i tehnologije. Spomenute komponente su izravno povezane jedna s drugom i tvore oblik dijamanta oko informacija u središtu modela, što je prikazano na Slici 3. [2]

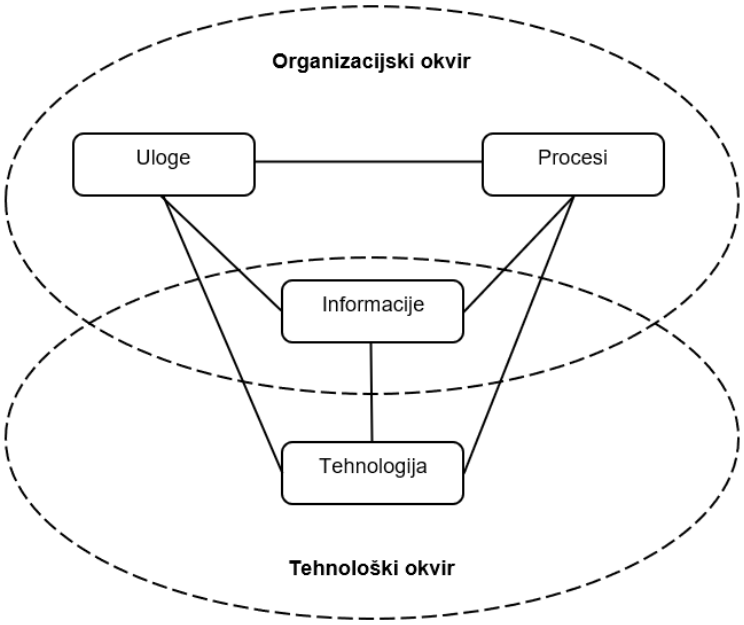

Slika 3. Dijamantni model upravljanja informacijama

Povezanost između tri glavne komponente i informacija jedna je od najvažnijih zadataka u primarnim fazama projekta razvoja informacijskog upravljanja. Veza između uloga i informacija koristi se kao osnova sustava u kojoj se ciljaju određeni korisnici te se formiraju korisničke grupe s različitim pravima pristupa. Pristupi informacijama u sustavima poslovne inteligencije povezani su s hijerarhijom uloga utvrđenoj u organizaciji. Sukladno tome, analiza povezanosti informacija i procesa daje uvid u vrstu informacija koje su potrebne, obrađene te

proizvedene u određenom procesu. Gledajući tehnologiju, njezina povezanost s drugim komponentama olakšava identifikaciju potrebnih mogućnosti informacijskih sustava u procesima te aktivnostima u organizaciji. Na temelju navedenih povezanosti, komponente i okviri čine tri stajališta razvoja informacijskog upravljanja te moraju biti zajedno ukomponirani u strategiju poslovne inteligencije.

2.4. Pristupi razvoju poslovne inteligencije

Najkritičnija faza u razvoju poslovne inteligencije i njezine strategije, koja također može utjecati na uspjeh svih ostalih faza, jest analiza zahtjeva za informacijama. Analizom zahtjeva može se izgraditi baza koja će moći procijeniti opseg projekta i time lakše omogućiti dizajn upravljanja informacijama. Takvom analizom predstavljaju se tri pristupa metodama razvoja skladišta podataka koji služe u usklađivanju budućih potreba za informacijama te njihovom opskrbom. Pristup utemeljen na podacima ignorira informacije koje su potrebne u razvoju podrške poslovanja sve dok se skladište podataka ne popuni organizacijskim podacima i dok se ne analiziraju rezultati upita. Slijedeći ovaj pristup, izrada strategije poslovne inteligencije temelji se na analizi postojećih modela podataka i transakcija koje se proizvode unutar organizacije. U poslovnom svijetu, ovakav pristup je bio vrlo kritiziran jer nije održavao organizacijske ciljeve te je riskirao trošenje resursa pohranjivanjem suvišnih podataka. Suprotno tome, pristup temeljen na potražnji konstruira strategiju koja se temelji na točno određenim potrebama poslovanja. Uz uključenje poslovnih korisnika, informacije se skupljaju i obrađuju iz različitih izvora te se potom analiziraju s obzirom na poslovne ciljeve. Poslovni korisnici određuju poslovne ciljeve u kojima bi se skladišta podataka trebala uskladiti s prioritetima te definirati inicijative koje bi podržavale ciljeve.

Prethodna dva pristupa koriste tehniku odozdo prema gore (eng. Bottom-up) jer se podaci prikupljaju unaprijed te se tek tada inicijativa poslovne inteligencije usklađuje s poslovnom strategijom. Treći pristup naziva se ciljanim pristupom u kojemu se koristi tehnika odozgo prema dolje (eng. Top-down). Tehnike odozgo prema dolje koriste se u upravljanju informacijama, posebice pri izgradnji cjelokupnog, integriranog skladišta podataka za određenu organizaciju. Pristup usmjeren ciljevima započinje usklađivanjem između poslovnih ciljeva i skladišta podataka uključivanjem svih organizacijskih jedinica u razvojni proces. Poslovni ciljevi proizlaze iz poslovne strategije, što također utječe i na samu shemu podataka koja je potrebna za funkcioniranja. Poslovne ciljeve treba pretvoriti u model podataka uz podršku mjernih karakteristika svakog poslovnog pitanja te procesa.

Sva tri pristupa imaju istu slabost. Ona se temelji na tome da krajnji korisnici rijetko mogu definirati poslovne ciljeve s kojima bi se trebalo usklađivati skladište podataka. Oni su u

nemogućnosti navesti potrebe za informacijama koje im trenutno nisu dostupne ili su još uvijek nepoznate. Moglo bi se reći da su njihova stajališta subjektivna, što znači da imaju specifično mišljenje i tumačenje informacija i da nisu niti svjesni svih dostupnih izvora informacija. Upravo je to razlog zašto se u većini slučajeva zanemaruje mogućnost skladištenja podataka. Kako bi se izbjegao takav scenarij, kako bi se prikupile poslovne informacije koriste se tehnike poput korisničkih intervjua (eng. User Interviews), oluje mozgova (eng. Brainstorming) i *JAD sesija* (eng. JAD sessions). Navedene tehnike mogu se prikupljati u obliku poslovnih pitanja koja se odnose na podršku u odlučivanju ili na situacijske probleme s kojima se obično susreću vodeći ljudi organizacije. [5]

3. Alati poslovne inteligencije

U današnje vrijeme često se u poslovnim krugovima, a isto tako i u suvremenom svijetu može čuti izreka „radite pametno, a ne teže“ (eng. work smarter, not harder“). Spomenuta fraza odlično odgovara za alate poslovne inteligencije. Softver poslovne inteligencije sastoji se od niza alata za analizu podataka dizajniranih za analizu i upravljanje podacima koji se odnose na određeno poslovanje. Neke od pogodnosti poslovne inteligencije uključuju bogate mogućnosti vizualizacije koje tvrtkama omogućuju nadzor prodaje, logistike, pa čak i produktivnosti. Također pruža opsežnu analizu podataka pomoću bogato vizualiziranih i intuitivnih izvještaja. Predstavljajući svoje podatke u lako razumljivom formatu, alati poslovne inteligencije pomažu poduzećima kako bi bolje razumjela prednosti i slabosti pružajući uvid u KPI (eng. Key performance indicators) i ostale važne faktore poslovanja. To ih čini kritičnim alatima za osiguranje konkurentnosti i profitabilnosti.

3.1. Prednosti alata poslovne inteligencije

Uključivanje uvida u vrijednosti poslovanja poduzeća

Prednosti i funkcionalnosti alata za poslovnu inteligenciju je ta da neprestano prikupljaju i analiziraju podatke kako bi se pružili uvidi u poslovanje poduzeća. U to ulazi generiranje raznih izvještaja o različitim skupovima podataka kao što su troškovi, operativni procesi, osoblje te korisničke usluge. Izvještaji koje alati poslovne inteligencije kreiraju mogu biti različite vrste. Sve platforme poslovne inteligencije nudit će unaprijed definirane mogućnosti izvještavanja koji prikupljaju podatke za KPI. Poduzeća također mogu generirati prilagođena izvješća primjenjujući vizualne podatke koje su specifična za određenu organizaciju. Također, postoje i ad-hoc izvješća koja su sastavljena direktno od korisnika te se obično usredotočuje na vrlo specifičan KPI koji ne mogu dati rezultate na drugim vrstama izvještaja. U ovoj grupi prednosti također treba spomenuti i relevantnost informacija. Budući da izvješća sadrže relevantne podatke prikupljene unutar određenog poslovanja, tvrtke su u mogućnosti djelovati na temelju podataka sadržanih u izvještajima poslovne inteligencije. Uz to, vizualizacija podataka koji su generirani alatima poslovne inteligencije vrlo lako je za razumjeti i objasniti.

Vizualizacija važnih podataka

Operativna izvješća mogu biti teška za tumačenje, smanjuje sposobnost organizacije da prepozna te da odmah djeluje na ključne metričke podatke. Samim time, jedna od ključnih prednosti alata poslovne inteligencije je ta što pruža izvrsne mogućnosti vizualizacije podataka, omogućujući tako korisnicima stvaranje intuitivnih vizualnih podataka koji su lako razumljivi i jednostavni za tumačenje. Grafikoni, videozapisi, animacije i slične vizualizacije privlačniji su za prikaz informacija od blokova brojeva te proračunskih tablica. Djelomično je to zato što je ljudski mozak teško obrađuje kognitivne informacije, odnosno informacije koje za tumačenje trebaju više pregleda što mnogo je mnogo sporije od vizualnih informacija.

Rudarenje podataka

Analitički alati poslovne inteligencije izuzetno su prikladni za snažno rudarenje podataka. Rudarenje podataka je proces traženja obrazaca podataka kako bi se prepoznali trendovi te se iz njih izvukli uvidi u iste. Provodi se u pet koraka: prikupljanje, skladištenje, organizacija, analiza i prezentacija. Neke platforme poslovne inteligencije mogu provesti sve korake za neku organizaciju, dok pojedine zahtijevaju podršku alata za analizu poslovanja, alata za analizu podataka te alata za njihovo skladištenje. Poslovna inteligencija analizira, obrađuje i prikazuje ogromne količine podataka koje se ne mogu upravljati slabijim alatima. Integrira se rješenjima za pohranu podataka, internim bazama podataka (npr. SQL poslužitelji), kao i strukturiranim i nestrukturiranim podacima. To omogućava jednostavan pristup informacijama te poboljšanim procesima donošenja odluka koje tvrtke inače mogu propustiti.

Uspostavljanje Benchmarking-a

Brzo razmišljanje i učinkovito odlučivanje važno je za postizanje uspjeha u poslovnom svijetu. Često odgovorni za vođenje poduzeća nemaju vremena za provođenje opsežnog istraživačkog projekta i određenog razvoja industrije. Korištenjem alata poslovne inteligencije neprestano mogu izvoditi dubinska istraživanja projekta koji skuplja informacije za donošenje temeljnih i kritičnih odluka. Benchmarking je vrijedan alat za analizu podataka kojega tvrtke koriste za mjerenje svoje produktivnosti, prihoda i općeg uspjeha u odnosu na konkurenciju. Organizacije često znaju imati dvojbe korištenjem benchmarking-a, na što poslovna inteligencija ima odgovora tako što pojednostavljuje postupak, pružajući djelotvorne informacije i izvješća koja su lako razumljiva. Zbog toga sve više korisnika traži pomoć u poslovnoj inteligenciji.

Upravljanje učincima poslovanja

Poslovna inteligencija također pomaže i u praćenju, upravljanju te provedbi ciljeva poslovanja. Pomoću alata, tvrtke mogu unositi ciljeve temeljena na podacima, poput prodajnih ciljeva ili ciljanog vremena isporuke, a zatim pratiti napredak na dnevnoj bazi. Ovakav mehanizam praćenja poznat je kao upravljanje učinkom i pruža neke od najučinkovitijih i lako implementiranih dostupnih ciljeva upravljanja. Alati poslovne inteligencije čine informacije lako dostupnim za što bi obično bilo potrebno nekoliko sati, pa čak i nekoliko dana da ih se potraži i organizira. Još jedna prednost poslovne inteligencije je ta što pomoću nadzornih ploča i podataka u stvarnom vremenu korisnici mogu lako organizirati važne informacije i primati trenutna ažuriranja. To doprinosi velikom uštedom vremena te omogućava da se problem odmah riješi. Samim time kada se pravilno implementiraju, alati poslovne inteligencije mogu značajno poboljšati učinke poslovanja određene organizacije.

Prodajna inteligencija

Jedna od bitnijih prednosti poslovne inteligencije je povećavanje svijesti. Kompanije ne mogu iskoristiti mogućnosti za koje nisu niti svjesni, stoga alati poslovne inteligencije omogućavaju da prolazne prilike učine vidljivim i primjetnim te da im pruže detalje kako bi maksimalno iskoristili svoje poslovanje. Izvješća i podaci koje proizvode alati poslovne inteligencije korisni su kada trebaju sigurnosne kopije podataka prilikom pregovaranja s potencijalnim klijentima. Također mogu biti korisne za donošenje brzih odluka u prodaji pomoću podataka u stvarnom vremenu te izvještaja poslovne inteligencije. Alati poslovne inteligencije mogli bi se pokazati najmoćnijim alatom kojim se pokušavaju uvjeriti klijenti, dobavljači u potencijale i mogućnosti koje nude proizvodi i usluge poduzeća. U prodaji također pomažu prepoznati trendove u preferencijama kupaca, pa će korisnici odmah znati što će ponuditi kupcima kako bi maksimizirali prodaju.

Pojednostavljenje operacija i njihova obrada

Sve što ne daje vrijednosti poduzeću može se smatrati nepotrebnim tako alati poslovne inteligencije imaju sposobnost pronalaska istoga, što uključuje operativne i administrativne poslove koji se mogu automatizirati sa sustavima poslovne inteligencije. Poslovna inteligencija obavlja posao kojim bi zaposlenici unosa podataka ili analitičari istih obično bili opterećeni poput organizacije podataka i sličnih ponavljajućih zadataka. Ova prednost poslovne inteligencije omogućuje da se zaposlenici mogu posvetiti intenzivnijim zadacima, povećavajući produktivnost. Također može uštedjeti vrijeme, novac i smanjiti ljudske pogreške. Također omogućava korisnicima da prepoznaju uspješnost organizacije i njezinih zaposlenika te na temelju toga donositi određene odluke. Poslovna inteligencija može prepoznati i nepotrebne operacije u ukupnom poslovanju. To se čini preciziranjem neučinkovitosti u proizvodnji,

poslovanju te prodaji. Uz pomoć prediktivne analize, poslovna inteligencija može ponuditi prijedloge za ublažavanje spomenutih problematičnih područja.

Uklanjanje nagađanja

Bez alata poslovne inteligencije, poduzeća su u osnovi prisiljene kockati se pri donošenju mnogih važnih odluka što se tiče upravljanja, financija, marketinga i sl. S alatima poslovne inteligencije, odluke koje donose čelnici poduzeća temelje se na podacima i često rezultiraju konkurentskom prednošću nad ostalim organizacijama. Poslovna inteligencija implementira strukturu podataka kako bi se potaknulo donošenje odluka utemeljenih na podacima, a ne da se poslovanje oslanja na nagađanja. Spomenuti poslovnim resurs, ne samo da će dovesti do veće profitabilnosti, već će i otkloniti veliki dio stresa i nesigurnosti u vođenju poslovanja.

Poboljšanje upravljanja zalihama

Prednosti alata poslovne inteligencije mogu se proširiti na nabavu te na upravljanje zalihama. Korisnici mogu generirati izvještaje s detaljnim potrebama skladišta kako bi se odredilo kada treba nabaviti određene sirovine, materijala ili proizvoda. Također, poslovnom inteligencijom prati se popis zaliha kako bi se poduzeća bolje pripremila za buduću prodaju te tako smanjila stvaranje viška. [6]

3.2. Tableau Software

Tableau Software je moćan i jedan od najbrže rastućih alata za vizualizaciju podataka koji se koristi u industriji poslovne inteligencije. Pomaže u pojednostavljivanju neobrađenih podataka u vrlo lako razumljiv format. S Tableau-om, analiza podataka je vrlo brza, a kreirane vizualizacije su u obliku nadzornih ploča ili radnih listova. Također podaci koji su stvoreni implementirani pomoću Tableau-a mogu razumjeti korisnici na bilo kojoj razini organizacije.

Slika 4. Logo alata Tableau Software-a [6]

Tableau su 2003. godine osnovali Pat Hanrahan, Christian Chabot te Chris Stolte koji su već nakon godinu dana svoje sjedište preselili u četvrt Fremont u Seattle-u, državi Washington. Kroz godine postojanja i poslovanja, tvrtka je proširivala svoje sjedište u Fremont-

u, dok su 2016. godine objavili planove za pomoćni kampus u predgrađu Kirkland-a, također u državi Washington koji je u konačnici i otvoren 2017. godine.

Najbolje osobine Tableau-a su kombiniranje podataka iz različitih izvora (eng. Data blending), analiza u stvarnom vremenu (eng. Real time analysis) te kolaboracija podataka (eng. Collaboration of Data). Za rad u alatu nije potrebna tehnička niti bilo kakva programska vještina. Upravo zbog toga, alat je pobudio zanimanje ljudi iz svih sektora poslovanja, kao što su ekonomija, istraživačka industrija itd.

Radi jasnijeg razumijevanja, analitika podataka u Tableau Software-u može se podijeliti u dvije kategorije (Slika 5.):

1) Alati za razvojne programere → u ovu kategoriju ubrajaju se Tableau alati koji se koriste za razvoj nadzornih ploča, grafikona, stvaranja izvještaja i vizualizacija. Tableau proizvodi u ovoj kategoriji su Tableau Desktop i Tableau Public.
2) Alati za dijeljenje → kao što i samo ime sugerira, svrha alata je dijeljenje vizualizacija, izvještaja, nadzornih ploča koje su stvorene pomoću alata za razvojne programere. Proizvodi koji se ubrajaju u ovu kategoriju su Tableau Online, Tableau Server te Tableau Reader.

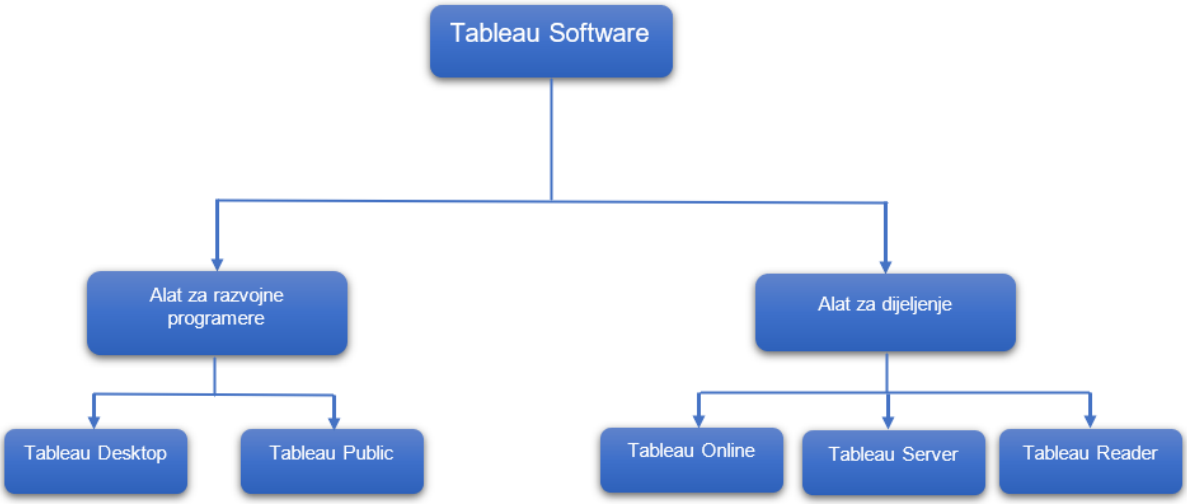

Slika 5. Struktura Tableau Software-a

3.2.1. Tableau Desktop

Tableau Desktop ima bogat skup značajki koji omogućavaju izradu prilagođenih vizualizacija te izvješća. U njemu se mogu pronaći funkcionalnosti poput stvaranja grafikona, izvješća, pa sve do njihovog objedinjavanja kako bi se stvorila nadzorna ploča. Za analizu podataka u realnom vremenu, Tableau Desktop pruža mogućnost povezivanja sa skladištem

podataka kao i različitim vrstama datoteka. Nadzorne ploče te izvještaji stvoreni u Tableau Desktop imaju mogućnost dijeljenja na lokalnoj razini ili javno. Na temelju povezanosti s izvorima podataka te mogućnosti objavljivanja, Tableau Desktop je klasificiran u dvije kategorije:

- Osobni Tableau Desktop (eng. Tableau Desktop Personal) → Pristup je ograničen, dok se radni list čuva privatnim te se ne mogu objavljivati na mreži. Stoga jedini način da se objavi je taj da se distribuira izvanmrežno ili u Tableau Public-u.
- Profesionalni Tableau Desktop (eng. Tableau Desktop Professional) → Radni list se može objavljivati na mreži ili u Tableau Server-u. Također u Professional verziji postoji potpuni pristup svim vrstama podataka.

3.2.2. Tableau Public

Tableau Public je inačica koja je posebno izrađena za korisnike koji imaju želju prikazati svoju isplativost te efikasnost poslovanja ili privatnih projekata. Pošto je verzija „Public“, odnosno javna, znači da su radni listovi, odnosno projekti stvoreni tako da se ne mogu spremiti lokalno, nego se spremaju u javni oblak (eng. Cloud) Tableau-a gdje ih razni korisnici mogu pregledati. Također nema datoteka s privatnošću jer im svatko može pristupiti i preuzeti ih s oblaka. Ova je verzija najbolja za pojedince koji žele učiti Tableau te za one koji žele podijeliti svoje podatke za širom javnošću.

3.2.3. Tableau Online

Kao što ime sugerira, to je alat za online dijeljenje radova, odnosno projekata izrađenih u Tableau. Njegove su funkcionalnosti slične Tableau Server-u, no podaci se pohranjuju na poslužitelje u oblaku koje održava Tableau grupa. Najbitnija značajka Tableau Online-a je ta da ne postoje ograničenja pohrane podataka koji se mogu objaviti. Također izravno je povezan s preko 40 izvora podataka na oblacima kao što su MySQL, Hive, Amazon Aurora, Spark SQL i mnogi drugi.

3.2.4. Tableau Server

Softver se posebno koristi za dijeljenje projekata, vizualizacija koje se stvaraju u aplikaciji Tableau Desktop u cijeloj organizaciji. Kako bi se projekti zajednički koristili na Tableau Server-u, potrebno je prvo objaviti projekt na Tableau Desktop. Nakon što se projekt učita na poslužitelj bit će dostupan licenciranim korisnicima koji imaju prava na određeni projekt. Tableau Server ne treba nužno biti instaliran, on služi kako bi zahtijevao vjerodajnice

za prijavu s kojima se mogu provjeriti izvješća putem web preglednika. Sigurno Tableau Server-a je vrlo visoka te je pogodna za brzu i učinkovitu razmjenu podataka u organizaciji.[6]

3.2.5. Tableau Reader

Tableau Reader je besplatni alat koji omogućuje pregled projekata i vizualizacija nastalih korištenjem Tableau Desktop ili Tableau Public. Podaci se mogu filtrirati, ali uređivanje i modifikacije su ograničene dok je razina sigurnosti jednaka kao na ostalim platformama jer ovisno o dozvolama, postoji mogućnost da projekt vide samo ograničeni broj ljudi ako je privatne prirode, ili svi ako je podijeljen javno.

Tablica 1. Načini i troškovi korištenja Tableau Software-a [6]

Korištenje	
Licence/pretplate	Temeljem broja korisnika. Pretplatom korisnicima se omogućuju pristup Tableau tijekom postavljenog vremenskog razdoblja.
Održavanje	Dolazi do dodatnih troškova ukoliko se želi omogućiti stalna podrška te održavanje sustava.
Instalacija/implementacija	Na zahtjev Oblak/SaaS: Uključeno u mjesečnu pretplatu Prilagođenu verziju nije moguće zatražiti - korisnici mogu sami napraviti ograničene prilagodbe kao što su: → korisnik može promijeniti ime poslužitelja koje se pojavljuje na kartici preglednika, savjetima te porukama → korisnik može promijeniti logotipe koji se pojavljuju u različitim kontekstima na poslužitelju → korisnik može kontrolirati jezik koji se koristi za korisničko sučelje poslužitelja i jezik koji se koristi za prikaze
Troškovi migracije podataka/Upravljanje promjenama	Migracija podataka moguća je na poslužiteljima Tableau-a, a može se obaviti pomoću sljedećih alata - Tabcmd Script, REST API, TabMigrate, Enterprise Deployment Tool (InterWorks)
Obuka	Postoje dvije vrste obuke - putem seminara ili virtualna (Obuka putem seminara traje 2 dana, dok virtualna nastava traje 4 dana) Obuka košta 1400$ po osobi za svaku vrstu obuke
Obnavljanje	Troškovi obnove jednak je naknadi koja se plaća na godišnjoj razini, na temelju broja korisnika

Tablica 2. Pojedinosti o cijenama korištenja Tableau Software-a [6]

Pojedinosti o cijenama		
Kategorija	**Opis**	**Cijena/Detalji**
Tableau poslužitelj	→ Lokalni ili javni oblak koji se koriste uz pomoć Amazon Web Servisom, Microsoft Azure i Google Cloud Platform → Centralno upravljanje izvorima podataka i projektima → Istraživanje analitika s bilo kojeg preglednika ili mobilnog uređaja	35$ mjesečno po korisniku
Tableau Online	→ SaaS oblik Tableau koji se u potpunosti održavaju, nadograđuju te pružaju sigurnost → Centralno upravljanje izvorima podataka i projektima → Istraživanje analitika s bilo kojeg preglednika ili mobilnog uređaja	42$ mjesečno po korisniku
Opcije implementacije	Koje su opcije dostupne za implementaciju proizvoda?	Temeljeno na oblaku, odnosno SaaS
Modeliranje cijena	Kakav je model naplaćivanja?	Temeljeno na pretplatama
Minimalne obveze korištenja	Je li potrebna minimalna mjesečna ili godišnja obveza za kupnju?	Potrebna je minimalna obveza od jedne godine korištenja
Prilagođene funkcionalnosti	Postoji li opcija za kreiranje prilagođenih funkcionalnosti?	Nije dostupno
Besplatna probna verzija	Pruža li dobavljač besplatnu probnu verziju?	Da

3.3. Microsoft Power BI

Microsoft Power BI je alat za poslovnu inteligenciju i vizualizaciju podataka koji pomaže pretvoriti podatke iz različitih izvora podataka u interaktivne nadzorne ploče i u izvješća poslovne inteligencije. Isto kao i Tableau Software, Power BI pruža više programskih verzija te usluga.

Slika 6. Logo alata Microsoft Power BI-a [7]

Power BI konceptualiziran je od strane Ruler-a i Dhers Netz-a koji su u tom trenutku u Microsoftu bili u timu koju su pružali usluge podrške za SQL poslužitelje, dok je samo sučelje dizajnirao West Chadic George 2010. godine. Isporučen je 2011. godine sa SQL poslužiteljem pod kodnim imenom Mount McKinley. Microsoft je predstavio prvi pregled Power BI-a u rujnu 2014, dok je prva verzija Power BI-a objavljena je 24. srpnja 2015. te se temeljila na programskim dodacima temeljenim na programu Excel, poput Power Query, Pivot, View i Map.

Power BI se može raščlaniti na nekoliko alata kao što je „Power Query“ koji se koristi za ekstrahiranje i transformiranje podataka. Također tu je i „Power Pivot“ koji se uglavnom koristi za modeliranje i analizu podataka, dok se alat „Power View“ i „Power Map“ koriste za vizualizaciju podataka. Time pruža interaktivne vizualizacije te ostale karakteristike poslovne inteligencije, što omogućava korisnicima da sami izrađuju izvještaje i nadzorne ploče bez podrške administratora baza podataka i sistem administratora. Microsoft pruža uslugu poslovne inteligencije temeljenu na oblaku (eng. Cloud) koja je poznata kao „Power BI Services“, a također pruža sučelje koje se koristi lokalno na računalu, poznato kao „Power BI Desktop“. Nudi mogućnost skladištenja podataka kao što su priprema podataka, organiziranje podataka te kreiranje interaktivnih nadzornih ploča. Također tu je i mogućnost učitavanja prilagođenih vizualizacija zbog kojih je vrlo popularan alat.

Power BI Desktop je besplatna aplikacija koja se instalira na lokalno računalo te omogućava povezivanje, transformiranje i vizualizaciju podataka. Pomoću njega se također mogu spojiti podaci iz različitih izvora te ih kombinirati, odnosno modelirati u podatkovni model. Navedeni model omogućuje da se izgrade vizualni prikazi podataka koji se mogu podijeliti i služiti kao izvještaji drugim korisnicima unutar organizacije. [7]

Tablica 3. Načini i troškovi korištenja Microsoft Power BI [7]

Korištenje	
Licence/pretplate	Temeljem broja korisnika za Power BI Pro. Temeljem kapaciteta za Power BI Premium.
Održavanje	Uključeno u cijenu pretplate.
Instalacija/implementacija	Uključeno u cijenu pretplate. Moguće su dodatne naknade za migraciju podataka tijekom implementacije, održavanja lokalnih izvora podataka te za izradu nadzornih ploča i izvještaja.
Troškovi migracije podataka/Upravljanje promjenama	Ovisi o trenutnom softveru kojeg organizacija koristi, količini podataka koju treba migrirati, dostupnosti alata za migraciju, složenosti podataka između postojećeg i novog sustava.
Troškovi obuke	Ovisno o vrsti obuke koju je odabrala organizacija, bilo da je riječ o treningu krajnjih korisnika ili obuci grupe ili samoobuci ili osposobljavanja odgovorne osobe. Samostalno učenje dostupno je besplatno, dok se „online“ seminari mogu naplatiti između $175 i 300$ za jedan Power BI tečaj
Obnavljanje	Troškovi obnove jednaki su naknadama koje se plaćaju za mjesečnu ili godišnju pretplatu.

Tablica 4. Pojedinosti o cijenama korištenja Microsoft Power BI [7]

Pojedinosti o cijenama		
Kategorija	**Opis**	**Cijena/Detalji**
Power BI Desktop	→ Povezivanje sa stotinama različitih izvora podataka → Čišćenje i pripremanje podataka pomoću vizualnih alata → Analiziranje i izrada izvješća s prilagođenim vizualizacijama → Objavljivanje projekata putem Power BI service	Besplatno
Power BI Pro	→ Izrada nadzornih ploča koje pružaju podršku u poslovanju u realnom vremenu → Automatsko ažuriranje podataka, uključujući lokalne resurse → Međusobna suradnja sa zajedničkim podacima → Revizija i upravljanje načinom na koji se pristupa podacima i kako ih se koristi → Distribuiranje sadržaja korisnicima putem aplikacija	$9.99 mjesečno po korisniku

Pojedinosti o cijenama		
Kategorija	**Opis**	**Cijena/Detalji**
Power BI Premium	→ Namjenski kapacitet koji se dodjeljuje i kontrolira → Distribuiranje i ugrađivanje sadržaja bez kupnji licenci za korisnike → Objavljivanje izvješća pomoću Power BI Report poslužitelja → Mogućnost otključavanja i dodjeljivanja većeg kapaciteta i većih ograničenja za napredne korisnike	→ $4995 po čvoru mjesečno → Otprilike $24975 mjesečno za 5000 korisnika s 3 čvora
Opcije implementacije	Koje su opcije dostupne za implementaciju proizvoda?	Opcije implementacije temeljene su na oblaku (SaaS)
Modeliranje cijena	Kakav je model naplaćivanja?	Na temelju pretplata i korištenja kapaciteta.
Minimalne obveze korištenja	Je li potrebna minimalna mjesečna ili godišnja obveza za kupnju?	Minimalna godišnja obveza korištenja je potrebna za kupnju
Prilagođene funkcionalnosti	Postoji li opcija za kreiranje prilagođenih funkcionalnosti?	Dostupno
Besplatna probna verzija	Pruža li dobavljač besplatnu probnu verziju?	Da

3.4. Qlik

Qlik se u današnje vrijeme smatra alatom koji ubrzano raste kao jedan od alata poslovne inteligencija za vizualizaciju podataka koji omogućava najbrže procesuiranje podataka. Najveća prednost alata je ta da se projekt može vrlo brzo implementirati te isto tako lako koristiti i na temelju vizualizacije napraviti korektan izvještaj. Također, poznat je po snažnom otkrivanju podataka te po interaktivno vođenoj analizi. Prema ovim parametrima, Qlik je vodeći alat na tržištu.

Slika 7. Logo alata Qlik [8]

Qlik su u Švedskoj 1993. godine osnovali Staffan Gestreliu te Bjorn Berg dok sama softverska tvrtka ima sjedište u Radnor-u, Pennsylvania. U ranijim verzijama se zvao Quik, kao engleska skraćenica za „Kvaliteta, razumijevanje, interakcija, znanje“ (eng. Quality, Understending, Interaction, Knowledge).

Na trenutačno visoko konkurentnom tržištu, Qlik je u skladu sa zahtjevima upravljanja i skalabilnosti većine poduzeća razvio vrlo naprednu arhitekturu poslovne klase. Kako bi se osigurala kvaliteta interaktivnog otkrivanja podataka, Qlik osigurava visoko skalabilno, sigurno te upravljivo sučelje. Također, bilo da se podaci nalaze lokalno u datotekama, na oblaku ili u „Big Data“ izvorima, njima se može pristupiti, kombinirati ih te učitati s određenog mjesta.

3.4.1. QlikView

QlikView je alat poslovne inteligencije koji se koristi za pretvaranje neobrađenih podataka u znanje. Kao što je već spomenuto, alat se temelji na interaktivnom otkrivanju podataka te uz to nudi „ad hoc“ upite te tako omogućava brzo donošenje odluka na temelju lako dostupnih informacija.

Alat je vrlo jednostavan te intuitivno koristi platformu koja nudi vizualizaciju podataka na smislen i inovativan način. Također vrijeme odgovora je trenutačno, bez ograničenja u količini podataka uz mogućnost izravnog i neizravnog pretraživanja podataka iz različitih izvora. QlikView pruža podršku za dinamičke aplikacije, nadzorne ploče te analize koje pomažu u prepoznavanju trendova i informacija za donošenje najinovativnijih odluka. Takve odluke u konačnici omogućavaju brži razvoj te upravljanje promjenama.

3.4.2. Qlik Sense

Qlik Sense je kompletna verzija platforme za analizu podataka koja postavlja referentnu vrijednost za novu generaciju analitike. Pomoću jedinstvenog mehanizma za asocijativnu analitiku, sofisticirane umjetne inteligencije te platforme oblaka visokih performansi koje mogu svakodnevno osnažiti sve u organizaciji za donošenje boljih odluka, stvarajući poduzeće koje se temelji na podacima.

Alat se služi indeksiranjem i razumije svaki odnos između podataka kako bi se istraživanje moglo provoditi u bilo kojem smjeru, što otkriva uvide koji se ne mogu vidjeti s alatima poslovne inteligencije koji se temelje na SQL upitima. Kombiniranje i učitavanjem podataka, stvaraju se vizualizacije uz povlačenje i ispuštanje (eng. Drag and Drop) radi stvaranja analitičkih aplikacija ubrzanih sugestijama i automatizacijom od strane umjetne inteligencije. Umjetna inteligencija se temelji na pojačavanju ljudske intuicije kroz Qlik Sense pomoću predloženih uvida i automatiziranih procesa. Alat također podržava razvijanje analitika

s velikim brojem otvorenih API-ja te omogućava da ih se uvede u bilo koju aplikaciju ili projekt s ugrađenom podrškom za analitiku. [8]

Tablica 5. Načini i troškovi korištenja alata Qlik [8]

Korištenje	
Licence/pretplate	Temeljem kombinacije licenciranja poslužitelja, korisnika, dokumenata te aplikacija.
Održavanje	Za rješenja na zahtjev, troškovi održavanja se dodatno naplaćuju. Standardne usluge podrške naplaćuju se 20% od troška licence. Premium usluge podrške (24/7) naplaćuju se 23% od troška licence.
Instalacija/implementacija	Usluge implementacije pruža Qlik Consulting ili partner za implementaciju uz dodatni trošak.
Troškovi migracije podataka/Upravljanje promjenama	Variraju ovisno o funkcionalnim zahtjevima ili odabranim uslugama. Ovisi o trenutnom softveru kojeg organizacija koristi, količini podataka koju treba migrirati, dostupnosti alata za migraciju, složenosti podataka između postojećeg i novog sustava.
Troškovi obuke	eUčenje i samostalno učenje besplatni su moduli Svi ostali seminari naplaćuju se na temelju broja korisnika. Seminari uživo ili virtualna učionica naplaćuje se u iznosu od $700 po osobi dnevno ili $3500 za određeni tečaj do 10 osoba.
Obnavljanje	Troškovi obnove uključuju licencu za ažuriranje softvera te troškove podrške.

Tablica 6. Pojedinosti o cijenama korištenja alata Qlik [8]

Pojedinosti o cijenama		
ategorija	**Opis**	**Cijena/Detalji**
QlikView Client	→ osobna upotreba → korisnička licenca → dokumentna licenca → sveobuhvatna licenca	→ osobna upotreba: besplatno → korisnička licenca: $1350 po korisniku → dokumentna licenca: $350 po dokumentu → sveobuhvatna licenca: $15000 po korisniku
QlikView Server	→ licenca poslužitelja poduzeća → licenca poslužitelja za mala poduzeća (do 25 korisnika) → Test poslužitelji → QlikView Publisher → Usluga distribucije PDF izvještaja → Priključak na SAP NetWeaver® → Priključak na Salesforce.com → Priključak na Informatica	→ licenca poslužitelja poduzeća: $35000 po poslužitelju → licenca poslužitelja za mala poduzeća (do 25 korisnika): $8400 po poslužitelju → Test poslužitelji: 50% cijena licence poslužitelja → QlikView Publisher: $21000 po poslužitelju → Usluga distribucije PDF izvještaja: $21000 po poslužitelju → Priključak na SAP NetWeaver®: $22500 po poslužitelju → Priključak na Salesforce.com: Besplatno → Priključak na Informatica: Besplatno
QlikView Extranet i ostali proizvodi	→ Extranet polsužitelj → Sveobuhvatna licenca za Extranet poslužitelj → Ostali proizvodi → Poslužitelj za pristup informacijama → QlikView Workbench → Web dodaci za MS SharePoint	→ Extranet polsužitelj: $18000 po poslužitelju → Sveobuhvatna licenca za Extranet poslužitelj: $3000 po poslužitelju → Poslužitelj za pristup informacijama: $70000 → QlikView Workbench: $4200 po poslužitelju → Web dodaci za MS SharePoint: $4200 po poslužitelju
Opcije implementacije	Koje su opcije dostupne za implementaciju proizvoda?	Na zahtjev
Modeliranje cijena	Kakav je model naplaćivanja?	Licenciranje
Minimalne obveze korištenja	Je li potrebna minimalna mjesečna ili godišnja obveza za kupnju?	Za rješenja koja se temelje na licenci obično je minimalna obveza od 1 do 3 godine
Prilagođene funkcionalnosti	Postoji li opcija za kreiranje prilagođenih funkcionalnosti?	Dostupno
Besplatna probna verzija	Pruža li dobavljač besplatnu probnu verziju?	Da

4. Baza podataka

Baza podataka je zbirka podataka koja je organizirana tako da joj se može lako pristupiti, upravljati njome te također provoditi ažuriranje nad istom. Računalne baze podataka obično sadrže agregirane podatke ili datoteke koje mogu sadržavati informacije poput prodajnih transakcija, interakcija s određenim kupcima i slično. Bazom podataka obično upravlja sustav za upravljanje bazom podataka (eng. Database management system, DBMS) koji zajedno s podacima i aplikacijama koji su povezane sa sustavom, čine cjelinu koju često nazivamo sustavom baza podataka, odnosno skraćeno samo baza podataka. [11]

Slika 8. Ilustracija baze podataka [13]

Podaci unutar baza podataka se obično modeliraju kroz retke i stupce u nizu tablica (Slika 8.) kako bi obrada i upiti nad podacima bili učinkoviti. Na takav način, omogućeno je lakše pristupiti podacima, upravljati njima, mijenjati ih, ažurirati, kontrolirati te organizirati. Većina baza podataka koristi strukturirani jezik upita (eng. Structured Query Language, SQL)[12].

Kroz evoluciju baze podataka, koja je započela u ranim šezdesetim godinama prošlog stoljeća, su doživjele drastičan razvoj. Navigacijske baze podataka kao što su hijerarhijska baza podataka (koja se oslanja na model poput stabla te je dopuštala samo odnos jedan prema više) i mrežna baza podataka (fleksibilniji model koji je omogućio višestruke odnose) izvorni su sustavi koji se koriste za pohranu i manipuliranjem podacima. Iako jednostavni, navedeni sustavi nisu bili dovoljno fleksibilni. U osamdesetim godina, relacijske baze postale su vrlo popularne, a zatim su se sredinom devedesetih godina pojavile objektno-orijentirane baze podataka. U novije vrijeme, NoSQL baze podataka nastale su kao odgovor na porast korištenja interneta kao izvora podataka i potrebe za bržom brzinom te obradom nestrukturiranih podataka. Danas baze podataka temeljene na oblaku i samostalne baze podataka otvaraju

novo područje kada je riječ o načinu prikupljanja, pohrane, upravljanja i korištenja podataka. [14]

4.1. Tipovi baza podataka

Postoji mnogo različitih vrsta baza podataka. Najbolja baza podataka za određenu organizaciju ovisi o tome kako organizacija namjerava koristiti podatke. U idućih nekoliko odlomaka ukratko su objašnjene vrste baza podataka.

4.1.1. Relacijske baze podataka

Relacijske baze podataka postale su dominantne u osamdesetim godinama prošlog stoljeća. Zapisi u relacijskim bazama podataka organizirani su kao skup tablica sa stupcima i redcima. Stupci tablice sadrže atribute podataka, a svaki zapis obično ima vrijednost za svaki atribut, što olakšava uspostavljanje odnosa između podatkovnih točaka. Tehnologija relacijskih baza podataka pruža najučinkovitiji i fleksibilni način pristupa strukturiranim informacijama. Relacijski model je sastavljen od logičke strukture podataka – tablica podataka (eng. Data Tables), pogleda (eng. View) i indeksa (eng. Indexes), koje su odvojene od fizičkih struktura za pohranu. Takvo razdvajanje znači da administratori baza podataka mogu upravljati fizičkom pohranom podataka bez utjecaja na pristup tim podacima kao logičkoj strukturi. Odnosno na primjer, preimenovanjem datoteke baze podataka, ne preimenuju se tablice pohranjene u njoj. Razlika između logičkog i fizičkog odnosi se također i na operacije baza podataka koje su jasno definirane radnje koje aplikacijama omogućuju manipulaciju podacima i strukturama baze podataka. Logičke operacije dopuštaju aplikaciji da navede sadržaj koji joj treba, dok fizičke operacije određuju kako tim podacima treba pristupiti, a zatim tek izvršava zadatak. [15]

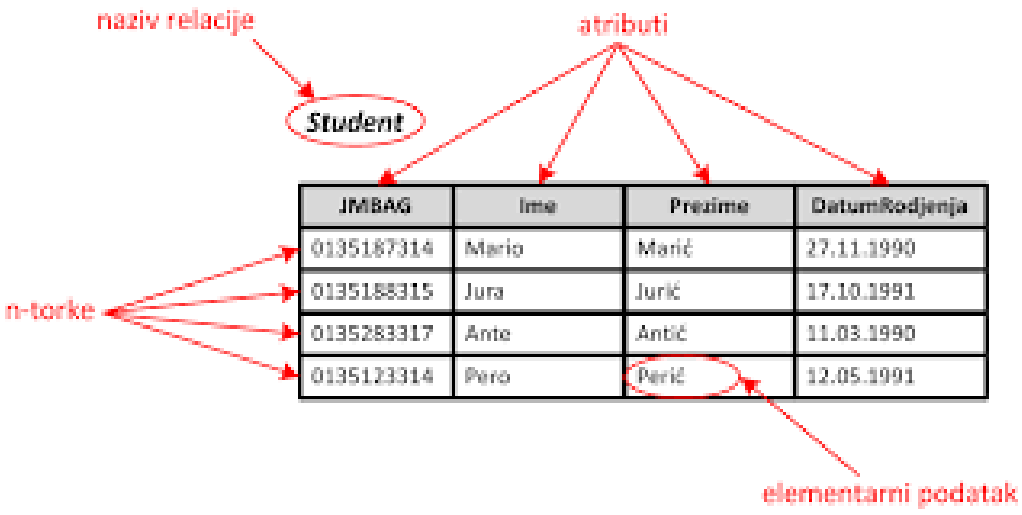

Slika 9. Primjer relacijske baze podataka [16]

4.1.2. Objektno orijentirane baze podataka

Informacije u objektno orijentiranoj bazi podataka predstavljaju se u obliku objekata koji se pohranjuju u memoriju, isto kao u objektno orijentiranom programiranju (eng. Object-oriented programming, OOP). Objekti imaju članove kao što su polja, svojstva i metode. Također imaju životni ciklus koji uključuje stvaranje objekta, upotrebu te brisanje istoga. Objektno orijentirane baze podataka često se koriste u aplikacijama koje zahtijevaju visoke performanse, izračune te brze rezultate. Neke od takvih aplikacija su sustavi u realnom vremenu, arhitektura i inženjering za 3D modeliranje, telekomunikacije te molekularna znanost i astronomija. [17]

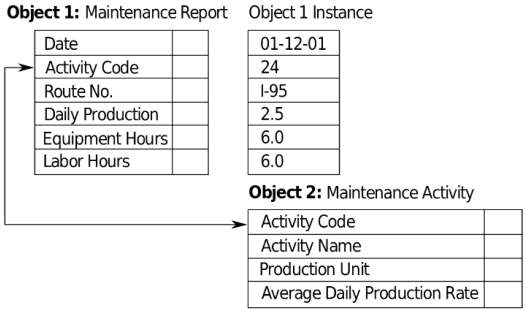

Slika 10. Primjer objektne baze podataka [17]

4.1.3. Distribuirane baze podataka

Distribuirana baza podataka sastoji se od dvije ili više datoteka smještenih na različitim web mjestima. Baza podataka može biti pohranjena na više računala, smještenih na istom fizičkom mjestu ili raštrkanih po različitim mrežama. Centralizirani sustavi upravljanja distribuiranim bazama podataka (eng. Distributed database management system, DDBMS) integrira podatke logički tako da se njima može upravljati kao da su svi pohranjeni na istom mjestu.

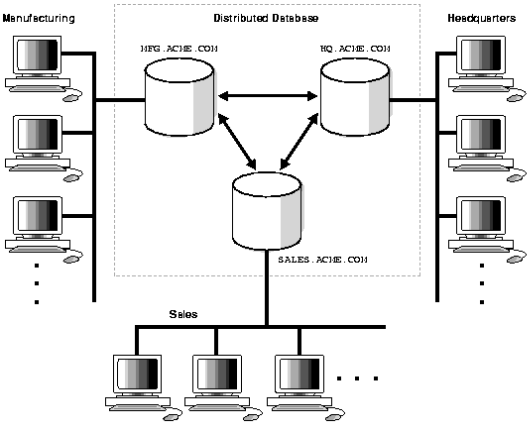

Slika 11. Primjer distribuirane baze podataka [18]

Također sustavi za upravljanje distribuiranim bazama podataka povremeno sinkroniziraju sve podatke te osiguravaju da će se ažuriranja i brisanja podataka na jednom mjestu automatski odraziti na podacima pohranjenim negdje drugdje. [18]

4.1.4. Skladišta podataka

Središnje spremište podataka, skladište podataka je vrsta baze podataka koja je posebno dizajnirana za brze upite te provođenje analize nad podacima. Također pruža postupak za prikupljanje i upravljanje podacima iz različitih izvora radi pružanja značajnih uvida u poslovanje te podrške u donošenju važnih odluka. Može se reći kako je skladište podataka spoj tehnologija i komponenata koji pomažu u strateškoj upotrebi podataka. To je elektroničko pohranjivanje velike količine podataka od strane tvrtke koja je dizajnirana za upite i analizu, odnosno proces pretvaranja podataka u informacije te pružanje istih korisnicima na raspolaganje kako bi se napravila razlika nad konkurencijom. Takvo okruženje održava se odvojeno od operativne baze podataka koja se koristi u organizaciji. Skladište podataka je zapravo arhitektonska konstrukcija informacijskog sustava koji korisnicima pruža trenutne i povijesne informacija koji imaju zadaću pružati podršku u donošenju odluka kojima je teško pristupiti ili ih predstaviti u tradicionalnoj operativnoj pohrani podataka. [19]

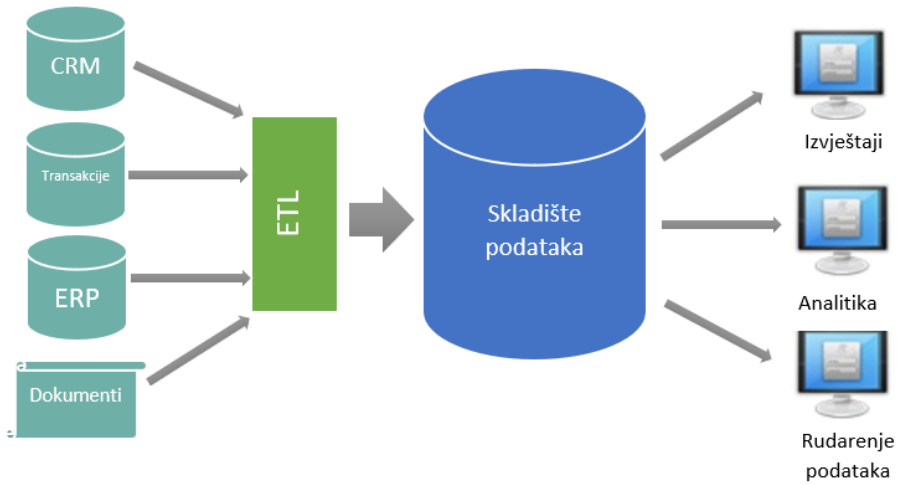

Slika 12. Primjer strukture skladišta podataka [19]

4.1.5. NoSQL baze podataka

NoSQL ili nerelacijske baze podataka omogućuju pohranu i manipulaciju nad nestrukturiranim i polustrukturiranim podacima (za razliku od relacijske baze podataka koje definira kako svi podaci umetnuti u bazu podataka moraju biti sastavljeni) što čini neke operacije bržim. NoSQL baze podataka postale su popularne kako su internetske aplikacije

postale sve više upotrebljive i složenije. NoSQL sustavi se ponekad nazivaju i „ne samo SQL“ (eng. Not only SQL) kako bi se naglasila činjenica kako navedena baza podataka može zadržavati jezike upita sličnih SQL-u. Također ovu vrstu baze podataka karakterizira jednostavnost dizajna te isto tako jednostavniju kontrolu na dostupnošću podataka. Strukture podataka koje koriste NoSQL baze podataka ponekad se također smatraju fleksibilnijima od relacijskih baza podataka. [20]

Slika 13. Struktura NoSQL baze podataka [21]

Ovo je samo nekoliko od više desetaka vrsta baza podataka koje se danas koriste. Ostale, rjeđe korištene baze podataka prilagođene su vrlo specifičnim znanstvenim, financijskim ili drugim funkcijama. Pored različitih tipova baza podataka, promjene u pristupima tehnološkim razvojima te dramatičan napredak oblaka i automatizacije pokreću baze podataka u potpuno novim smjerovima. Neke od najnovijih baza podataka uključuju otvorene baze podataka (eng. Open source database), baze podataka u oblaku (eng. Cloud database), više modelska baza podataka (eng. Multimodel database) te JSON baze podataka (eng. JSON database).

4.2. Sustav za upravljanje bazom podataka (SUBP)

Sustav za upravljanje bazama podataka (eng. Database management system, DBMS) je softverski paket dizajniran za definiranje, manipulaciju, pronalaženje i upravljanje podacima u bazi podataka. SUBP općenito manipulira samim podacima, formatom podataka, imenima polja, strukturom zapisa te strukturom datoteka. Također definira pravila za provjeru valjanosti i manipulaciju tim podacima. Sustavi upravljanja bazom podataka postavljaju se na određenim konceptima rukovanja podacima, odnosno kako se razvija sama praksa administriranja baze podataka. U početku su baze podataka obrađivale samo pojedinačne dijelove posebno

oblikovanih podataka. Današnji, puno razvijeniji sustavi mogu obrađivati različite vrste manje formatiranih podataka te ih povezati na složenije načine.

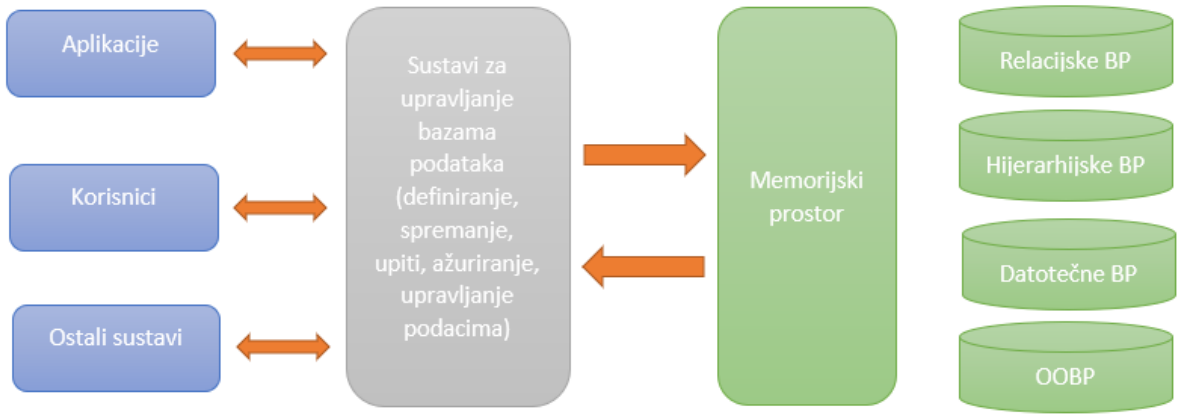

Slika 14. Funkcionalnosti sustava za upravljanje bazom podataka [22]

Kao što je ranije spomenuto, vremenom su se modeli za sustave upravljanja bazama podataka znatno promijenili te se može reći kako je to ključni dio razumijevanja kako rade razne opcije SUBP-a. Najranije verzije SUBP-a sastojali su se uglavnom od hijerarhije i mrežnih modela.

- Hijerarhijski model je model u kojemu svaki čvor ima odnos dijete/roditelj s jednim drugim čvorom.
- U mrežnom modelu razlika je u tom što jedan čvor može imati više odnosa.

Međutim, s vremenom je te modele sustiglo nešto što se naziva relacijskom bazom podataka. U relacijskom modelu baze podataka pojedinačne komponente imaju atribute koji su povezani s njihovim identitetima kroz dizajn tablice baze podataka. Redovi i stupci određene baze podataka uključuju identitete i atribute na takav način da se tradicionalni strukturirani jezik upita (SQL) može koristiti za manipuliranjem različitih vrsta informacija o tim relacijskim modelima. Od tada se pojavio još noviji koncept nazvan NoSQL koji se koristi za opisivanje sustava koji su izvan tradicionalnih modela SQL-a i relacijskih baza podataka.

Također je važno napomenuti da je NoSQL mnogo apstraktniji pojam od „tradicionalne“ relacijske baze podataka. U određenom smislu, NoSQL ne sadrži koncepte relacijskih baza podataka. Jedna od istaknutih vrsta NoSQL sustava je model objektno orijentiranih baza podataka. Umjesto relacijskih tablica, sustavi baza podataka koriste objektne dizajne za rad s gore spomenutim identitetima i atributima. Isto tako, razmatranje dizajna NoSQL baze podataka uključuje stupanj normalizacije ili strukturiranja podataka koji se događa i način na koji sustav baze podataka to rješava. Kod takvih procesa, inženjeri moraju pretraživati alate

za dosljednost i razlučivost podataka u cijelom sustavu, kako bi promovirali ujednačenost te riješili različite probleme korelacije.

Ostale vrste SUBP-a uključuju model baze podataka temeljene na grafovima, te na modelima odnosa entiteta (eng. Entity-Relatioship model, ER model) koji opisuje međusobno povezane tablice u određenoj domeni. Oni nude daljnje alternative tradicionalnom relacijskom dizajnu baze podataka. Također neke od najnovijih vrsta SUBP-a mogu se koristiti tamo gdje podatkovna memorija može imati velike razlike u različito formatiranim ili relativno neformatiranim ili „sirovim“ podacima za rad, gdje se zapisi ne normaliziraju na uobičajeni način. Takve vrste napretka učili su svijet sustava za upravljanje bazom podataka složenijim i povećali vrijednost iskusnim inženjerima baza podataka te administratorima modernih sustava. [23]

Najpoznatiji sustavi za upravljanjem bazama podataka su MySQL, Microsoft Access, Oracle, PostgreSQL, dBASE, FoxPro, SQLite, IBM DB2, LibreOffice Base, MariaDB te Microsoft SQL Server.

5. Projektni zadatak – COVID-19

Projektni zadatak diplomskog rada temelji se na usporedbi triju najkorištenijih alata poslovne inteligencije: Tableau, Power BI i Qlik. Kako je trenutačno stanje u svijetu obilježeno zarazama bolesti korona virusa (COVID-19) tako se i baza podataka korištena u ovom diplomskom radu temelji na istome.

5.1. Baza podataka

Baza podataka sadrži informacije (Tablica 7.) kao što su broj novooboljelih od korona virusa na određeni datum za pojedinu državu, zatim ukupan broj oboljelih na određeni datum, broj smrtnih slučajeva na određeni datum i slične informacije koje će biti detaljnije prikazane u TABLICI. Kao alat za uređivanje same baze podataka korišten je sustav za upravljanje baza podataka Microsoft Access iz skupine uredskih alata.

Tablica 7. Popis podataka korištenih pri izradi projektnih izvještaja

Naziv polja	Vrsta podataka	Opis
ISO kod	Kratki tekst	ISO Alpha-3 kod države
Kontinent	Kratki tekst	Naziv kontinenta na kojemu se nalazi određena država
Lokacija	Kratki tekst	Naziv države
Datum	Datum/vrijeme	Datum određenog slučaja
Ukupan broj slučajeva	Broj	Ukupan broj otkrivenih slučaja COVID-19
Broj novih slučajeva	Broj	Broj novih slučajeva COVID-19 na određeni datum
Broj novih slučajeva (pomični prosjek)	Broj	Pomični prosjek novih slučajeva COVID-19 na određeni datum
Ukupan broj smrtnih slučajeva	Broj	Ukupan broj smrtnih slučajeva nastalih posljedicom COVID-19
Novi broj smrtnih slučajeva	Broj	Broj novih smrtnih slučajeva nastalih posljedicom COVID-19 na određeni datum
Novi broj smrtnih slučajeva (pomični prosjek)	Broj	Pomični prosjek novih smrtnih slučajeva nastalih posljedicom COVID-19 na određeni datum
Ukupan broj slučajeva (na milijun stanovnika)	Broj	Ukupan broj slučajeva zaraze COVID-19 na milijun stanovnika

Naziv polja	Vrsta podataka	Opis
Broj novih slučajeva (na milijun stanovnika)	Broj	Broj novih slučajeva zaraze COVID-19 na određeni datum na milijun stanovnika
Broj novih slučajeva (pomični prosjek na milijun stanovnika)	Broj	Pomični prosjek novih slučajeva zaraze COVID-19 na određeni datum na milijun stanovnika
Ukupan broj smrtnih slučajeva (na milijun stanovnika)	Broj	Ukupan broj smrtnih slučajeva nastalih posljedicom COVID-19 na milijun stanovnika
Novi broj smrtnih slučajeva (na milijun stanovnika)	Broj	Broj novih smrtnih slučajeva nastalih posljedicom COVID-19 na određeni datum na milijun stanovnika
Novi broj smrtnih slučajeva (pomični prosjek na milijun stan)	Broj	Pomični prosjek novih smrtnih slučajeva nastalih posljedicom COVID-19 na određeni datum na milijun stanovnika
Novi broj testiranih osoba	Broj	Broj testiranih osoba na određeni datum
Ukupan broj testiranih osoba	Broj	Ukupan broj testiranih osoba
Ukupan broj testiranih osoba (na tisuću stanovnika)	Broj	Ukupan broj testiranih osoba na tisuću stanovnika
Novi broj testiranih osoba (na tisuću stanovnika)	Broj	Broj testiranih osoba na određeni datum na tisuću stanovnika
Novi broj testiranih osoba (pomični prosjek)	Broj	Pomični prosjek broja testiranih osoba na određeni datum
Novi broj testiranih osoba (pomični prosjek na tisuću stan)	Broj	Pomični prosjek broja testiranih osoba na određeni datum na tisuću stanovnika
Prosjek napravljenih testova i slučajeva	Broj	Prosjek napravljenih testova i novih slučajeva na određeni datum
Stopa pozitivnosti	Broj	Stopa pozitivnosti na COVID-19
Indeks strogosti	Broj	Indeks strogosti je broj koji označava stupanj mjera koje su određene za pojedinu državu
Populacija	Broj	Broj stanovnika u određenoj državi
Gustoća naseljenosti	Broj	Gustoća naseljenosti pojedine države
Starost populacije (medijan)	Broj	Medijan starosti populacije pojedine države
Populacija starija od 65	Broj	Broj stanovnika s navršenih 65 godina
Populacija starija od 70	Broj	Broj stanovnika s navršenih 70 godina

Naziv polja	Vrsta podataka	Opis
BDP po stanovniku	Broj	Bruto domoći proizvod po stanovniku pojedine države
Ekstremno stanovništvo	Broj	Indeks ekstremnog stanovništva za pojedinu državu
Stopa smrtnosti od kardiovaskularnih bolesti	Broj	Stopa smrtnosti od kardiovaskularnih bolesti u pojedinoj državi
Prevalencija dijabetesa	Broj	Postotak broja slučajeva dijabetesa u određenoj zemlji
Ženska populacija ovisnika o cigaretama	Broj	Ukupni broj ženske populacije ovisne o cigaretama
Muška populacija ovisnika o cigaretama	Broj	Ukupni broj muške populacije ovisne o cigaretama
Stopa pranja ruku	Broj	Stopa pranja ruku u pojedinoj državi
Broj bolničkih kreveta na tisuću stanovnika	Broj	Broj bolničkih kreveta za pojedinu državu na tisuću stanovnika
Srednji životni vijek	Broj	Državni prosjek životnog vijeka

U korištenoj bazi podataka nalazi se 39 atributa raznih vrsta podataka u kojemu najveću koncentraciju imaju vrsta podataka brojevi koji će biti idealni za daljnje provođenje analize te izrade izvještaja koji će kasnije omogućiti temeljitu usporedbu triju najkorištenijih alata poslovne inteligencije.

Microsoft Access, kao što je već spomenuto, je Microsoft-ov sustav za upravljanje bazama podataka (SUBP) koji kombinira Microsoft-ov „Jet Database Engine“ s grafičkim korisničkim sučeljem i alatima za razvoj softvera. Također, sustav MS Access podatke pohranjuje u vlastitom formatu, no isto tako omogućava uvoz (eng. Import) i izravno povezivanje s podacima pohranjenim u drugim aplikacijama i bazama podataka.

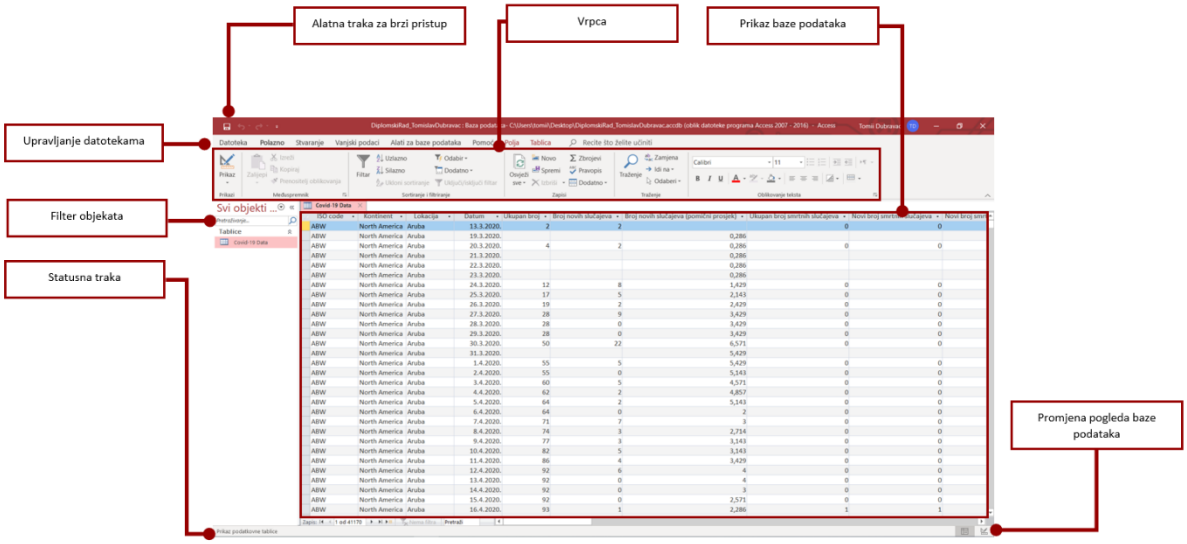

Slika 15. Pogled "Prikaz podatkovne tablice" u Microsoft Access-u

Na slici 15. prikazan je pogled „Prikaz podatkovne tablice“ putem kojega se može vidjeti kako baza podataka izgleda te ako je potrebno iščitati informacije iz nje. Također u trenutačnom pogledu nalaze se i opcije filtriranja objekata, u slučaju da postoji više tablica filtriranje je vrlo korisno te ubrzava proces samog upravljanja bazom podataka. Najvažnija stavka cijeloga MS Access-a su alatne trake i vrpce koje sadrže mnogobrojne akcije za upravljanje i manipuliranje podacima u bazi. Pa tako postoje vrpce za traženje, sortiranje i filtriranje podataka, zapisivanje novih podataka, kreiranje upita, obrazaca te izvješća te također postoji opcija kreiranja makronaredbi u Visual Basic-u. Uz već spomenuti uvoz i izvoz podataka u MS Access, postoje i alati za bazu podataka koji imaju mogućnost sažimanja i popravka baze podataka, stvaranje odnosa i ovisnosti objekata (odnosno tablica), te analiziranje i premještanje baze podataka ukoliko je to potrebno.

Uz pogled „Prikaz podatkovne tablice“, Microsoft Access sadrži i pogled pod nazivom „Prikaz dizajna“. Pogled „Prikaz dizajna“ omogućava uvid u strukturu tablice koja sadrži „Naziv polja“, „Vrstu podataka“ te „Opis“ što je i prikazano na slici 16. U navedenom pogledu, postoje mogućnosti kao i u „Prikazu podatkovne tablice“, no sadrži i alate koji omogućavaju definiranje primarnog ključa te provjere valjanosti definiranih pravila. Također u donjem dijelu pogleda nalaze se svojstva polja u kojemu je moguće definirati veličinu polja, njezin oblik, opis, zadanu vrijednost (ako je potrebno) i slično.

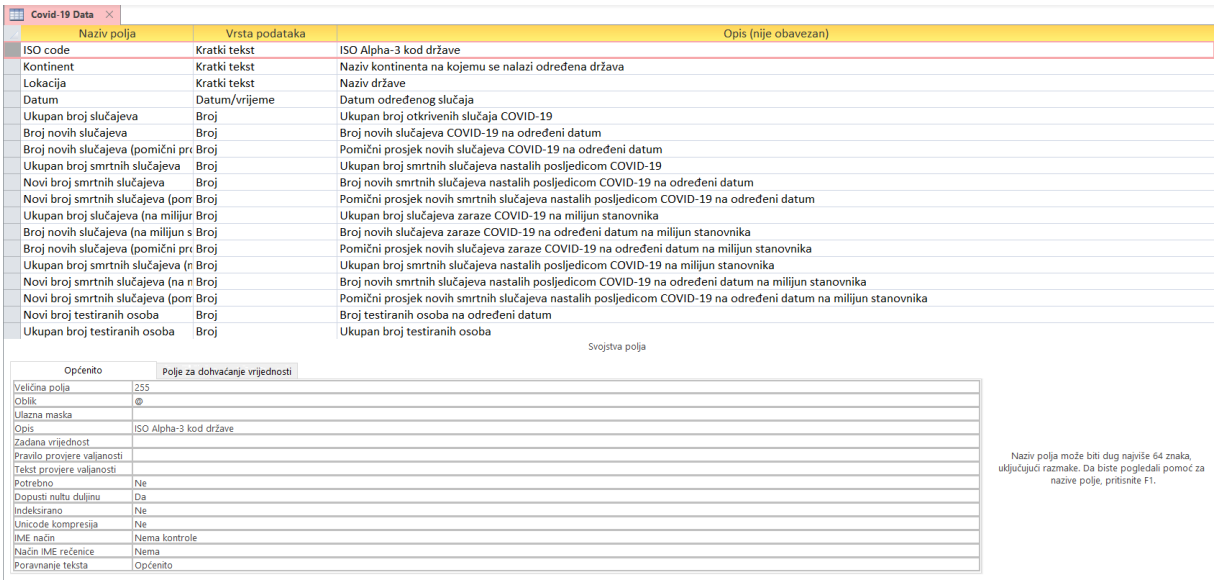

Slika 16. Pogled "Prikaz dizajna" u Microsoft Access-u

U samom MS Access-u, nad preuzetom bazom podataka odrađena je promjena imena polja te promjena pojedinih vrsta podataka iz kratkog teksta u broj te su također dodani opisi za sva polja. U daljnjim koracima, prikazat će se mogućnosti pojedinih alata poslovne inteligencije te će na temelju krajnjih rezultata biti napravljena usporedba istih.

5.2. Analiza podataka – Tableau

Kao što je spomenuto u prijašnjim poglavljima, Tableau omogućuje povezivanje s podacima te predstavljanje istih na jedan drugačiji način kojeg karakterizira mnoštvo dijagrama koje će prikazati određeno poslovanje na jednostavniji i zanimljiviji način. Na slici 17. prikazan je početni prozor alata Tableau Desktop-a koji nudi nekoliko mogućnosti. Prva mogućnost je spajanje na Tableau Server koja omogućava pristup interaktivnim uvidima s bilo kojeg mjesta objavljujući, dijeleći te administrirajući sadržajem. Također Tableau Server omogućava objavljivanje sadržaja, odnosno radnih knjiga, pogleda te nadzornih ploča koji se kreiraju u Tableau Desktop-u. Uz to, Tableau Desktop pruža mogućnost učitavanja podataka s lokalne memorije i to putem Microsoft Excel-a, Microsoft Access-a, JSON, PDF ili txt dokumenta te putem raznih statističkih dokumenata i slično. Isto tako moguće je spajanje na razne poslužitelje kao što su Microsoft SQL Server, MySQL, Oracle, Amazon Redshift itd.

Slika 17. Početni zaslon aplikacije Tableau Desktop

Kao što je spomenuto ranije u ovom poglavlju, za čišćenje, uređivanje i manipuliranjem podacima korišten je Microsoft Access preko kojega su i učitani podaci na Tableau Desktop. Za povezivanje baze s Microsoft Access-a na Tableau potrebna je putanja do .mdb ili .accdb dokumenta kao što je prikazano na slici 18. No postoji mogućnost da datoteka baze ima sigurnost radne grupe (eng. Workgroup security), tada su potrebne vjerodajnice koje se sastoje od naziva datoteka radne grupe, ime korisnika te zaporke. Isto tako, takvo povezivanje zahtjeva određeni upravljački program (eng. Driver) za komunikaciju s bazom podataka. U pravilu takvi upravljački programi su već po zadanom instalirani, no ukoliko to nije slučaj, otvara se dijaloški okvir s porukom u kojoj se nalazi veza na stranicu (eng. Hyperlink) na kojoj se mogu pronaći poveznice na upravljačke programe uz koje se nalaze upute za instalaciju.

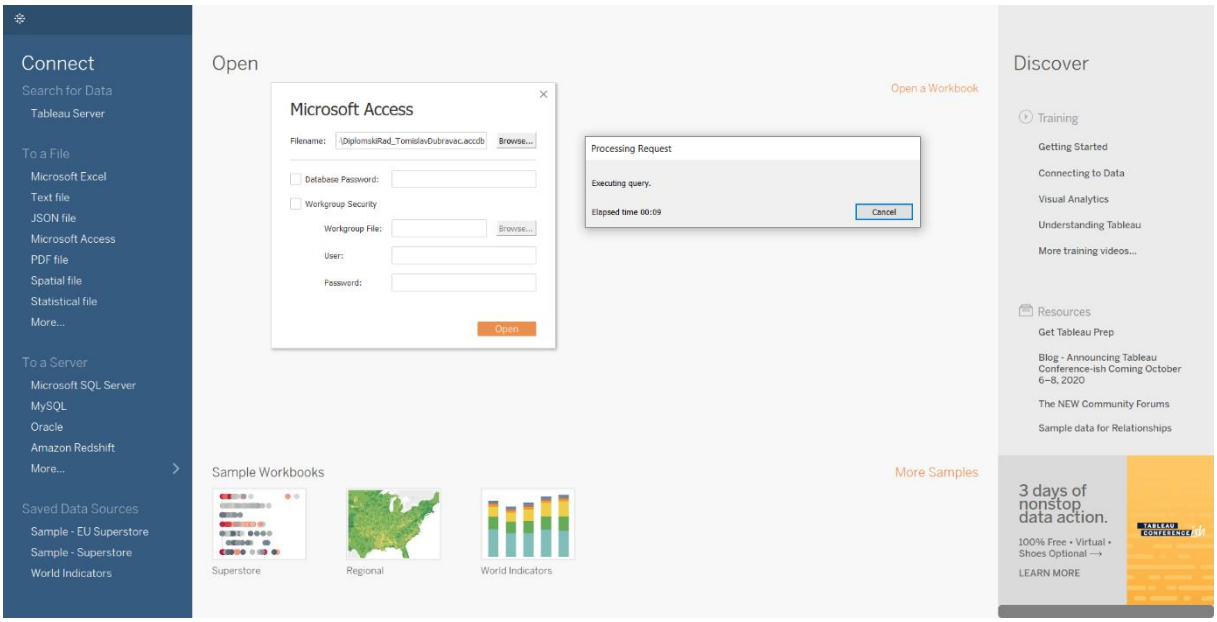

Slika 18. Spajanje izvora podataka na Tableau Desktop

Tableau Desktop pruža korisnicima mogućnost upravljanjem podacima kroz svoj alat prije i za vrijeme izrade izvještaja, pogleda te nadzornih ploča. Pod upravljanje podacima u ovom kontekstu podrazumijeva se promjena formata pojedinog atributa, definiranje mjerljivih i dimenzijskih podataka i slično. Na slici 19. prikazana je baza nakon učitavanja na kojoj su moguće promjene prethodno nabrojane. Također ukoliko ima nekoliko tablica, ovdje se mogu vrlo jednostavno povezati.

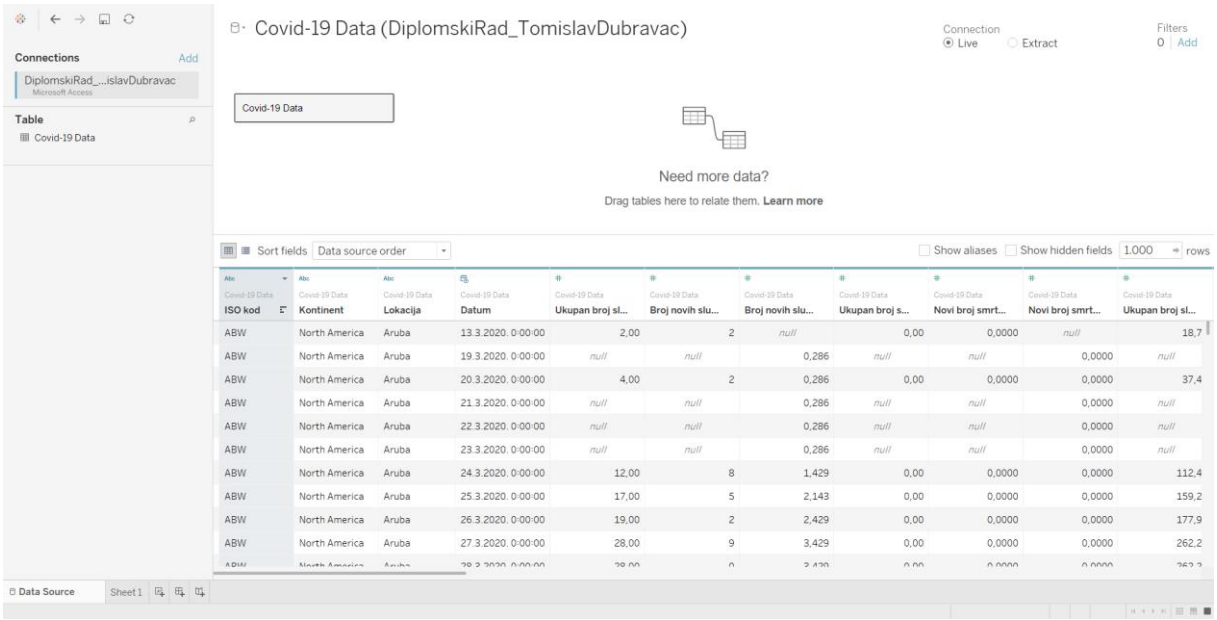

Slika 19. Prikaz podataka nakon učitanih podatala u Tableau Desktop

Idući prikaz Tableau Desktop prozora na slici 20., prikazuje otvoreni radni list na kojemu se mogu vidjeti sve mogućnosti i karakteristike koje posjeduje spomenuti alat poslovne inteligencije. S lijeve strane imamo popis svih podataka koji se nalaze u bazi te su podijeljeni u dvije skupine, mjerljive (eng. Measure data) i dimenzijske (eng. Dimensions data) podatke. Također na radnom listu nalaze se mogućnosti filtriranja podataka te oblikovanja istih kada se odredi koja vrsta izvještaja i koji podaci su potrebni za kreiranje istoga. Spomenuti podaci koji su potrebni za kreiranje izvještaja, odnosno određenog dijagrama, mogu se označiti tako da se direktno dodaju na radni list, odnosno postoji mogućnost da se točno odrede podaci koji idu u stupce (eng. Columns) te koji idu u retke (eng. Rows). Isto tako s desne strane radnog lista nalaze se primjeri grafikona koji se mogu koristiti te prelaskom miša preko svakoga, dobivaju se informacije koje su sve vrste podataka potrebne za određeni dijagram.

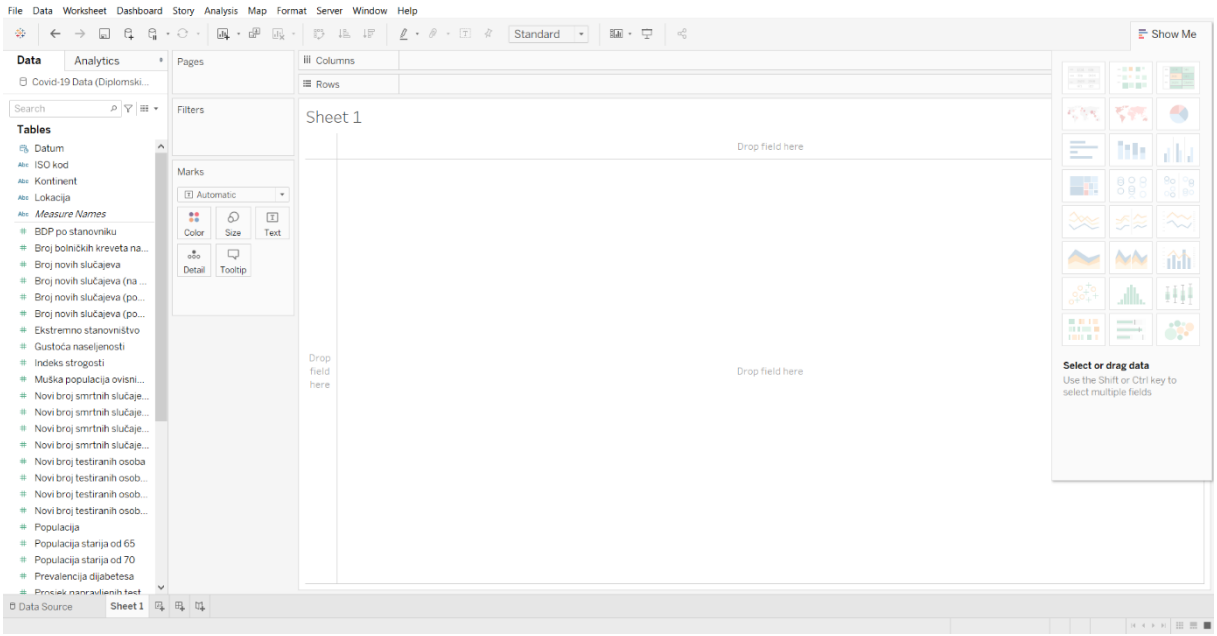

Slika 20. Prazni radni list alata Tebleau Desktop

Na prvom dijagramu (Slika 21.) prikazan je ukupan broj zaraženih osoba COVID-19 na prostoru Republike Hrvatske u razdoblju od 1. ožujka 2020. do 31. kolovoza 2020. godine. Dijagram je linijski u kojemu su korištene mogućnosti filtera za interval razdoblja godine koje se uzima u obzir te filter lokacije za koju državu se žele vidjeti podaci. Također na istom dijagramu dodane su krajnje vrijednosti podataka koje prikazuju koliko je ukupno bilo zaraženih na samom početku 1. ožujka te na kraju razdoblja 31. kolovoza kada su podaci preuzeti.

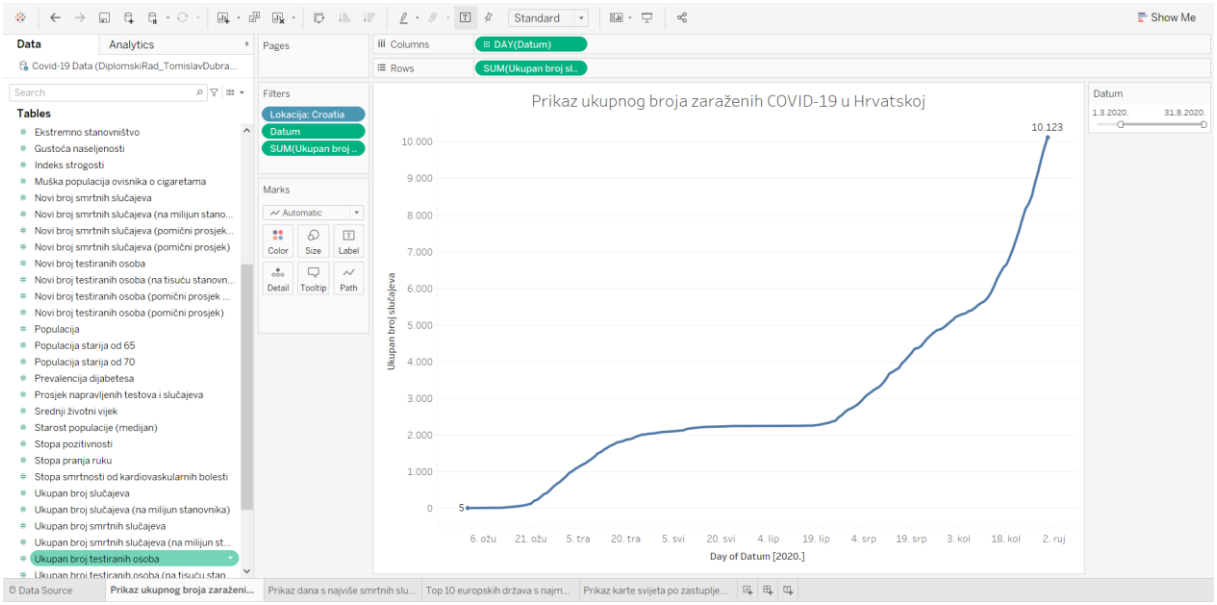

Slika 21. Prikaz ukupnog broja zaraženih COVID-19 u Hrvatskoj

Idući dijagram (Slika 22.) prikazuje dane s najviše smrtnih slučajeva u svijetu kojemu je uzrok bio COVID-19. Dijagram je u obliku mape drveta (eng. Tree Maps) koji predstavlja hijerarhijske podatke u obliku ugniježđenih pravokutnika u kojima površina svakoga odgovara određenoj numeričkoj vrijednosti. Tako se s ovog dijagrama mogu iščitati datumi sedamdeset dana u kojima je bilo najviše smrtnih slučajeva. Tamnom bojom i najvećim pravokutnikom označen je 16. travanj 2020. godine koji je po broju smrtnih slučajeva u ovom trenutku najgori za vrijeme novonastale epidemije. Također uz njega s malo svjetlijom, ali i dalje tamnom plavom bojom označeni su 14. kolovoz i 24. srpanj kao jedni od najgorih dana navedene epidemije.

Slika 22. Prikaz dana s najviše smrtnih slučajeva u svijetu

Uz linijske, stupčasti su najzastupljeniji dijagrami kada se u obzir uzima poslovna inteligencija te prikaz određenih poslovnih prilika i neprilika. U ovom slučaju na stupčastom dijagramu (Slika 23.) prikazano je deset europskih država s najmanjim indeksom strogosti za vrijeme COVID-19 epidemije, tj. indeks mjera koje su donijele određene Vlade pojedinih država za novonastalu situaciju. Tako iz prikazanog dijagrama može se vidjeti kako je Bjelorusija europska zemlja s daleko najmanjim indeksom strogosti od 8,74 te ju slijedi Švedska s 28,61 te Estonija s 31,32. Također kao filter uzeti s podaci lokacije te Europe kao kontinenta i deset najmanjih vrijednosti indeksa strogosti te je dodijeljeno oblikovanje prema lokacijama tako da svaka zemlja ima svoju različitu boju kako bi se lakše iščitao dijagram.

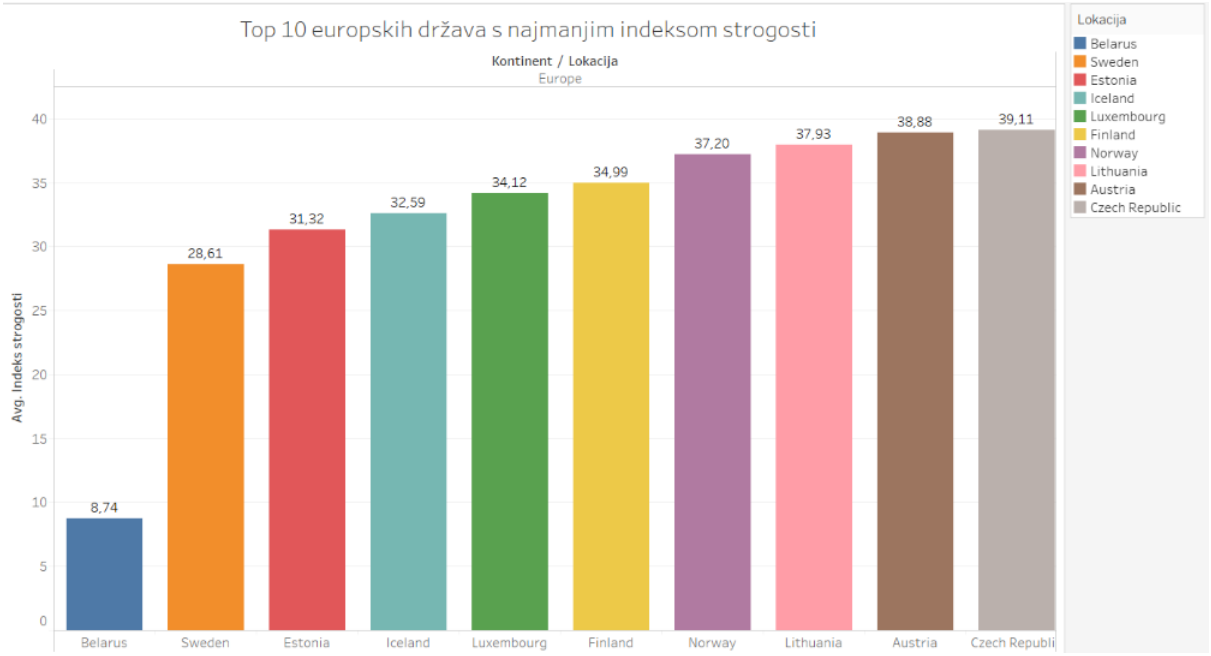

Slika 23. Top 10 europskih država s najmanjim indeksom strogosti

Najzanimljiviji dijagram alata Tableau Desktop-a je definitivno interaktivni zemaljski prikaz svijeta na koju postoji mogućnost prikazivanja različitih vrsta mjerljivih podataka te njihov prikaz na vrlo maštovit i različit način. Pa tako idući interaktivni dijagram (Slika 24.) prikazuje kartu svijeta po zastupljenosti broja slučaja COVID-19. Kako bi se geografski prikazale određene vrijednosti na ovakvoj vrsti dijagrama potrebna je i geografski tip podataka koji će u odnosu na ime zemlje, odnosno lokacije moći prikazati određenu definiranu vrijednost. Tako su u navedenom slučaju podaci lokacije definirani kao geografski (eng. Geographic) te u opcija su definirane kao nazivi zemalja, dok su kao mjerljivi podaci uzete maksimalne vrijednosti ukupnog broja zaraženih pojedine države. Na temelju tih maksimalnih vrijednosti napravljena je poredak svih zemalja te su se na temelju toga i dodijelile različite boje na kartama. Tamnija crvena boja prikazuje zemlje s najvećom zastupljenosti broja slučaja, dok tamnozelena boja prikazuje najmanju koncentraciju COVID-19 epidemije.

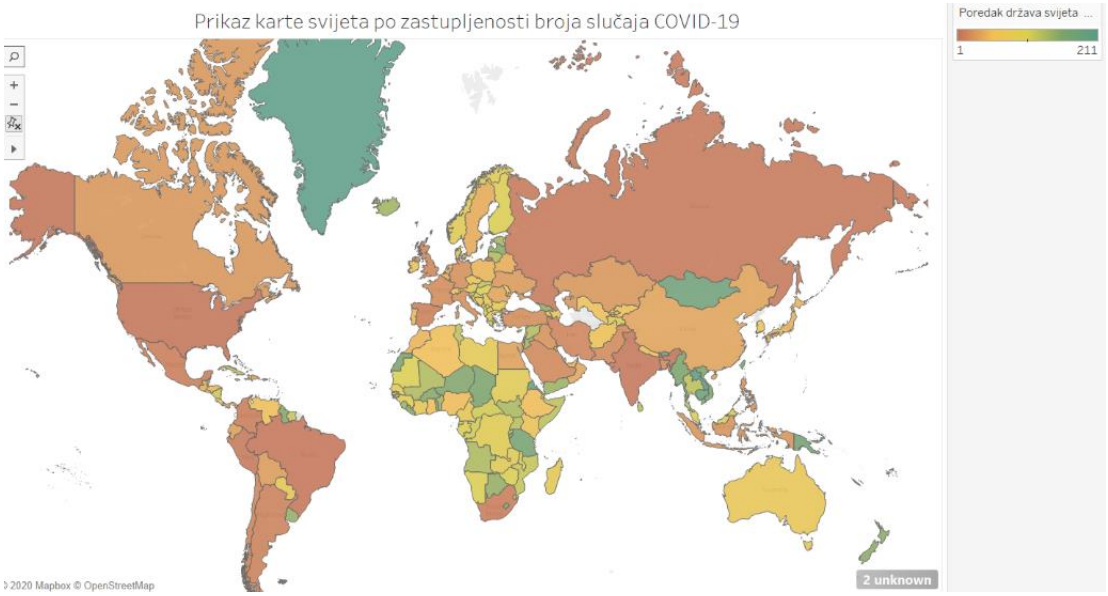

Slika 24. Interaktivni prikaz karte svijete po zastupljenosti broja slučaja COVID-19

Zadnji dijagram napravljen u Tableau Desktop (Slika 25.) je ponovni linijski dijagram koji prikazuje ukupni broj testiranih osoba na COVID-19 po pojedinom kontinentu na mjesečnoj bazi. Kao filteri korišteni su filter datuma koji omogućava da se prikazuju određene vrijednosti na mjesečnoj bazi te suma novih broja slučajeva koji su i prikazani za određeni mjesec na liniji. Također dodano je oblikovanje kako bi svaki kontinent bio obojan svojom bojom. Pa tako se s dijagrama može uočiti kako se u Africi i Sjevernoj Americi trend testiranja smanjuje, dok se u Aziji, Europi, Oceaniji i Južnoj Americi trend testiranja osoba na COVID-19 još uvijek povećava.

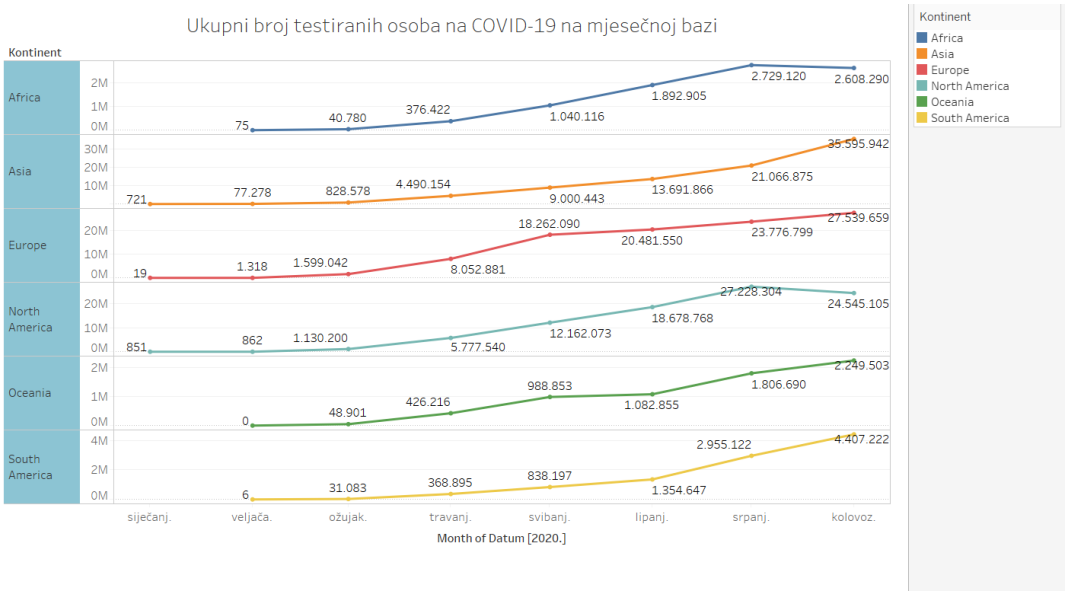

Slika 25. Ukupni broj testiranih osoba na COVID-19 na mjesečnoj bazi filtriranih po kontinentu

5.3. Analiza podataka – Microsoft Power BI

Microsoft Power BI je alat poslovne inteligencije koji omogućava izradu izvještaja koji omogućavaju povećanje konkurentnosti na tržištu. Za izradu specifičnih izvještaja, Power BI integrira Microsoft-ov „engine“ za upite, modeliranje podataka te tehnologije vizualizacije. Analitičari podataka (eng. Data analysts) i druga srodna zanimanja mogu stvarati zbirke upita, podatkovnih veza, modela te izvještaja koje se lako mogu podijeliti s ostatkom svijeta putem Power BI poslužitelja koji pruža nove uvide u svjetske podatke s kojima se lako može upravljati te ih koristiti. Slika 26. prikazuje početni zaslon samo aplikacije s koje se može pristupiti podacima koji su pohranjeni lokalno ili putem nekog poslužitelja. Također mogu se koristiti nedavno izrađena izvješća te gotova zadana izvješća koja su kreirana od strane Microsoft-a.

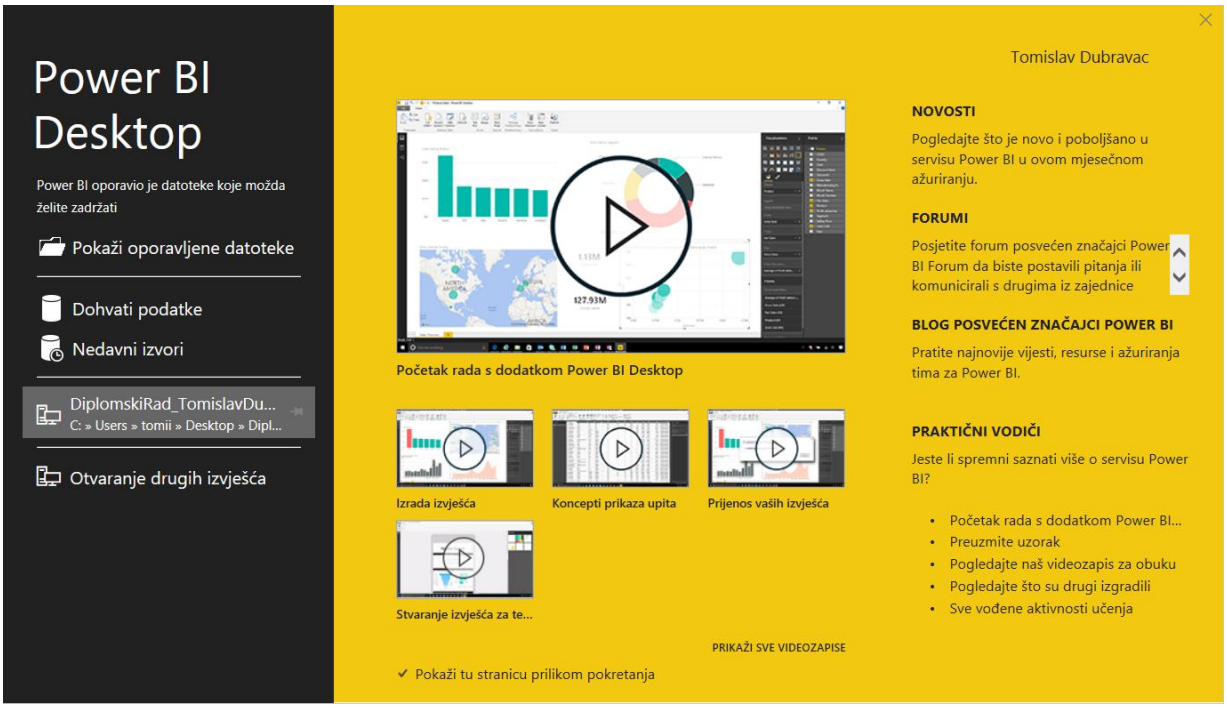

Slika 26. Početni zaslon Microsoft Power BI

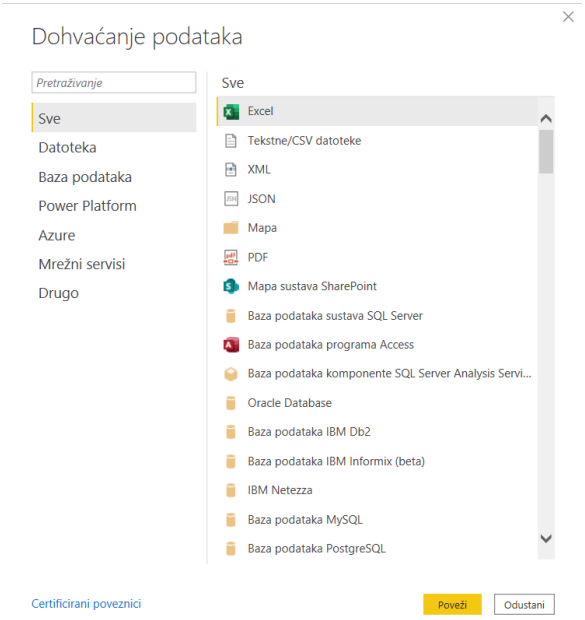

Slika 27. Dohvaćanje podataka na Microsoft Power BI

Postoje razne vrste dohvaćanja podataka (Slika 27.) koji će se koristiti pri izradi raznih izvještaja. Pa tako postoje uobičajeni načini poput Microsoft Excel-a i Access-a, CSV, XML, JSON datoteka. Isto tako postoji mogućnost spajanja na Oracle te IBM DB2 bazu podataka kao i na MySQL i PostgreSQL baze podataka, dok postoji i mogućnost spajanja na Power Platform-e te Azure. Na slici 28. prikazan je novootvoreni radni list bez dohvaćenih podataka koji sadrži kartice Polja u kojemu će se nalaziti učitani podaci, kartice Vizualizacije u kojemu se nalaze razne vrste dijagrama koji se mogu koristiti za izradu izvještaja te kartica Filtri koji omogućavaju upravljanjem samih podataka te odabiranje potrebnih vrijednosti.

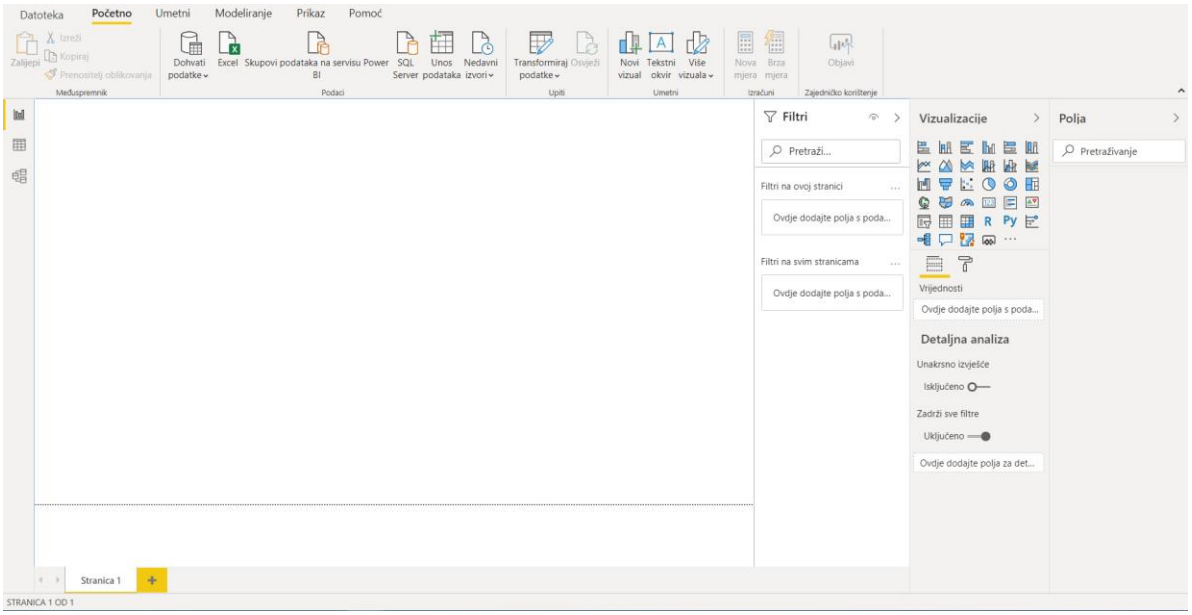

Slika 28. Novootvoreni radni list Microsoft Power BI

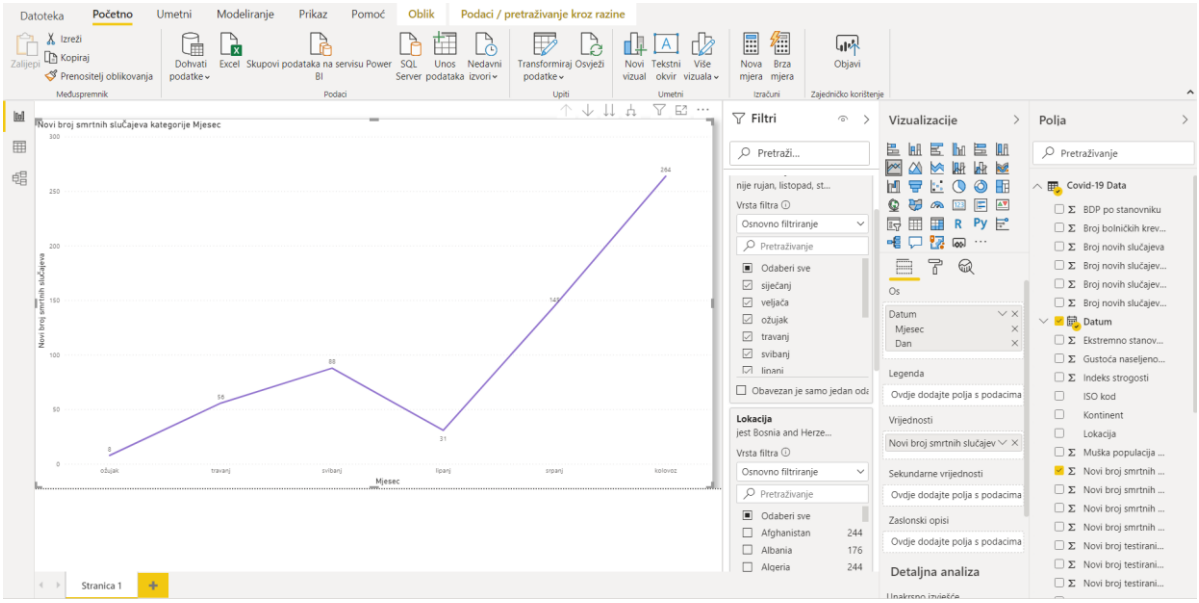

Slika 29. Prikaz ukupnog broja smrtnih slučajeva po mjesecima u Bosni i Hercegovini

Na slici 29. prikazan je linijski dijagram alata Power BI, koji prikazuje broj smrtnih slučajeva po mjesecima u državi Bosni i Hercegovini. Temeljem dolje viđenog grafa, korišteni su filteri koji prikazuju mjesece od ožujka do kolovoza te filter koji prikazuje podatke samo za Bosnu i Hercegovinu. Također na liniji su dodane vrijednosti koje prikazuju koliko je točno smrtnih slučajeva uzrokom COVIDa-19 zabilježeno.

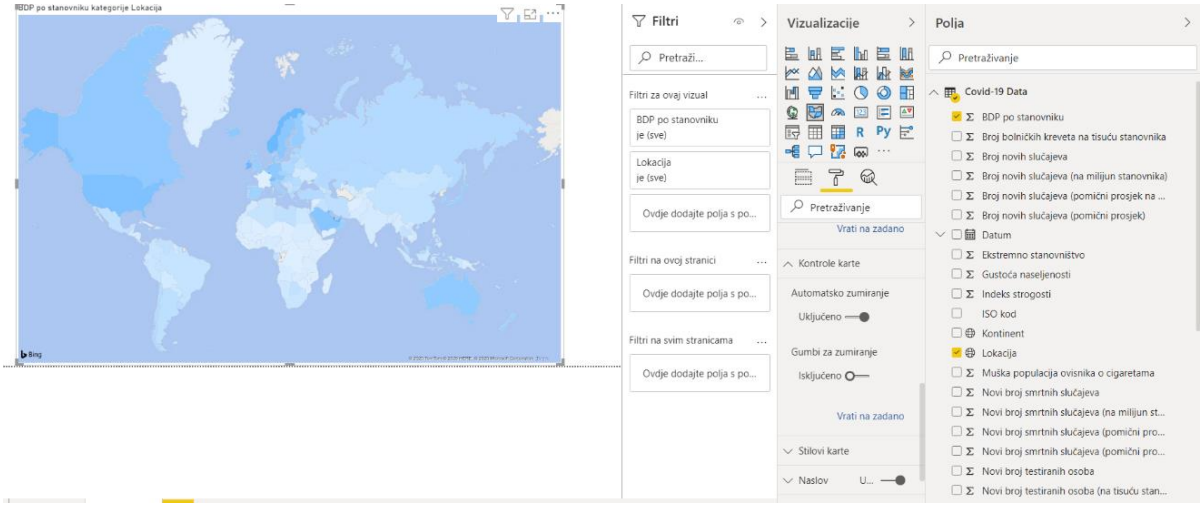

Slika 30. Interaktivni prikaz BDP po stanovniku u svijetu

Power BI također posjeduje mogućnost izrade interaktivnih karata kao prikaza određenih vrsta podataka (slika 30.). U ovom slučaju korišteni su podaci Lokacije koji su promijenjeni u geografski tip podataka kako bi se države mogle spojiti s kartom te kao mjerljivi podaci uzet je BDP (Bruto domaći proizvod) po stanovniku. Na karti su tamnoplavom bojom

označene su države svijeta s najvećim BDP-om po stanovniku, te su svijetloplavom bojom označene slabije razvijene države.

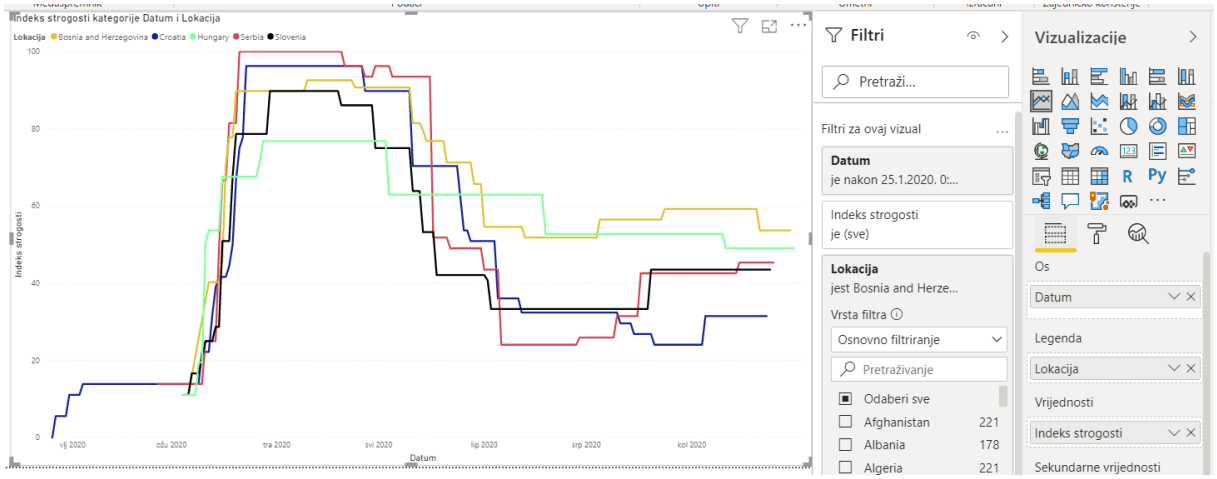

Slika 31. Prikaz indeksa strogosti pojedinih Balkanskih država

Prethodni dijagram prikazuje kretanje (Slika 31.), odnosno donošenje mjera za borbu s COVID-19 epidemijom od početka siječnja pa sve do kraja kolovoza 2020. godine. Podaci se točno odnose na Republiku Hrvatsku te njezine susjede te se slijedno tome može lako vidjeti koja je vlada u kojem trenutku tijekom navedenog razdoblja donijela strože, odnosno blaže mjere. Tako se može vidjeti da je Republika Hrvatska prva krenula s donošenjem mjera u odnosu na ostale susjedne zemlje te se također prema zadnjim podacima vidi kako je Republika Hrvatska osigurala najbolje mjere koje su pridonijele tome da trenutno ima najslabije mjere.

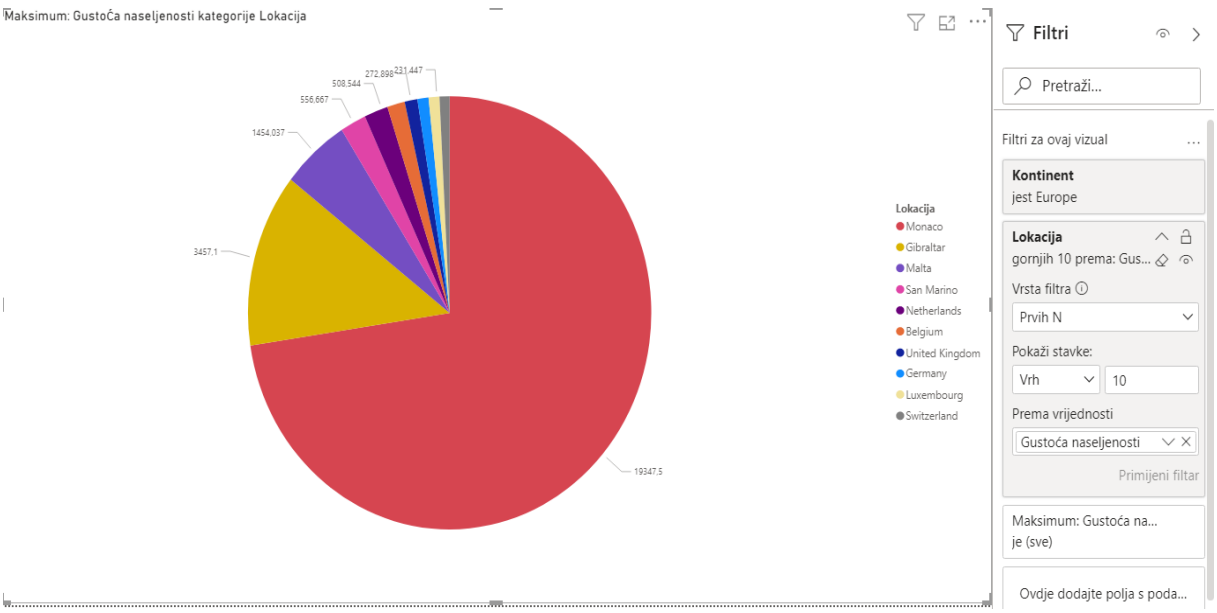

Slika 32. Dijagram u obliku pite koji prikazuje gustoću naseljenosti u Europi

Nadalje, prvi put u ovom projektu korišten je dijagram u obliku pite (Slika 32.) koji se temelji na krugu koji je podijeljen na sektore u kojemu svaki predstavlja određeni udio u cjelini. Tako gore prikazani grafikon predstavlja gustoću naseljenosti u Europi, odnosno prikazuje deset najgušće naseljenih država. Kao filteri korišteni su podaci kontinenata u kojemu su filtrirane države Europe te prema lokaciji su filtrirani prvih 10 država prema vrijednosti Gustoće naseljenosti. Tako da vidimo da preko 70% udjela grafikona zauzima Kneževina Monako te zatim slijede Gibraltar, Malta itd.

Zadnji dijagram prikazan u Power BI-u (Slika 33.) je stupčasti dijagram u kojemu se prikazuje dnevna aktivnost usporedbe broja novih slučaja i broja testiranih osoba tijekom mjeseca kolovoza u Republici Hrvatskoj u kojoj je na dnevnoj bazi bilo najviše zaraženih tijekom spomenute epidemije. Svijetloplava boja prikazuje broj zaraženih osoba, dok tamnoplava boja označava broj testiranih osoba na određeni datum. Također s dijagrama se vrlo lako može zaključiti kako je u fokusu činjenica koja kaže da što je veći broj testiranih osoba da je i broj zaraženih puno veći.

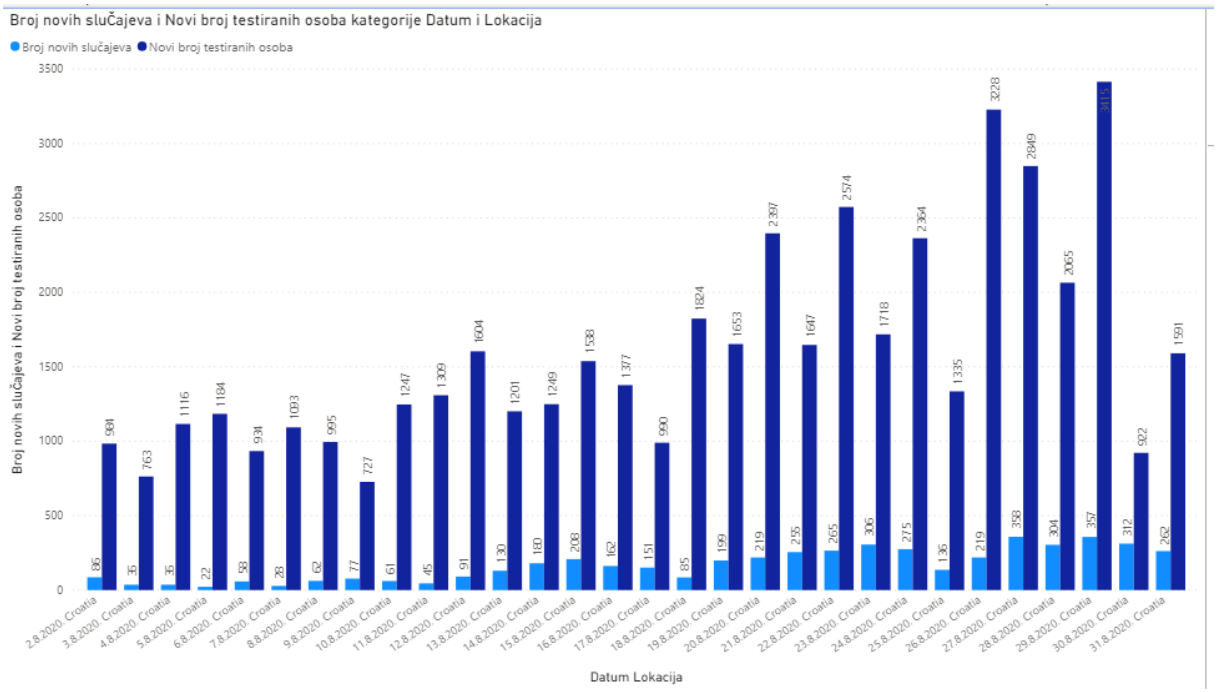

Slika 33. Prikaz odnosa ukupnog broja novih slučajeva te broja testiranih osoba na određeni datum

5.4. Analiza podataka – Qlik

Qlik Sense omogućuje slobodno istraživanje podataka krećući se vlastitim putevima do uvida. To znači da odabirom podataka, Qlik Sense sam definira određene grafikone svojom umjetnom inteligencijom koje tvore takozvane nadzorne ploče što će biti prikazano kasnije u poglavlju. Također, Qlik podržava čitav spektar slučajeva upotrebe analitike iz različitih vrsta

izvora. Time uključuje navedenu automatski generiranu vizualizaciju podataka kako bi se korisnika navelo na istraživanje podataka te vođenu analitiku radi usklađivanja korisnika sa standardnim poslovnim procesima tijekom rada. Sljedeća slika (Slika 34.) prikazuje početnu stranicu Qlik Sense-a koja omogućuje učitavanje podataka koji su spremljeni lokalno na računalo ili podatke koji su zadani prema određenom predlošku (eng. Template).

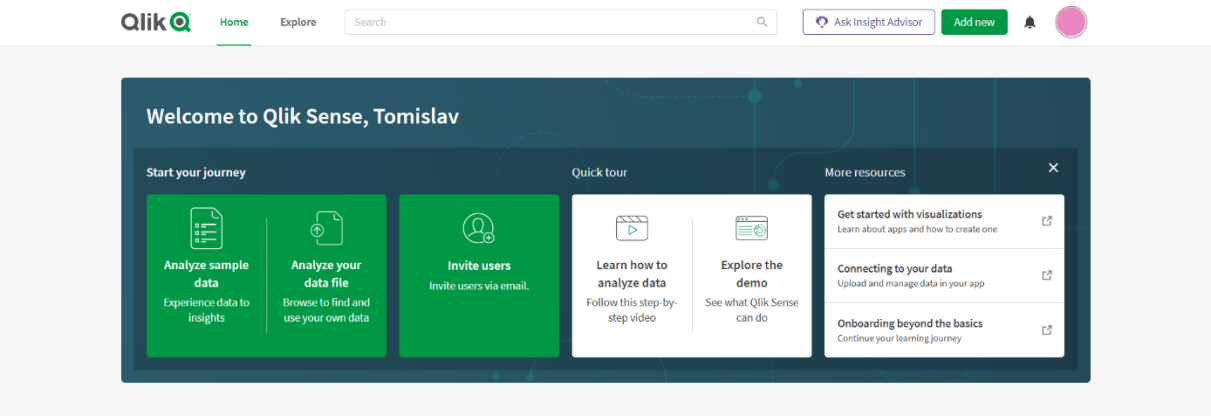

Slika 34. Početni zaslon alata Qlik

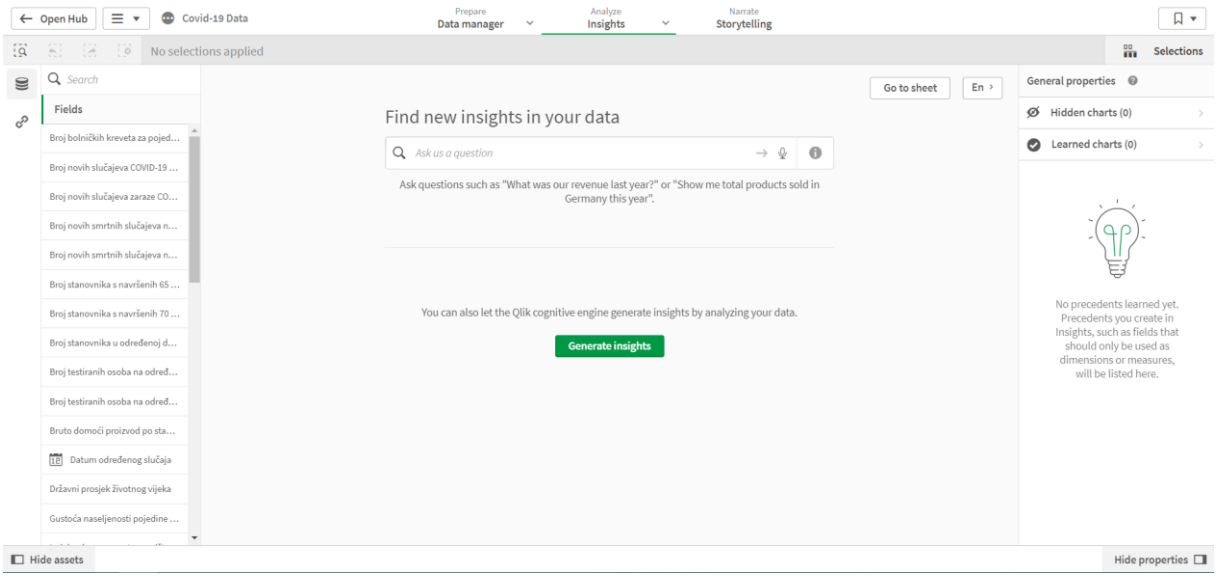

Slika 35. Uvidi alata Qlik

Na slici 35. nalazi se prikaz ekrana Qlik Sense koji prikazuje analitičku stranu uvida u podatke koji pružaju ulaznu točku za istraživanje podataka te stvaranje vizualizacije. Uvidi (eng. Insights) koriste Qlik kognitivni mehanizam za izradu vizualizacije na temelju odabranih podataka kao i umjetne inteligencije za stvaranje dijagrama. Uvidi se generiraju temeljem dodavanja novih podataka, povezivanjem i uređivanjem tablica te klasificiranjem polja,

odnosno vrste podataka. Isto tako generirani dijagrami se mijenjaju na temelju toga kako uvidi proučavaju polja te da li se u podatkovnom modelu koriste u dimenzijama, mjerama ili izrazima. Qlik Sense nadograđuje svoju umjetnu inteligenciju svakom novom interakcijom stvaranja dijagrama u svojoj aplikaciji.

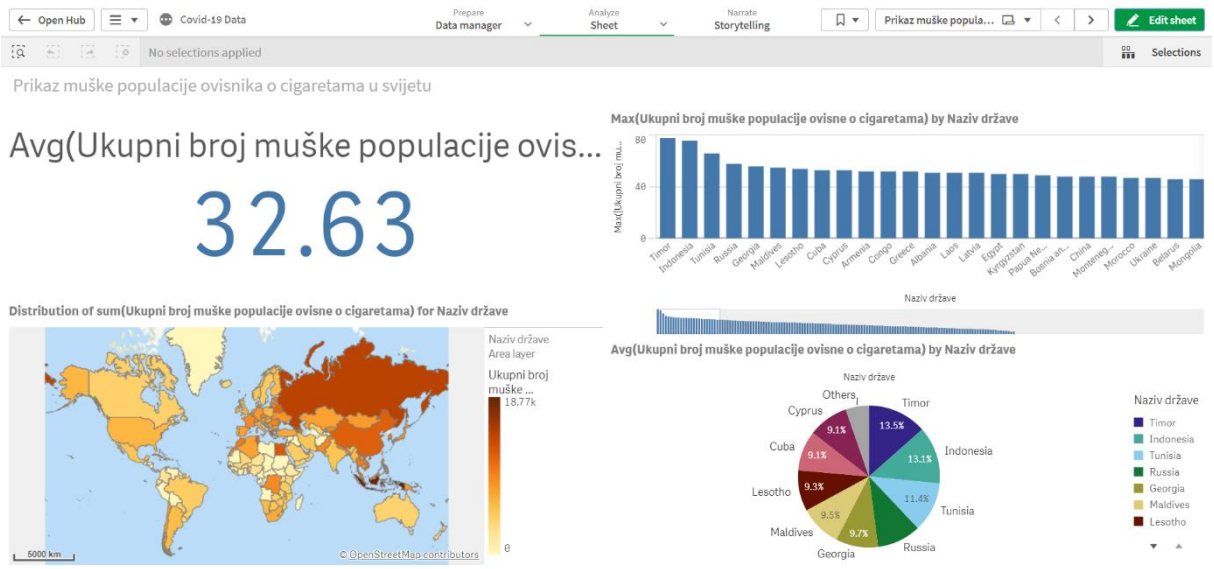

Slika 36. Nadzorna ploča prikaza muške populacije ovisnika o duhanskim proizvodima u svijetu

Prvi izvještaj u Qlik Sense-u (Slika 36.) prikazuje svjetsku situaciju o muškoj populaciji koja je ovisna u cigaretama. Kao što je već spomenuto, Qlik Sense automatski generira dijagrame koji se kasnije prenose na radni list koji samim time predstavlja određeni oblik nadzorne ploče. Tako na ovom primjer, može se vidjeti kako 32,63% muške populacije u svijetu su ovisnici o duhanskim proizvodima te isto tako na stupčastom i dijagram u obliku pite prikazuju se države s najvećim postotkom muške populacije ovisnima o duhanskim proizvodima. Kao i Tableau i Power BI, tako i Qlik posjeduje interaktivnu kartu svijeta koja prikazuje distribuciju o navedenom području analiziranja. Tamnom bojom prikazane su države svijeta u kojoj je najveća koncentracija ovisnika, dok se svijetlom bojom prikazuju države s malom koncentracijom istih. Qlik Sense također omogućuje odabir dijela podataka putem svitka (eng. Scroll) koji se nalazi ispod stupčastog dijagrama.

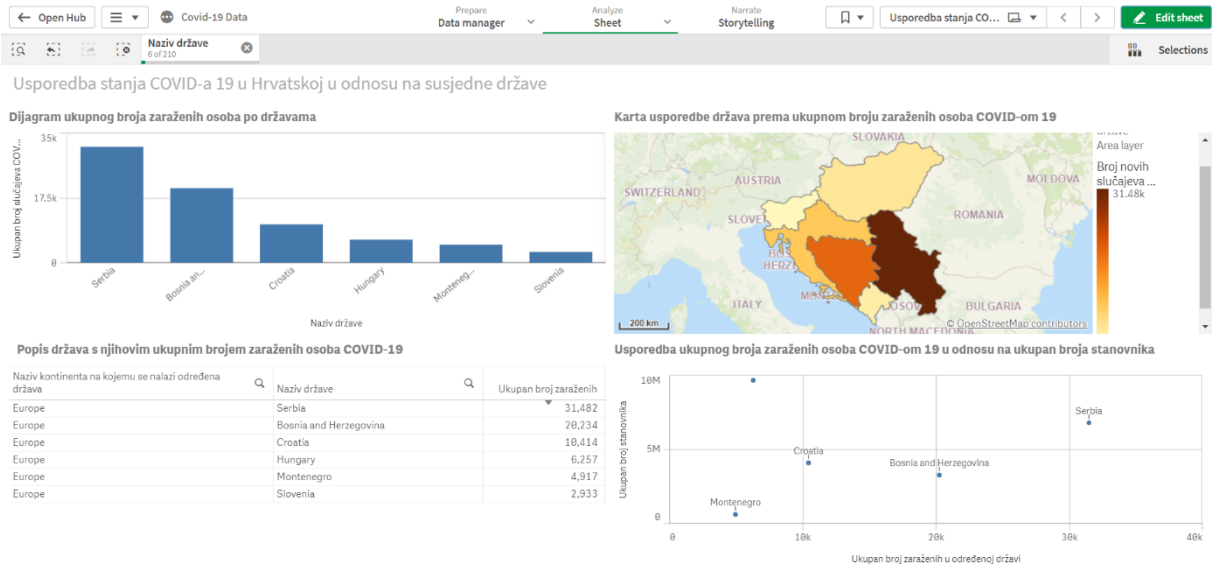

Slika 37. Usporedba stanja COVID-19 u Hrvatskoj u odnosu na susjedne države

Putem Qlik Sense-a detaljno, a opet vrlo jednostavno predstavljen je analitički izvještaj usporedbe stanja epidemije COVID-19 u Hrvatskoj u odnosu na susjedne države (slika 37.). Krenuvši od stupčastog dijagrama na kojemu se grafički lijepo mogu vidjeti odnosi u novonastaloj situaciji te isto tako na interaktivnoj karti gdje se vidi kako je Republika Srbija obojana tamnom bojom koja ukazuje kako upravo ona ima najveći broj zaraženih COVIDom-19. Na dijagramu koordinatnog sustava mogu se vidjeti odnosi ukupnog broja stanovnika u određenoj državi te broja zaraženih u istoj. Također u ovom slučaju izvještaja korišten je filter koji se odnosi na polja Kontinent te Lokacije u kojemu je kao Kontinent u obzir uzeta Europa, dok su u kontekst Lokacije uzete Republika Hrvatska i sve njezine susjedne države s kojom posjeduje kopnenu granicu.

Zadnji izvještaj sastavljen u Qlik Sense-u (Slika 38.) sadrži podatke koje se odnose na stopu smrtnosti od kardiovaskularnih bolesti. Kardiovaskularne bolesti su jeden od najrizičnijih skupina bolesti u trenutnoj novonastaloj situaciji. Tako je u izvještajima na prvom mjestu napravljen stupčasti dijagram koji prikazuje deset država svijeta s najvećom stopom smrtnosti od navedene bolesti. Iz toga se može vidjeti kao su države predvodnice u ovoj kategoriji Uzbekistan, Afganistan te Papua Nova Gvineja. Isto tako, interaktivna karta pokazuje odnosne u svijetu gdje tamne boje prikazuju najveće stope smrtnosti. Na mapi stabla nalaze se prikazi država po kontinentima u navedenom području te ukoliko se pritisne na određeni kontinent dobiva se prikaz samo za njega što je prikazano na (Slika 39.).

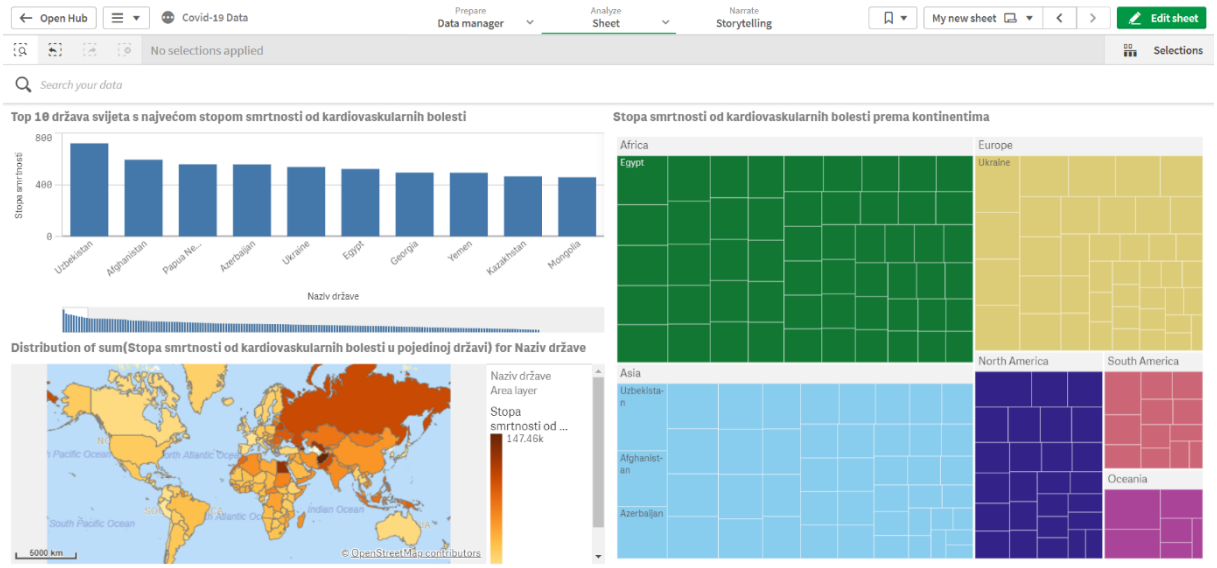

Slika 38. Nadzorna ploča prikaza stope smrtnosti od kardiovaskularnih bolesti u svijetu

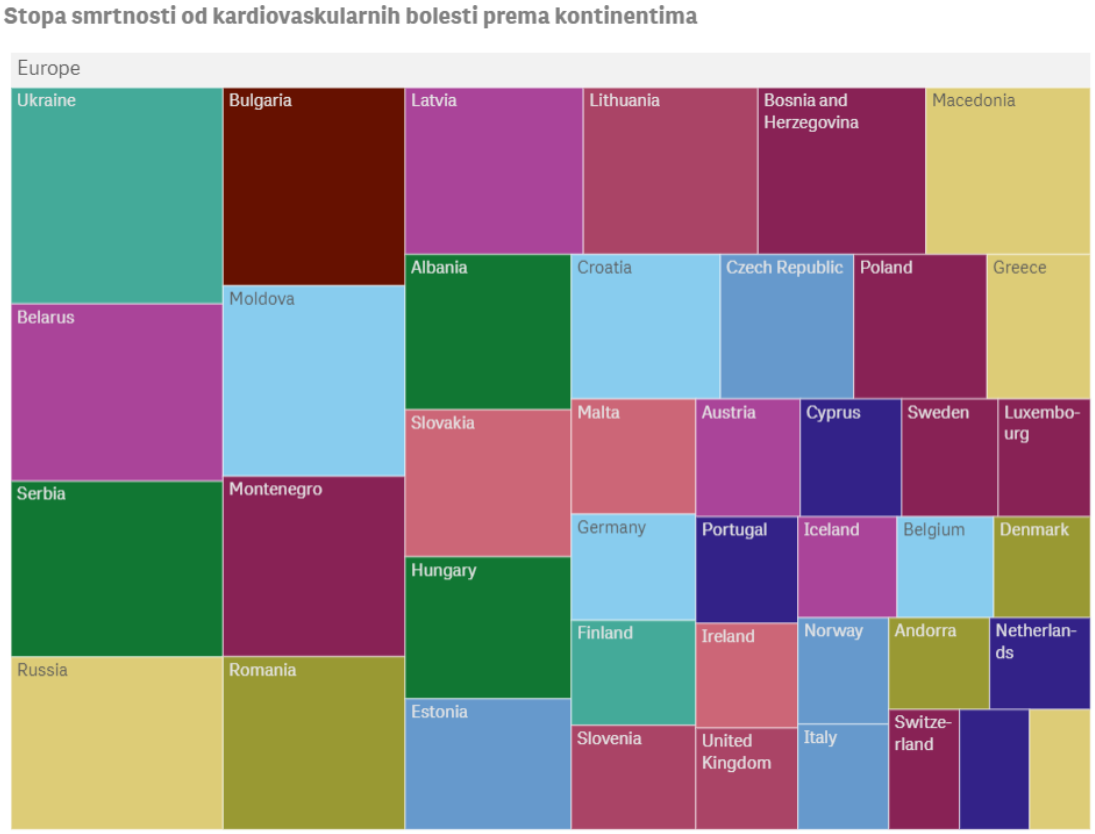

Slika 39. Mapa stabla europskih država prema smrtnosti od kardiovaskularnih bolesti

6. Usporedba alata poslovne inteligencije

„Analitika je primarno sredstvo za dobivanje istine i značenja podataka koji pokreću poslovni rast.“ [24] Rečenica koju je izjavio Hugo Moreno za jedan od najuspješnijih poslovnih magazina na svijetu – Forbes. Tvrtke se sve više i više oslanjaju na podatke jer su gotovo sve informacije koje su potrebne za poslovanje u potpunosti digitalizirane. Takvi podaci potrebni su softverima za poslovnu inteligenciju koji nude značajke koje analiziraju i izrađuju izvještaje za provođenje boljeg poslovanja i veće konkurentnosti na tržištu. Najpopularniji alati su Tableau, Microsoft Power BI te Qlik.

U daljnjem dijelu poglavlja istaknut će se ključne prednosti i nedostatci svake o nabrojenih alata poslovne inteligencije te sveobuhvatna lista alata poslovne inteligencije koji pokazuju kako se svaki slaže u ključnim poslovnim i funkcionalnim zahtjevima. Navedena usporedba alata poslovne inteligencije, Tableau, Microsoft Power BI te Qlik, razmatra odnose u vizualizacijama, analitici, OLAP-u (mrežnoj analitičkoj obradi), upravljanju dokumentima, uslugama donošenja odluka te u integracijskim značajkama tih triju sustava. Tableau je vrhunski alat za vizualizaciju, dok Qlik ima prednost u analitici, no Power BI prednjači nad svojim konkurencijama za svoje usluge u odlučivanju te mogućnostima integracije (Slika 40.).

	tableau	Power BI	Qlik
Vizualizacija podataka *Podaci su vizualizacijski predstavljani za jednostavnu interpretaciju*	✓ Prednost	✓	✓
Analitika *Identifikacija informacija te evaluacija istih radi provođena analitike radi praćenja trendova u tvrtki*	✓	✓	✓ Prednost
Mrežna analitička obrada (OLAP) *Funkcionalnosti mrežne analitičke obrade pružaju pristup bazama podataka i web servisima*	✓	✓	✓
Upravljanje dokumentima *Pretvaranje izvještaja u različite formate datoteka te dijeljenje istih*	✓	✓	✓
Mogućnosti odlučivanja *Omogućavanje donošenja kompetitivnih odluka na temelju analiza*	✓	✓ Prednost	✓
Integracija *Sposobnost povezivanja s drugim sustavima te pružanje više izvora i funkcionalnosti*	✓	✓ Prednost	✓
Integracija veliki podataka *Pristup programima velikih podataka za sveobuhvatnu analizu*	✓	✓ Prednost	✓

Slika 40. Usporedba alata poslovne inteligencije [24]

6.1. Prednosti i nedostatci – Tableau vs. Power BI vs. Qlik

6.1.1. Vizualizacija podataka

Tableau vodi u industriji softvera za vizualizaciju podataka. Tvrtka ulaže velika sredstva u napredne mogućnosti udruživanja podataka te u klasteriranje, segmentaciju i ostale moćne analitičke funkcije. Korisničino sučelje također omogućuje korisnicima brzu i jednostavnu izradu prilagođenih nadzornih ploča kako bi se dobio uvid u širok spektar poslovnih informacija. Mogućnosti povlačenja i ispuštanja (eng. Drag-and-drop) rješenje te uparivanje sa velikim brojem izvora podataka, čine Tableau vodećom tvrtkom u području vizualizacije podataka.

Microsoft Power BI jedan je od najkorisnijih alata za vizualizaciju podataka na tržištu poslovne inteligencije. Funkcija povlačenja i ispuštanja, zajedno s pristupom na preko osamdeset aplikacija za vizualizaciju podataka, pruža jednostavan prikaz koji rezultira detaljnim izvještajima. Power BI također koristi mnoge funkcije koje su dostupne u programu Office Excel tako da će se korisnicima u Office-u biti vrlo lako prilagoditi navedenom alatu.

Zajedno sa standardnim funkcionalnostima izrade izvještaja (predlošci vizualizacije, prilagodljivim prikazima te grafikom), Qlik-ov faktor vizualizacije jest stvaranje interaktivne analize u stvarnom vremenu. Sve vizualizacije i skupovi podataka prikazuju se uključujući Qlik-ov mehanizam (eng. Engine) koji ima sposobnost brze asocijativne analitike koje nije ostvariva samo pomoću SQL-a. Spomenuti mehanizam je dovoljno skalabilan da se integrira s mnogim različitim vrstama izvora podataka stvarajući tako jedinstvenu nadzornu ploču koja prikazuje analitiku, mjerne podatke te ključne pokazatelje uspješnosti (KPI). [24]

Iako jako dobri alati, Power BI i Qlik nisu dostigli postignuća Tableau-a koji nadmašuje svoje konkurente u navedenoj kategoriji. Sa svojim intuitivnim sučeljem, prilagodljivim mogućnostima prezentacije te analitikom u stvarnom vremenu, Tableau pruža sveobuhvatno i jednostavno iskustvo vizualizacije podataka.

6.1.2. Analitika

Tableau je alat koji pruža poduzećima održavanje i rješavanje hitnih analitičkih zahtjeva. To se može vidjeti iz poboljšanja manipulacijom podataka, pojednostavljenih sučelja te napredne analitike. Također održava potrebe organizacija koje žele prijeći aspekte vizualizacije podataka svojih aplikacija te obaviti napredniji analitički posao. Isto tako Tableau ima mogućnost podrške za složenije tijekove rada udruživanja podataka u razvoju mobilnih aplikacija.

Analitičko sučelje Power BI-a vrlo podsjeća na Excel, osiguravajući tako prepoznatljivu funkcionalnost. Microsoft Power BI stvara složene analize podataka koje se temelje na

izvorima podataka te točkama integracije. Mjerne i organizacijske značajke omogućuju jednostavno upravljanje podacima i tumačenje trendova. Osim alata za standardnu analizu podataka, Power BI nudi integraciju s podatkovnim programima temeljenim na lokacijama kao što su SQL Server Geospatial, BING te Esri ArcGIS.

Qlik posjeduje mogućnost kombiniranja mnogih izvora podataka bez potrebe za početnom pripremom. Oslanja se na sofisticiranu analitiku koja omogućuje otkrivanje podataka pomoću mehanizma za analizu podataka za uzorke koji nisu vidljivi kroz SQL strukture podataka, odnosno upite. Qlik također omogućava automatsku analizu i uvide dok korisnici manipuliraju s njihovim podacima. [25]

U usporedbi triju analitičkih alata poslovne inteligencije, Qlik ima najbolje analitičke značajke. Alat se može pohvaliti fleksibilnom analitičkom platformom koja omogućuje prilagodbu izvještaja koji se ažuriraju tijekom uporabe.

6.1.3. Mrežna analitička obrada (OLAP)

Tableau se može povezati s mrežnom analitičkom obradom kao sredstvo za istraživanje slojeva podataka na najdubljoj razini. To znači da zajedno s mogućnostima filtriranja i automatskim generiranjem vremenskih intervala, služe kao alati potrebni za ulazak u višedimenzionalne skupove podataka te nude pristup analizama koje pružaju.

Microsoft Power BI povezuje se s mrežnim analitičkim obradama putem SQL poslužitelja za vršenje višedimenzionalne analize podataka, izdvajanje podataka, promatranje uzoraka te rudarenje podacima. Takvim prediktivnim analizama, predviđaju se potencijalni budući trendovi. Također sam softver nudi popis mjera podataka koje treba prikazati u izvještaju. Kao tipična OLAP platforma, Power BI u detaljnu analizu uključuje i druge alate za istraživanje podataka.

Pristup mrežnoj analitičkoj obradi putem Qlik-a, omogućuju se inkapsulirani prikazi podataka. Pomoću takvih podataka, korisnici mogu analizirati dubinu OLAP podataka i povezati uvide sa svojim vlastitim izvještajima. Qlik OLAP konektor izdvaja podatke iz velikih baza podataka, dok značajke istraživanja podataka poput mogućnosti detaljnog izvođenja pružaju pristup najdubljim razinama podataka. Raznolike baze podataka pružaju sveobuhvatni pregled analizi, promatrajući slojeve podataka kroz više perspektiva. [26]

Tableau, Power BI i Qlik imaju standardnu OLAP funkcionalnost na istoj razini te niti jednom alatu se ne može pružiti prednost u ovom segmentu.

6.1.4. Upravljanje dokumentima

Tableau je uključio podršku za objavljivanje analitičkog sadržaja na raznim platformama koje omogućuju objavljivanje istoga. Opcije dostupne za formatiranje izvještaja uključuju PDF-ove, proračunske tablice, slike te unakrsne kartice (eng. Crosstabs). Korisnici mogu pregledavati sve faze izrade izvještaja pomoću značajke koja sprema i arhivira sve prošle verzije kako bi se mogle pogledati kasnije.

Izvještaji generirani u programu Microsoft Power BI mogu se izvesti u formatima PDF, TIFF (eng. Tagged Image File Format), HTML (eng. Hyper Text Markup Language) te u datotekama Microsoft Office-a. Datoteke Power BI uključuju datoteke radne površine (pbix) te predoška (pbit). Također izvoz izvještaja te pristup dokumentima je vrlo jednostavan, no ne podržava izravnu kontrolu nad verzijama i nema mogućnost kontrole svih faza kreiranja izvještaja.

Korisnici Qlik-a mogu pretvoriti izvještaja u formate XLS (Office Excel), HTML, XML (eng. eXtensible Markup Language), QVX (eng. Qlik dana eXchange) te u PDF. Softver podržava datoteke skripte Qlik-a (qvw) kako bi se omogućilo pojednostavljeno praćenje i usporedba binarnih datoteka. Qlik također kao i Tableau ima mogućnost pregledavanja faza izrada izvještaja. [24]

Sva tri alata poslovne inteligencije ekvivalentna su u kategoriji upravljanja dokumentima te isto tako svi mogu s lakoćom pretvoriti izvješća u više formata.

6.1.5. Mogućnost odlučivanja

Tableau mogućnosti u odlučivanju temelje se na pružanju resursa za pomoć u interpretaciji analize podataka te donošenju odluka. Isto tako alati za otkrivanje prijevara koji su ugrađeni u softver služe kao snažna sigurnosna mjera. Kao dio takvog fokusa odnose se na širu podršku za analitiku u kojoj su uključeni u poboljšanja u pripremi podataka te u većoj kontroli nad upravljanjem istih. Također odnose se na dodatke koji su ugrađeni u naprednu analitiku koja se provodi putem spomenutog alata.

Microsoft Power BI može se koristiti kao alat za financijsku analizu sa zaštitom od prijevara, praćenjem usklađenosti te dodatnim sigurnosnim značajkama. Funkcije analize prikazuju trendove i nude uvide putem zadanih savjetodavnih usluga. Takvi savjetnici, korisnicima pružaju sustav podrške za sve upite koje se tiču funkcije softvera. Isto tako služe kao vodič za konzultantske usluge koje nude uvid u analize koje pruža sustav Power BI-a. Dodatne usluge uključuju financijsku analitiku, mjere za sprječavanje prijevara te sigurnost i nadzor usklađenosti cijelog sustava.

Financijske usluge te bankarske mogućnosti omogućuju alatu Qlik pružanje precizno definiranog znanja i analize koje vode do informiranog donošenja odluka dok sigurnosne mjere smanjuju rizik od prijevare. Potrebni propisi te politike nadgledaju se pomoću alata za usklađivanje nadzorne ploče u Qlik-u. Široki raspon Qlik-ovih mogućnosti poslovne inteligencije omogućuju brzo učenje mrežnih vodiča te njihovih sustava učenja. Također, uz proizvod se isporučuju brojni vodiči s uputama te drugi resursi za samo razumijevanje, kao i tim stručnjaka koji stoje iz Qlik alata. Oni mogu pomoći u svakom koraku učenja sposobnosti sustava, od početnih lekcija do stvaranja kompleksnih uvida u podatke te stvaranja raznih aplikacija. [25]

Kada se razmatraju spomenuta tri alata poslovne inteligencije, Microsoft Power BI stavlja svoje mogućnosti odlučivanja iznad svih ostalih time što pružaju opsežni izvor znanja koji se ni u kojem smislu ne može usporediti s konkurentima.

6.1.6. Integracija

Na temelju integracije, Tableau omogućava poboljšanu podršku za REST API-je te za JavaScript, čineći tako integraciju preko analitičkih platformi koje se smatraju učinkovitijom i manje ovisnom o prilagođenom programiranju. Podrška za integraciju Tableau-a, korištenjem API-ja, omogućuje pojednostavljenu suradnju s programima kao što su Google Analytiscs, SAP, Salesforce, Microsoft Office te softver za planiranje resursa poduzeća i slični kanali društvenih medija. Za dodatnu razinu zaštite ugrađenim sigurnosnim mjerama softvera dodaju programi kao što su Active Directory , Kerberos te OAuth.

Microsoft Power BI posjeduje prednost Microsoft-ovog povezivanja te povezivanja s raznim aplikacijama. Njegovi korisnici mogu rudariti podatke iz programa kao što su Microsoft Excel, Google Analytics, MySQL, Oracle, Salesforce, MailChimp, Facebook te Zendesk, uz dodavanje novih izvora podataka tijekom određenog vremena. Microsoft-ov analitički alat se temelji na osiguravanju nesmetanog povezivanja Power BI-a sa postojećom radnom bazom tvrtke. U tom smislu, jedna od inovativnijih značajki Microsoft Power BI-a je mogućnost korištenja autorskih podataka zasnovanih na pregledniku te radnoj površini aplikacija koje se nalaze lokalno na računalu ili na oblaku. Takva strategija naziva se hibridnom te se temelji na API-jevima koje koriste Microsoft Azure Cloud.

Qlik ima jedan od najnaprednijih skupova naredbi sučelja za aplikacijsko programiranje (API) u industriji analitike te kontinuirano poboljšava svoju funkcionalnost tijekom posljednjih nekoliko godina. Qlik-ov API omogućuje besprijekornu integraciju s drugim alatima i podacima smještenim u određenom projektu. Uz mnoga poduzeća koja traže API podršku, Qlik je pružio API-je za kontrolu funkcija koje su prethodno bile dostupne samo putem korisničkog sučelja. Rezultat je bio brzo usvajanje platforme Qlik Analytics (QAP), koju programeri danas koriste

za ugrađivanje analitičkih upita u aplikacije za izvještavanje te analitiku. Qlik također ima mogućnost izdvajanja podataka iz standardne otvorene povezanosti baze podataka (ODBC) i OLE (eng. Object Linking and Embedding) veze te nestandardnih i nestrukturiranih izvora poput tekstualnih datoteka te XML datoteka. Kroz Qlik nudi se mogućnost integracije s web uslugama, sigurnosnim alatima, naslijeđenim sustavima te metapodacima. Softver oglašava koordinaciju s programima poput Microsoft Excel-a, Salesforce-a, SAP Netweaver-a te Microsoft SharePoint.vet. [25]

Prednost u integraciji podataka zauzima Microsoft-ova podloga platforme Power BI-a koja osigurava jednostavnu integraciju s brojnim vanjskim aplikacijama. Gotovo svaki program koji radi s Microsoft-om može se integrirati s Power BI-om, nudeći pritom opsežnu biblioteku mogućih mogućnosti suradnje.

6.1.7. Integracija velikih podataka

Tableau se može povezati s gotovo bilo kojim spremištem podataka (od Microsoft Office Excel-a pa sve do Hadoop klastera). Program otvara integraciju izvora podataka širokom spektru relacijskih baza podataka, Hadoop distribucijama i NoSQL-u. Pored toga, uključena je i podrška za IBM SPSS (IBM-ova statistička softverska platforma), SAS (sustav statističke analize) te datoteke podataka sa softverom R.

Zajedno s drugim Microsoft-ovim ponudama, uključujući Azure, SQL-ov analitički poslužitelj, manipulaciju podacima u stvarnom vremenu te R analitiku, Power BI pruža širok analitički spektar mogućnosti. Također nudi mogućnost povezivanja s vlastitim izvorima podataka ili vanjskim izvorima kao što su Hadoop, Azure HDInsight i Spark za cijeli niz podataka. Integracija otvorene baze podataka omogućuje pristup izvorima velikih podataka te tako korisnici mogu vizualizirati, analizirati, izvještavati te dijeliti podatke preuzete s ODBC (eng. Open Database Connectivity) izvora.

Qlik može izvući podatke iz mnogih izvora kako bi osigurao cjelovite i detaljne informacije te njihove odnose. Prednost Qlik-a je u tome što se može priključiti na gotovo svaki izvor podataka, što ga čini najsvestranijim alatom poslovne inteligencije. Za prikupljanje podataka koristi svoju aplikaciju Qlik Connectors, dok je Qlik DataMarket resurs koji korisnicima nudi mjesto za stjecanje vanjskih izvora podataka. [25]

Jednostavnost integracije velikih podataka, Power BI postaje najbolje rješenje iznad Tableau-a i Qlik-a. Power BI predstavlja baze podataka u prikazu izbornika gdje korisnici mogu jednostavno odabrati svoje odabrani izvor podataka, povezati se s njima te započeti postupak analize i kreiranja izvještaja.

6.2. Konstatacija prednosti

Tableau, Power BI i Qlik su izvrsni alati poslovne inteligencije koji imaju svoje prednosti, a i svoje mane. Alat koji će najbolje odgovarati odrađenoj kompaniji ili tvrtki ovisi o njezinim potrebama za analizom. Ako je povezivanje s postojećim internim bazama podataka, skladištima podataka i drugim izvorima podataka presudno za određeno poslovanje, postoji mogućnost da je potrebno analizirati pojedina rješenja u odnosu na zahtjeve te konfiguracije. Ukoliko su vizualizacije glavni fokus, Tableau je daleko najbolji alat za što postoji poseban razlog zašto su tvrtka i sam softver neprestano najbolje rangirani u spomenutim vizualizacijama.

Qlik je vrlo prilagodljiv i pruža široku dubinsku analitiku te također pruža integraciju s Daltek-ovim proizvodima koji se koriste za izvještaje koji se temelje na vremenu i troškovima. Uz sve uzete funkcionalnosti, Qlik nastavlja imati jednu od najviših ocjena zadovoljstva kupaca u industriji alata poslovne inteligencije.

S druge strane, Microsoft-ov Power BI je relativno jeftin alat poslovne inteligencije koji se besprijekorno uključuje s Microsoft-ovim Office-om. Takva opcija omogućuje brzi pristup određenoj analitici te intenzivnom izvještavanju, ukoliko postoje educirane osobe koje vješto barataju upitima podataka temeljenim na izvorima Microsoft-a. Može se reći kako je Power BI jedina aplikacija za vizualizaciju i analitiku podataka koja ima opsežne integracije povezane s R jezikom te velikim podacima (eng. Big Data), što osigurava skalabilnost ove aplikacije za veće projekte.

7. Zaključak

U ovom radu napravljena je usporedba alata poslovne inteligencije – Tableau, Microsoft Power BI te Qlik kroz izrade raznih izvještaja temeljem podataka o COVID-19 epidemiji koja je trenutno svjetski problem broj jedan. Glavni rezultati diplomskog rada ističu prednosti i nedostatke pojedinih alata poslovne inteligencije. Generalno kako bi se moglo odrediti koji je alat najbolji potrebna je analiza podataka te kreiranje izvještaja. No i nakon provedenih analiza i kreiranja izvještaja, odabir najboljeg alata je vrlo težak zadatak jer sva tri alata mogu ponuditi nešto jedinstveno te su razvijeni na takav način da služe određenoj svrsi. Mogućnosti povlačenja i ispuštanja, zajedno sa sigurnim podatkovnim vezama, čine Tableau vodećim na tržištu. Snage Qlik-a uključuju mogućnost vlastitog mehanizma za vizualizaciju podataka. Stvaranje izvještaja putem Power BI-a omogućuje dijeljenje projekata u timovima te pristup na bilo kojem uređaju. Kada se zbroje rezultati provedene usporedbe, Power BI se nameće kao najkonkurentniji alat zbog svoje integracije podataka te mogućnostima u odlučivanju. Riječ je o Microsoft-ovim aplikacijama i platformama visoke razine (eng. High-level) koji posjeduje naprednu podršku za kreiranje analiza koji se mogu koristiti lokalno, ali i na oblaku.

Također poslovna inteligencija sama po sebi je vrlo širok pojam o kojemu se raspravlja u kontekstu poboljšanja upotrebe informacija te probijanja poslovne inteligencije kroz različite strategije. Isto tako, vrlo bitno je usklađivanje spomenutih strategija koje moraju biti orijentirane prema poslovanju kako bi se postigla određena konkurentnost. Kontinuirano prikupljanje podataka u stvarnom vremenu te razmjena istih osiguravaju provođenje poslovnih ciljeva koji time omogućuju rješenjima poslovne inteligencije da stvore dodatnu vrijednost i doprinesu uspjehu poslovanja tvrtke.

Razvoj analitičkih alata poslovne inteligencije ima vrlo veliku važnost u današnjem svijetu informacija koje s pravom imaju status najbitnijeg resursa poslovanja. Samo tržište poslovne inteligencije raste te posljedično s time, udio informacija i podataka koji se koriste u dnevnim odlukama također rastu što daje plodno područje za daljnje istraživanje i spomenuti razvoj informacijskih tehnologija.

Popis literature

[1] S. Negash, „Business Intelligence“. Kennesaw State University, 2004, Pristupljeno: kol. 25, 2020. [Na internetu]. Dostupno na: https://aisel.aisnet.org/cais/vol13/iss1/15/.

[2] T. Järvinen, „Business Intelligence (BI) strategy development: a grounded action research“, Master’s thesis, Aalto University, 2014.

[3] A. K. Maheshwari, Business Intelligence and Data Mining. New York: Business Expert Press, LLC, 2015.

[4] „Mintzberg’s 5 Ps of Strategy“, MindTools, 2018. https://www.mindtools.com/pages/article/mintzberg-5ps.htm (pristupljeno kol. 30, 2020).

[5] N. McMurchy, „Take These Steps to Develop Successful BI Business Cases“. 2008, Pristupljeno: kol. 28, 2020. [Na internetu]. Dostupno na: http://www.umsl.edu/~sauterv/DSS4BI/links/pdf/BI/gartner_businesscase.pdf.

[6] „Tableau“, Tableau. https://www.tableau.com/ (pristupljeno kol. 30, 2020).

[7] „Microsoft Power BI: Data Visualization“, Microsoft. https://powerbi.microsoft.com (pristupljeno kol. 30, 2020).

[8] „Qlik | Data Analytics & Data Integration Solutions“, Qlik. https://www.qlik.com/ (pristupljeno kol. 30, 2020).

[9] „What Is a Database | Oracle“, Oracle. https://www.oracle.com/database/what-is-database.html (pristupljeno kol. 30, 2020).

[10] Rabuzin Kornelije, *SQL - napredne teme*. Varaždin: Fakultet organizacije i informatike, 2014.

[11] Rabuzin Kornelije i Maleković Mirko, *Uvod u baze podataka*. Varaždin: Fakultet organizacije i informatike, 2016.

[12] Rabuzin Kornelije, *Uvod u SQL*. Varaždin: Fakultet organizacije i informatike, 2011.

[13] „Database Design and Management“. https://www.visual-paradigm.com/training/database-design-and-management/ (pristupljeno kol. 30, 2020).

[14] „A Brief History of Database Management“, Dataversity, ožu. 23, 2017. https://www.dataversity.net/brief-history-database-management/# (pristupljeno kol. 27, 2020).

[15] „What Is a Relational Database | Oracle“, Oracle. https://www.oracle.com/database/what-is-a-relational-database/ (pristupljeno kol. 31, 2020).

[16] Carić T., Relacijski model podataka i osnove relacijske algebre“, [Na internetu]. Dostupno na: https://www.weboteka.net/fpz/Baze%20podataka/Predavanja/04%20-%20BP%20-%2004.tjedan.pdf.

[17] „What Are Object-Oriented Databases And Their Advantages“, C# Corner, lip. 09, 2019. https://www.c-sharpcorner.com/article/what-are-object-oriented-databases-and-their-advantages2/ (pristupljeno kol. 30, 2020).

[18] „Distributed DBMS - Distributed Databases“, TutorialsPoint. https://www.tutorialspoint.com/distributed_dbms/distributed_dbms_databases.htm (pristupljeno kol. 27, 2020).

[19] „What is Data Warehouse? Types, Definition & Example“, Guru99. https://www.guru99.com/data-warehousing.html (pristupljeno kol. 29, 2020).

[20] Lauren Schaefer, „What is NoSQL?“, mongoDB. https://www.mongodb.com/nosql-explained (pristupljeno kol. 29, 2020).

[21] „What is NoSQL Database“, Educba. https://www.educba.com/what-is-nosql-database/ (pristupljeno kol. 29, 2020).

[22] „Database management systems (DBMS)“, SQLRelease, 2015. https://sqlrelease.com/sql-server-tutorial/dbms-rdbms-and-sql-server/dbms (pristupljeno kol. 29, 2020).

[23] „What is DBMS? Application, Types, Example, Advantages“, Guru99. https://www.guru99.com/what-is-dbms.html (pristupljeno kol. 30, 2020).

[24] A. Conrad, „Power BI vs Tableau vs QlikView: Which BI Software is the Winner?“, SelectHub - Confidence in Software. https://www.selecthub.com/business-intelligence/tableau-vs-qlikview-vsmicrosoft-power-bi/ (pristupljeno kol. 31, 2020).

[25] „Power BI vs Tableau vs Qlik“, Educba. https://www.educba.com/power-bi-vs-tableau-vs-qlik/(pristupljeno kol. 31, 2020).

[26] „What is Business Intelligence? BI Definition - OLAP.com“, OLAP.com. https://olap.com/learn-biolap/olap-bi-definitions/business-intelligence/ (pristupljeno kol. 30, 2020).

Popis slika

Slika 1. Proces sustava Poslovne inteligencije 1
Slika 2. Arhitektura poslovne inteligencije [2] 5
Slika 3. Dijamantni model upravljanja informacijama 9
Slika 4. Logo alata Tableau Software-a [6] 15
Slika 5. Struktura Tableau Software-a 16
Slika 6. Logo alata Microsoft Power BI-a [7] 20
Slika 7. Logo alata Qlik [8] 22
Slika 8. Ilustracija baze podataka [13] 26
Slika 9. Primjer relacijske baze podataka [16] 27
Slika 10. Primjer objektne baze podataka [17] 28
Slika 11. Primjer distribuirane baze podataka [18] 28
Slika 12. Primjer strukture skladišta podataka [19] 29
Slika 13. Struktura NoSQL baze podataka [21] 30
Slika 14. Funkcionalnosti sustava za upravljanje bazom podataka [22] 31
Slika 15. Pogled "Prikaz podatkovne tablice" u Microsoft Access-u 36
Slika 16. Pogled "Prikaz dizajna" u Microsoft Access-u 37
Slika 17. Početni zaslon aplikacije Tableau Desktop 38
Slika 18. Spajanje izvora podataka na Tableau Desktop 39
Slika 19. Prikaz podataka nakon učitanih podatala u Tableau Desktop 39
Slika 20. Prazni radni list alata Tebleau Desktop 40
Slika 21. Prikaz ukupnog broja zaraženih COVID-19 u Hrvatskoj 41
Slika 22. Prikaz dana s najviše smrtnih slučajeva u svijetu 41
Slika 23. Top 10 europskih država s najmanjim indeksom strogosti 42
Slika 24. Interaktivni prikaz karte svijete po zastupljenosti broja slučaja COVID-19 43
Slika 25. Ukupni broj testiranih osoba na COVID-19 na mjesečnoj bazi filtriranih po kontinentu 43
Slika 26. Početni zaslon Microsoft Power BI 44
Slika 27. Dohvaćanje podataka na Microsoft Power BI 45
Slika 28. Novootvoreni radni list Microsoft Power BI 45
Slika 29. Prikaz ukupnog broja smrtnih slučajeva po mjesecima u Bosni i Hercegovini 46
Slika 30. Interaktivni prikaz BDP po stanovniku u svijetu 46
Slika 31. Prikaz indeksa strogosti pojedinih Balkanskih država 47
Slika 32. Dijagram u obliku pite koji prikazuje gustoću naseljenosti u Europi 47
Slika 33. Prikaz odnosa ukupnog broja novih slučajeva te broja testiranih osoba na određeni datum 48

Slika 34. Početni zaslon alata Qlik 49
Slika 35. Uvidi alata Qlik 49
Slika 36. Nadzorna ploča prikaza muške populacije ovisnika o duhanskim proizvodima u svijetu 50
Slika 37. Usporedba stanja COVID-19 u Hrvatskoj u odnosu na susjedne države 51
Slika 38. Nadzorna ploča prikaza stope smrtnosti od kardiovaskularnih bolesti u svijetu 52
Slika 39. Mapa stabla europskih država prema smrtnosti od kardiovaskularnih bolesti 52
Slika 40. Usporedba alata poslovne inteligencije [24] 53

Popis tablica

Tablica 1. Načini i troškovi korištenja Tableau Software-a [6] 18
Tablica 2. Pojedinosti o cijenama korištenja Tableau Software-a [6] 19
Tablica 3. Načini i troškovi korištenja Microsoft Power BI [7] 21
Tablica 4. Pojedinosti o cijenama korištenja Microsoft Power BI [7] 21
Tablica 5. Načini i troškovi korištenja alata Qlik [8] 24
Tablica 6. Pojedinosti o cijenama korištenja alata Qlik [8] 25
Tablica 7. Popis podataka korištenih pri izradi projektnih izvještaja 33