Alati za vizualizaciju podataka u poduzećima

Krulić, Kristijan

Undergraduate thesis / Završni rad

2020

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Pula / Sveučilište Jurja Dobrile u Puli**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:137:390414

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-29**

Image not found or type unknown

Repository / Repozitorij:

Digital Repository Juraj Dobrila University of Pula

zir.nsk.hr

Image not found or type unknown

Sveučilište Jurja Dobrile u Puli
Odjel za informacijsko-komunikacijske tehnologije

Kristijan Krulić

Alati za vizualizaciju podataka u poduzećima

Završni rad

Pula, Rujan 2020.

Sveučilište Jurja Dobrile u Puli

Odjel za informacijsko-komunikacijske tehnologije

Kristijan Krulić

Alati za vizualizaciju podataka u poduzećima

Završni rad

JMBAG: 030375983, redovni student

Studijski smjer: Informatika

Kolegij: Osnove IKT

Mentor: doc.dr.sc. Snježana Babić

Pula, Rujan 2020.

IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisani Kristijan Krulić, kandidat za prvostupnika informacijsko-komunikacijske tehnologije ovime izjavljujem da je ovaj Završni rad rezultat isključivo mojega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio Završnog rada nije napisan na nedozvoljen način, odnosno da je prepisan iz kojega necitiranog rada, te da ikoji dio rada krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

Student

Kristijan Krulić

U Puli, Rujan, 2020. godina

IZJAVA

o korištenju autorskog djela

Ja, Kristijan Krulić dajem odobrenje Sveučilištu Jurja Dobrile u Puli, kao nositelju prava iskorištavanja, da moj završni rad pod nazivom „Alati za vizualizaciju podataka u poduzeću“ koristi na način da gore navedeno autorsko djelo, kao cjeloviti tekst trajno objavi u javnoj internetskoj bazi Sveučilišne knjižnice Sveučilišta Jurja Dobrile u Puli te kopira u javnu internetsku bazu završnih radova Nacionalne i sveučilišne knjižnice (stavljanje na raspolaganje javnosti), sve u skladu s Zakonom o autorskom pravu i drugim srodnim pravima i dobrom akademskom praksom, a radi promicanja otvorenoga, slobodnoga pristupa znanstvenim informacijama. Za korištenje autorskog djela na gore navedeni način ne potražujem naknadu.

U Puli, Rujan, 2020. godina

Potpis

Kristijan Krulić

Sadržaj

1. UVOD 1
2. POSLOVNA INTELIGENCIJA (BI) 2
2.1 OPĆE KARAKTERISTIKE POSLOVNE INTELIGENCIJE 2
2.2 POSLOVNA INTELIGENCIJA U PODUZEĆIMA 3
2.3 METODE POSLOVNE INTELIGENCIJE 4
2.3.1 Dashboards 5
2.3.2 Izvještavanje 7
2.3.3 Prediktivna analizika 8
2.3.4 ETL 8
2.3.5 Rudarenje podataka 10
2.3.6 OLAP 11
3. VIZUALIZACIJA PODATAKA 11
3.1 POVIJESNI RAZVOJ VIZUALIZACIJE PODATAKA 12
3.2 PREDNOSTI VIZUALIZACIJE PODATAKA U PODUZEĆIMA 14
4. ALATI ZA VIZUALIZACIJU PODATAKA 16
4.1 OSNOVNE FUNKCIONALNOSTI ALATA ZA VIZUALIZACIJU PODATAKA .. 18
4.2 NAJPOZNATIJI ALATI ZA VIZUALIZACIJU PODATAKA 20
4.2.1 Tableau 20
4.2.2 Looker 22
4.2.3 Zoho Analytics 23
4.2.4 Sisense 24
4.2.5 Qlik Sense 25
4.2.6 Microsoft Power BI 26
4.2.7 Klipfolio 27
4.3 PRIMJERI UGRAĐENE VIZUALIZACIJE „NON-VISUALIZATION“ ALATA 29
4.3.1 Jupyter Notebook 30
4.3.2 R Studio 31
4.3.3 MongoDB 32
4.3.4 Google Analytics 33
5. ZAKLJUČAK 34
Sažetak 35
Summary 36
6. LITERATURA 37

1. UVOD

Živimo u razdoblju u kojem je nužna potreba za što većem znanjem. Način na koji se to znanje pribavlja jest što većom količinom podataka koji su danas prisutni svugdje. Ljudi raspolažu brojnim tehnologijama, društvenim mrežama i internetom koji im omogućuje dobivanje svako jakih oblika informacija. Svaka osoba u današnjem svijetu koristi se internetom i ne prođe dan bez da ne sazna neki oblik informacije. Internet je jedna od osnovnih izvora podataka gdje ljudi mogu pronaći sve. Možemo reći da živimo u razdoblju u kojem prevladava „Big Data“.

Imaju mogućnost pribavljanja tolike količine podataka često se javlja problem prenatrpanosti podacima. Ovo je jedan od osnovnih problema svakog poduzeća. Raspolažu velikim količinama nepotrebnih podataka u kojem se ne mogu snalaziti, što usporava rad cijelog poduzeća. Kako bi se spriječio ovaj problem razvio se sustav koji se upotrebljava u gotovo svim velikim i malim poduzećima. Riječ je o poslovnoj inteligenciji.

Poslovna inteligencije je sustav koji se sastoji od metoda i alata koji omogućavaju poduzećima u lakšem baratanju sa podacima. Omogućuju različite metode prikupljanja i rada sa podacima kao i lakšeg snalaženje među njima. Problem kod velikih poduzeća je to da raspolažu sa toliko podataka pri čemu zaposlenici ne mogu filtrirati bitne od nebitnih, čime se usporava proces poslovanja. Kako ne bi došlo do toga, poslovna inteligencije sadrži jednu vrlo praktičnu metodu koja je danas postala temelj za rad sa podacima, to je vizualizacija podataka.

Vizualizacija podataka kao što sama riječ govori, daje vizualnu sliku podataka za lakše snalaženje i obradu nad podacima. Ukratko ona pomaže poduzećima u postizanju novih ciljeva i kreiranju kvalitetnih poslovnih izvješća pomoću kojih ljudi mogu prezentirati trenutnu situaciju u kojoj se poduzeće nalazi. Zahvaljujući njoj poslovni sastanci postaju bolji i jednostavniji upravo radi vizualne reprezentacije podataka. Puno lakše je shvatiti neku priču objašnjenu na slikovit način nego u obliku dosadnih sirovih podataka.

Razvoj vizualizacije jako je napredovao posljednjih nekoliko godina. Razlog tome je očit, kao što smo objasnili svijetom prevladava previše podataka a premalo metoda i alata za rukovanje podacima. Iz tog razloga dolazi do velike potražnje za metodama i

alatima za obradu podataka. Proces vizualizacije konstantno napreduje kreiranjem sve boljih i boljih alata za vizualizaciju podataka kako bi se riješio problem o „Big Data“. Možemo prognozirati da će se proces vizualizacije još dugo vremena razvijati. Kako vrijeme prolazi i kako tehnologija postaje sve bolja, tako se i količina podataka povećava iz dana u dan. Svijet će težiti tome da se razviju što bolji alati, jer razvojem sve kvalitetnijih i sve bržih alata za vizualizaciju, proces poslovanja u poduzećima postaje sve jednostavniji i bolji, a time i zadovoljstvo ljudi. (Hussain, 2019, dostupno na:https://medium.com/@syedjunaid.h47/what-is-big-data-why-is-big-data-important-in-todays-era-8dbc9314fb0a)

2. POSLOVNA INTELIGENCIJA (BI)

2.1 OPĆE KARAKTERISTIKE POSLOVNE INTELIGENCIJE

Postoje različite definicije poslovne inteligencije, međutim svaka od tih definicija ima jedan zajednički cilj. Generalno poslovnu inteligenciju možemo definirati kao skup tehnika, alata i različitih strategija ili metodologija, koje se koriste u svrhu prikupljanja, obrade i pohrane različitih podataka. Korištenjem tih podataka dobivaju se određene informacije, koje su potrebne poduzećima za donošenje poslovnih odluka. Možemo zaključiti da je poslovna inteligencija jedna od glavnih sastavnica svakog oblika poslovanja u organizacijama. Koristi se za donošenje kvalitetnijih poslovnih odluka, analizu prikupljenih podataka pomoću različitih alata i metodologija koje ona pruža, vizualizaciju tih podataka, skladištenje podataka i brojnih drugih čimbenika koje pridonose u razvoj organizacije. (Bentley, 2017, str 1)

2.2 POSLOVNA INTELIGENCIJA U PODUZEĆIMA

Kao što smo spomenuli poslovna inteligencija je sustav koji se koristi za prikupljanje podataka i pretvorbu tih podataka u informacije koje su potrebne poduzećima pri donošenje važnih poslovnih odluka. Sustav poslovne inteligencije pohranjuje podatke o procesima vlastitog poduzeća, o podacima njegovih konkurencija, podatke o kupcima, te ih obrađuje u smislene i korisne informacije. Takve informacije daju poduzeću bolje razumijevanje nad potencijalnim kupcima, poslovnim partnerima, natjecanju protiv različitih konkurencija, kvalitetno planiranje, natjecanju na tržištu, stvaranju budućih promjena, prilagođavanju trenutačnog stanja poduzeća, predviđanju budućih promjena i slično.

Ovaj proces prikupljanja podataka izvršava se pomoću brojnih alata, aplikacija i metodologija kojima raspolaže poslovna inteligencija. Podaci se prikupljaju iz različitih unutarnjih i vanjskih izvora, pripremaju se za analizu, analiziraju se i na temelju provedene analize prikazuju se pomoću različitih metoda vizualizacije (grafovima, tablicama, člancima…). Rezultat postupka jest čitljiv i razumljiv prikaz informacija, potreban direktorima, menadžerima i ostalim članovima poduzeća za donošenje konkretnih i ispravih poslovnih odluka koje poboljšavaju produktivnost, povećavaju prihod i ubrzavaju rast poduzeća.

Način na koji poduzeće dolazi do ovakvih podataka jest pomoću alata ili metoda za poslovnu inteligenciju. Alati za poslovnu inteligenciju omogućio je raznim poduzećima, velikim i malim, brojne mogućnosti za dohvaćanje, analizu, vizualizaciju i pretvaranje podataka. Današnja poduzeća sakupljaju ogromne količine podataka, međutim svi ti podaci su nepotrebni ako ih ne možemo pravilno upotrijebiti. Pravilnom uporabom podataka i shvaćanje čime poduzeće raspolaže, dolazimo do donošenja kvalitetnih poslovnih odluka.

U današnje vrijeme alati za rad sa podacima praktičniji su i jednostavniji za korištenje za razliku od onih prije nekoliko godina. Za korištenje tih alata nije potrebna velika količina informatičkog znanja, kao nekad u prošlosti. Prije su ih upotrebljavali samo IT stručnjaci, radi njihove kompleksnosti i loše strukturiranosti. Međutim to se ubrzo promijenilo i još danas se mijenja, kako bi postali što jednostavniji i bolji, jer živimo u svijetu gdje se tehnologija stalno mijenja i poboljšava iz dana u dan. Došlo je do toga

da su se pojavili alati koji su znatno jednostavniji za korištenje, sa puno boljim performansa, čitljiviji i bolje strukturirani za razliku od prošlih.

Objasnili smo kako funkcionira sustav poslovne inteligencije, kako poduzeće njime raspolaže, što mu omogućava i kako dolazi do takvih vrsta informacija. Zadnji korak koji je ostao jest prezentiranje prikupljenih rezultata. Spomenuli smo da je rezultat čitljiv i razumljiv prikaz informacija. Način na koji se podaci prikazuju članovima poduzeća jest pomoću izvješća. Postoje dva osnovna načina prikazivanja podataka. To su standardan ili specifičan način ovisno o potrebi. Standardan način kao što sama riječ govori jest cijeli prikazi informacija nekog promatranog dijela, dok specifičan način uključuje prikaz samo određenih dijelova promatranog područja, ovisno o upitima korisnika. Ti izvještaji u većini slučajeva prikazuju se u obliku tablica ili različitih vrsta grafova, gdje dolazimo do jedne važne grane poslovne inteligencije, to je vizualizacija podataka. Ona ima važnu ulogu u svakom poduzeću jer omogućava bolje razumijevanje informacija, bolje predočavanje, povezivanje podataka i samim time bolje donošenje poslovnih odluka. (Pratt i Fruhlinger, 2019, dostupno na: https://www.cio.com/article/2439504/business-intelligence-definition-and-solutions.html)

2.3 METODE POSLOVNE INTELIGENCIJE

Jedna od najvažnijih sastavnica za pravilan rad svakog poduzeća su podaci. Podaci su korisne informacije koje su potrebne prilikom bilo kakvog oblika odlučivanja. Svaki direktor treba znati kako iskoristiti svoje podatke u potpunosti, kako bi se poduzeće razvijalo. Oni nam pomažu u boljem razumijevanju svojih kupaca, vrsti poslovanja, donošenju boljih poslovnih odluka, rješavanju problema, poboljšavanju procesa, omogućavaju praćenje stanja poduzeća i kao najvažnija činjenica omogućiti da na bolji način poduzeće iskoristi novac. Niti jedno poduzeće svijeta ne može pravilno funkcionirati bez podataka.

Alati poslovne inteligencije su vrsta softvera ili metoda koji služe za prikupljanje i obradu velikih količina podataka. Pružaju različite načine prikupljanja podataka, prikazivanja podataka, pripremu podataka za analizu i kreiranje različitih izvješća,

„dashborda“ i slično. Isto tako omogućavaju direktorima, menadžerima i zaposlenicima u bržem donošenje poslovnih odluka u poduzeću, prepoznavanja potencijalnih poboljšanja, pomaganje u prepoznavanju različitih trendova, ukratko stvaranju prednosti u odnosu na ostale konkurencije.

Te metode sastoje se od sedam najvažnijih dijelova koje ćemo objasniti. Njihova osnovna uloga jest pružati korisniku što jednostavniji rad sa podacima. Svaka od tih metoda obavlja određeni zadatak u poslovnoj inteligenciji, međutim svi imaju jedan zajednički cilj, a to jest ubrzati i poboljšati cjelokupan proces poslovanja u poduzećima.

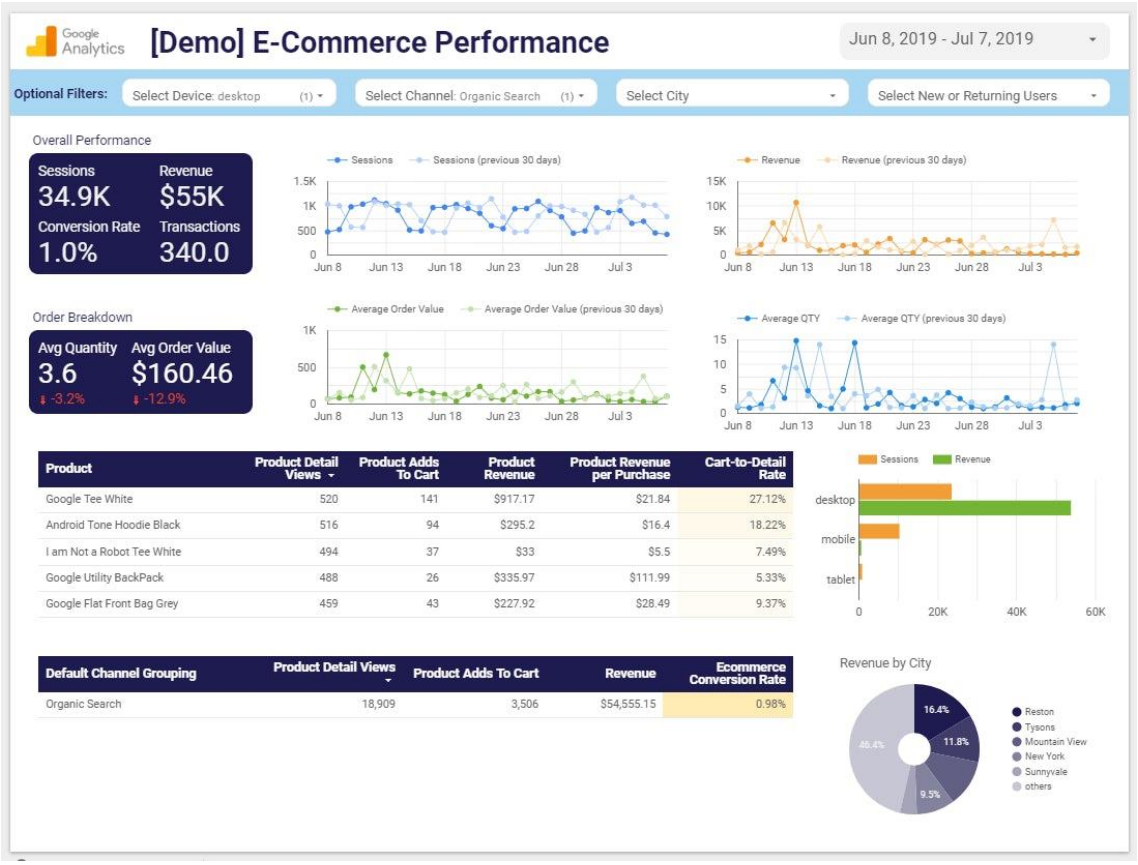
(Adair, 2018, dostupno na: https://www.selecthub.com/business-intelligence/key-types-business-intelligence-tools/)

(Saylor,2018, dostupno na: https://www.microstrategy.com/us/resources/introductory-guides/business-intelligence-the-definitive-guide)

2.3.1 Dashboards

Dashboards ili interaktivna sučelja je alat koji služi poduzećima za vizualno praćenje i upravljanje informacijama. Grafičko sučelje jednostavne je građe i jednostavan za korištenje, kako bi korisnicima bilo razumljivo i pregledno. Jedno je od osnovnih alata za vizualizaciju podataka, jer omogućava interakciju sa podacima. Možemo reći da predstavljaju vezu između krajnjeg korisnika i podataka.

Interaktivna sučelja organiziraju, pohranjuju i prikazuju sve važe informacije iz različitih izvora na jednom mjestu. Podaci se prikazuju u obliku različitih grafova, tablica, linijskih shema, traka i mjerila, koji pomažu korisnicima razumjeti veze između podataka i provoditi kvalitetne analize nad njima. Pomažu u boljem razumijevanju korelacija između podataka, prepoznavanju različitih trendova, otkriti i riješiti probleme i razumjeti cjelokupan proces poslovanja koji prevladava u poduzeću.(Wille, 2001, dostupno na: https://www.klipfolio.com/resources/articles/what-is-data-dashboard)



Slika 1. Prikaz interaktivnog sučelja u poslovanju
Izvor: https://econsultancy.com/what-are-digital-dashboards-challenges-best-practice/ (Pristupljeno: 02.078.2020)

Slika 1. prikazuje primjer interaktivnog sučelja u poslovanju jedne e-trgovine. Sastoji se od podataka prikupljenih iz različitih izvora, pomoću kojih direktori i menadžeri mogu razumjeti cjelokupan proces poslovanja nad svojom e-trgovinom. Pomažu nam razumjeti cjelokupan proces poslovanja i sam koncept poslovne inteligencije koji se odvija u našem poduzeću. Međutim izrada ovakvih sučelja dosta je složena i komplicirana. Dizajneri moraju izraditi interaktivno sučelje koje će obuhvaćati sve potrebne informacije o poslovanju, pritom pazeći na to da sve bude jednostavno prikazano i dobro objašnjeno. Isto tako potrebno je pripaziti na ispravnost i točnost podataka koje upotrebljavamo. Podaci se prikupljaju na razne načine i spremaju se u spremišta. Prilikom izrade sučelja dizajneri moraju paziti na vrstu podataka koju uzimaju, jer može se desiti da su podaci dosta neprecizni ili neaktualni.

Radi toga kvaliteta interaktivnog sučelja ne ovisi samo o njenim svojstvima i mogućnostima, nego o tome tko ju je izradio i koliko dobro. Da li su podaci korišteni za izradu dovoljno ažurni, dovoljno precizni, način strukturiranja podataka u interaktivnom sučelju, način prikaza podataka i sam način izrade sučelja. Svako

interaktivno sučelje biti će prikazano drugačije ovisno o kvaliteti dizajnera koji ga izrađuje. Izraditi dobro interaktivno sučelje nije jednostavno, jer mora pripaziti na sve navedene činjenice, s time da sve bude prikazano na korisniku jednostavan i razumljiv način. Korisnici kojima se prikazuje interaktivno sučelje najčešće su direktori ili poslovni menadžeri, koji zahtijevaju da budu izrađeni na način da se prikazuju što je više informacija moguće, na što jednostavniji i što bolji način.

2.3.2 Izvještavanje

Kada govorimo o izvještavanju u poslovnoj inteligenciji riječ je o metodi koja prikuplja i predstavlja podatke, pomoću koje možemo analizirati i donositi određene poslovne odluke. Izvještavanje u poslovnoj inteligenciji sastoji se od dviju osnovnih cjelina. Jedna cjelina odnosi se na proces prikupljanja podataka iz različitih izvora i prezentiranje tih podataka korisnicima na njima razumljiv način. Druga cjelina odnosi se na predstavljanje podataka. Podaci se pretvaraju u informacije koje su bitne poduzeću i omogućavaju korisnicima/klijentima da te informacije razumiju i djeluju sa njima. Prikazuju se u obliku statističkih podataka, neke vrste vizualnog prikaza ili pak standardnog teksta, koji se koriste prilikom kratkoročnog i dugoročnog odlučivanja za razvoj i rast poduzeća.

Osnovni cilj izvještavanja je omogućiti korisnicima pristup nad podacima kako bi ih mogli analizirati i pretvarati u informacije bitne poduzeću. Drugim riječima, izvještavanje se bavi prikupljanjem i prikazivanjem podataka, gdje se svako izvješće usredotočuje na jedan određeni skup podataka, dok analiziranje pretvara prikupljene podatke u korisne informacije. Ako se poduzeće pravilno upotrebljava metodom izvještavanja, puno će se brže razvijati i djelovati za razliku od svojih konkurenata. Povećati će poslovanje u poduzeću, brzinu rada, bolje će primjenjivati podatke, stvarati bolja predviđanje i bolje optimizirati troškove poduzeća. Sve ove karakteristike vode ka stjecanju bolje pozicije na tržištu, što je osnovni cilj svakog poduzeća da budu što dominantnije za razliku od svojih konkurenata. (Durcevic,2020, dostupno na: https://www.datapine.com/blog/business-intelligence-reporting/)

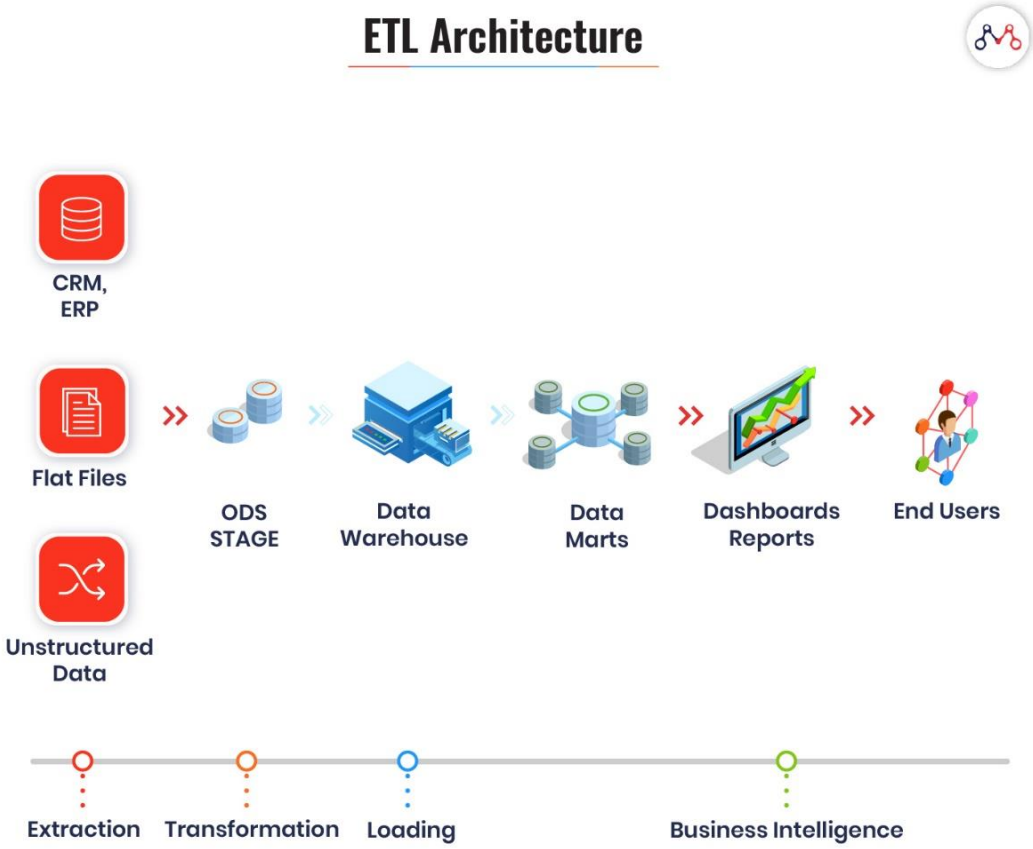
2.3.3 Prediktivna analizika

Prediktivna analitika jest metoda koja govori o nečemu što će se tek dogoditi u budućnosti. Na temelju korištenja različitih statističkih tehnika kao što su rudarenje podataka, umjetna inteligencija, strojno učenje i slično, analiziraju se trenutni i zastarjeli podaci pomoću kojih se predviđaju budući događaji. Dobivanje ovakvih informacija, što će se dogoditi u budućnosti znatno pomaže u razvoju poduzeća. Svako je može upotrebljavati na svoj način. Možemo ju definirati kao granu statistike koja se bavi analizom podataka za predviđanje budućnosti. Na temelju toga poduzeće može na vrijeme reagirati i pripremiti se na nadolazeće promjene i probleme, otkriti potencijalne propuste u poslovanju, koristiti je za optimizaciju marketinških kampanja, predviđanja zaliha, poboljšanja učinkovitosti u poslovanju, smanjiti vjerojatnost pojave rizika, zadovoljiti očekivanja kupaca i brojne druge čimbenike.

Isto tako korištenjem prediktivne analitike poduzeća stvaraju prednosti nad svojom konkurencijom. Te prednosti očitavaju se u obliku donošenja pametnijih, preciznijih i bržih odluka, povećanju konkurentnosti na tržištu, smanjenju pojavljivanja rizika i nesigurnosti prilikom donošenja odluka, bolje upravljanje resursima i stvaranje bolje proizvodnje. (Bentley, 2017, str. 37-38) (Yonatan, 2018, dostupno na: https://www.dundas.com/resources/blogs/how-to-leverage-predictive-analytics-in-your-business-intelligence-solutions)

2.3.4 ETL

Extract, Transform, Load, jest procedura koja je postala u današnje vrijeme vrlo popularna. Razlog toga je što svako veliko poduzeće koristi bazu podataka radi pohrane velikih količina podataka. Imati tako veliku količinu podataka javlja se potreba za integriranjem podataka. To znači da je potrebna metoda koja uzima podatke iz različitih izvora, pretvara ih u određeni oblik i sprema na određenu lokaciju. Iz tog razloga proces ETL postao je jedan od standarda cjelokupnog procesa integriranja podataka.



Slika 2. Prikaz procesa ETL u poduzećima
Izvor: https://www.mantralabsglobal.com/blog/etl-in-business-intelligence/ (Pristupljeno: 03.078.2020)

Procedura ETL funkcionira na principu prikazanog primjera. Proces se sastoji od tri faze koje se odvijaju sekvencijalno, što znači da se faze odvijaju slijedno, jedna nakon druge.

Prva faza „Extract“ bazira se na izdvajanju podataka iz različitih izvornih sustava. To je ujedno i najbitnija faze ETL-a radi slijednog odvijanja procesa. Ako prilikom izdvajanja podataka dolazi do greške cijeli proces se zaustavlja. Nakon ulaska u iduću fazu podaci se mapiraju u jedinstveni oblik i provjeravaju. Provjeravanje podataka bitan je dio faze, kako bi se ustanovilo da podaci imaju očekivane vrijednosti.

Druga faza „Transform“ izvršava niz operacija nad podacima kako bi se pripremili za posljednju fazu. Dakle nakon izdvajanja podataka i njihovog mapiranja, provodi se takozvano čišćenje podataka. Operacije koje se izvršavaju u procesu čišćenja su: spajanje, filtriranje, računanje i provjeravanje određenog formata podataka. Po završetku procesa čišćenja podaci prelaze u treću i posljednju fazu.

Posljednja faza „Load“ učitava pripremljene podatke na određenu lokaciju. Ta lokacija može biti bilo kakva vrsta spremišta za podatke, ovisno o potrebama i zahtjevima poduzeća.

Po završetku procesa dobivamo bazu sa točnim i ispravnim podacima, koji se koriste za vizualizaciju. Dizajneri stvaraju interaktivna sučelja sa potrebnim podacima, te se oni prikazuju korisniku na daljnje analiziranje. (Bentley, 2017, str. 162-164)

2.3.5 Rudarenje podataka

Rudarenje podataka je proces pomoću kojeg pronalazimo bitne informacija iz velikih količina neobrađenih podataka. Ovakve analize provode se pomoću softvera za rudarenje podataka, pomoću kojih se analiziraju informacije iz više različitih izvora za pronalazak trendova. Međutim ovaj proces ne uključuje samo prikupljanje podataka, već i skladištenje i obradu podataka. To znači da će se zastarjeli podaci koji se nalaze u bazi zamijeniti novima. Na taj način poduzeće se opskrbljuje potrebnim informacijama pomoću kojih mogu saznati više o svojim kupcima, iskorištavati resurse na optimalniji način, donositi bolje poslovne odluke, kontinuirano analizirati podatke bez prevelike potrošnje vremena i stvarati bolja predviđanja radi preciznijih i ažurnijih podataka. (Bentley, 2017, str. 64), (Orad, 2020, dostupno na: https://www.sisense.com/glossary/data-cleaning/)

2.3.6 OLAP

Internetska analitička obrada ili kraće OLAP jest tehnologija koja omogućuje korisnicima napredne analize nad podacima. Često je koriste analitičari radi potrebe za grupiranjem, organiziranjem i spajanjem podataka iz različitih baza. Kod obrade podataka u bazama ova tri procesa troše dosta vremena i puno resursa. Razlog tome je što se neki podaci sastoje od više kategorija, što znači da se podatak može raščlaniti na više manjih dijelova. Primjerice imamo podataka o vremenu. On se sastoji od nekoliko različitih dijelova kao što su godina/mjesec/tjedan/dan ili pak sat/minute/sekunde/milisekunde. Upravo iz tog razloga provodi se OLAP proces.

OLAP tehnologija služi za izvođenje višedimenzionalne analize nad velikim količinama poslovnih podataka iz bilo kakvih vrsta spremišta za podatke. To znači proces pomoću kojeg se otkrivaju podaci i omogućava izvođenje različitih analitičkih proračuna, kao što su analiziranje trendova i modeliranje podataka. Izvlači podatke iz relacija podataka i mapira ih u višedimenzionalni format, što omogućuje preciznu analizu i brzu obradu nad podacima. Ovaj proces koriste poduzeća kako bi dobili specifične informacije u što kraćem vremenskom periodu i pritom bile bolje pozicionirane za donošenje boljih, bržih i preciznijih poslovnih odluka. (Rungta, 2020, dostudno na: https://www.guru99.com/online-analytical-processing.html)

3. VIZUALIZACIJA PODATAKA

Podatak osnovna je sastavnica svakog poduzeća svijeta. Možemo reći da oni čine temelj povrh čega se gradi i razvija poduzeće. Nebitno da li se radi o velikim ili malim poduzećima svi ciljaju na jedan zajednički cilj, a to jest prikupljanje što više podataka. Prikupljanjem podataka poslovne organizacije poboljšavaju svoj položaj na tržištu, što znači da postaju veća konkurencija drugima. Oni koji raspolažu sa više podataka i informacija dobivaju prednosti nad svojim konkurentima. Raspolagati sa više podataka daje poduzećima više znanja i bolje razumijevanje trenutačne situacije u kojoj se nalazi, na temelju čega dolazi do izrade naprednijih analiziranja i donošenje boljih poslovnih odluka.

Korištenjem sustava poslovne inteligencije poduzeća raspolažu različitim metodama i alatima za pribavljanje i obradu podataka. Pojedini alati ili metode koje smo naveli razvijaju i pomažu poduzeću svaka na svoj način. Rudarenje podataka i ETL služe za prikupljanje raznih podataka, OLAP za izvođenje različitih operacija nad podacima, izvještavanje metoda za prikupljanje i prezentiranje podataka i brojne druge. Svaka od ovih alata/metoda ima svoju ulogu u poslovnoj inteligencije, međutim najveću i najbitniju ulogu ima vizualizacija podataka.

Vizualizaciju podataka možemo definirati kao vizualni prikaz određene skupine podataka. Podaci se mogu prikazivati pomoću različitih vrsta grafikona, bilo to kružnih, linijskih, stupčastih ili nekog drugog oblika vizualizacije. Ona pretvara podatke u informacije koje su bitne poduzeću. Naveli smo razne metode prikupljanja podataka, međutim svi ti podaci nepotrebni su poduzeću ako ih pravilo ne upotrijebi. Kod svakog velikog poduzeća podaci se spremaju u bazu podataka, koja se sastoji od mnoštva tablica sa preko tisuću i tisuću podataka. U takvoj situaciji teško je uočiti vezu između pojedinih podataka i zaključiti koji podaci su zapravo značajni a koji nisu. Unatoč tom problemu razvili su se brojni alati za vizualizaciju podataka, kako bi mogli iskoristiti informacije kojima raspolažemo na što učinkovitiji način. (Bentley, 2017, str. 246)

3.1 POVIJESNI RAZVOJ VIZUALIZACIJE PODATAKA

Vizualizacija podataka igra veliku ulogu kroz povijest čovječanstva. Definirali smo da je vizualizacija vizualni prikaz određene skupine podataka. U današnje vrijeme kad razmatramo pojam vizualni prikaz mislimo na neku vrstu grafikona, interaktivnog sučelja, tablice ili slično. Međutim vizualizacija jest bilo kakav oblik pretvaranja sirovih podataka u slikovit prikaz. Bilo to prikaz podataka o poslovanju nekog poduzeća ili prikaz ilustracije ili animacije svakodnevnog života ljudi. Ti podaci za neku osobu imaju veliko značenje, dok su za drugu totalno nepotrebni. Važnost podataka ne igra nikakvu ulogu prilikom vizualizacije. Njen osnovni cilj jest jednostavnije shvaćanje podataka, jer ljudskom mozgu lakše je shvatiti podatke prikazane vizualno, nego u obliku složenih sirovih statističkih podataka. To je tehnika koju oduvijek ljudi koriste u svrhu stjecanja znanja.

Kada bismo razmatrali povijest vizualizacije ne možemo točno definirati od kada je ona počela i kako se razvijala. Razlog tome jest jer je uvijek postojala još za vrijeme kamenog doba. U kamenom dobu kada su ljudi živjeli u pećinama koristili su određene „tehnike vizualizacije“. Na zidovima pećina prikazivali su način njihovog života, kako su ljudi živjeli u to razdoblje, način preživljavanja, prikaz lova, generalno njihov svakodnevni život. Tu se javljaju prvi znakovi vizualizacije.

Kroz stoljeća postepeno se razvijao proces vizualizacije. Prvi znakovi razvoja javljaju se u drugom stoljeću u Egiptu, gdje je nastala prva tablica podataka, koja se upotrebljavala u astrološke svrhe. Kroz ovo razdoblje vizualizacija se koristila za stjecanje osnovnih informacija o našem svijetu. Koristili su je moreplovci za izradu geografskih karata svijeta, brojna carstva za prikaza gradova, zemljišta, resursa, razni znanstvenici za prikazivanje svemira, zvijezda i slično.

Nakon pojave prve industrijske revolucije počinju se razvijati oblici vizualizacije kakve i danas poznajemo. Ovim razdobljem prevladavaju brojni statističari koji svojim znanjem unapređuju svijet. Iz tog razloga prevladava potražnja za prikupljanjem velikih količina podataka. Razvijaju se brojne statističke teorije i različiti načini prikazivanja podataka. Podaci se prikazuju pomoću grafikona kako bi se lakše uočile razlike između njih. Raste potražnja za boljem mapiranjem geoloških i medicinskih podataka i preciznijim fizičkim mjerenjima. U kartografiji javlja se tematsko mapiranje, kako bi se prikazalo više od samog zemljopisnog položaja i brojno drugo.

Velika prekretnici dogodila se drugom polovicom dvadesetog stoljeća pojavom računala. Ovo je razdoblje gdje se vizualizacija rasprostranila diljem svijeta. Postala je jedna od osnovnih područja razvoja. Razvoj računala dao je statističarima razne mogućnosti prikupljanja i pohranjivanja velikih količina podataka, te bržu i jednostavniju vizualizaciju. Razvijaju se brojni alati, softveri i aplikacije koji dodatno olakšavaju cjelokupan proces vizualizacije. Oni daju ljudima i poduzećima nove mogućnosti za stjecanje i prikupljanje podataka. Stvaraju se brojni paketi i proširenja kako bi se nadogradile aplikacije i time postale još bolje.

Cijeli proces vizualizacije do danas nadograđuje se sve brže i brže. Alati postaju sve bolji i jednostavniji za korištenje, otkrivaju se nove metode prikupljanja, pohranjivanja, obrađivanja i analiziranja podataka. Samim time potražanja za vizualizacijom u svakodnevnom životu raste i nastavljat će rasti, jer živimo u razdoblju gdje su ljudima

potrebne ogromne količine podataka. Raspolaganjem takvom masom podataka ljudima su nužne metode i alati koji će im pomoći kod obrade i vizualizacije tih podataka.
(Friendly,2008,dostupno:https://www.researchgate.net/publication/226400313_A_Brief_History_of_Data_Visualization)

3.2 PREDNOSTI VIZUALIZACIJE PODATAKA U PODUZEĆIMA

Poslovna inteligencija sastoji se od sedam dijelova, točnije šest metoda i jednog alata. Svaka od njih pridonosi poduzeću na određeni način i pomaže u cjelokupnom razvoju. Danas najvažniju ulogu za svako poduzeće igra vizualizacija podataka i jedan od njegovih osnovnih dijelova, što jest dizajniranje dashboarda.

Velike količine podataka neizbježan su faktor za napredak poslovanja u poduzećima. Na temelju kvalitetnih informacija, poduzeća mogu znatno brže i preciznije reagirati na trenutnu situaciju u kojoj se nalaze. U tom pogledu vizualizacija igra ključnu ulogu. Kao što smo već spomenuli, imati masu podataka ne znači nužno dobro za poduzeće. Važno je znati sa kakvim podacima poduzeće raspolaže. Neki podaci mogu imati malo ili nikakve koristi za odvijanje kvalitetnog poslovanja u poduzeću. Kako bi imali koriste i kvalitetne informacije koristimo vizualizaciju, za pretvorbu velikih količina podataka u koristan i razumljiv izvještaj. Navesti ćemo nekoliko prednosti koje vizualizacija omogućuje poduzećima.

Jednostavnije shvaćanje podataka

Jedna je od osnovnih prednosti vizualizacije. Baratanjem sa velikom količinom sirovih podataka često dovodi do pogrešnog tumačenja informacija i težeg tumačenja priče. Ljudski mozak funkcionira na način da će puno lakše shvatiti neku informaciju prikazanu u obliku slike nego u obliku dosadnih brojki i slova. Vizualizacija podataka možda nije najbolje rješenje za proces analitike, međutim pomoću nje korisnici stvaraju jednostavne slikovite izvještaje koji ubrzavaju osnovno razumijevanje podataka.

Brzo donošenje odluka

Na temelju spomenutog da ljudski mozak brže obrađuje slike od sirovih podataka, korištenje vizualizacije podataka u velikoj mjeri ubrzava proces donošenja odluka u poduzeću. Jednostavnijem i bržem shvaćanju podataka korisnici puno brže razumiju trenutnu situaciju poduzeća, što utječe na donošenje bržih i preciznijih odluka. Donošenjem bržih i preciznijih odluka pomaže poduzećima da se prilagode na trenutne promjene koje se događaju na tržištu i stjecaju prednost nad svojim konkurentima, što se sve ubiti svodi na stvaranje kapitala.

Praćenje trendova

Proučavanjem velikih količina podataka mogu se lakše uočiti promjene koje se trenutno dešavaju na tržištu i praćenje trendova. Praćenje trendova i promjena na tržištu jedna su od ključnih čimbenika svakog poduzeća. Ako poduzeće ne raspolaže nikakvim konkretnim informacijama što se trenutno zbiva na tržištu, stvaranje kapitala nije garantirano. Pomoću vizualizacije podataka poduzeće može otkriti najnovije trendove trenutno aktualne na tržištu. Na temelju toga poduzeće posluje kvalitetnijom robom, što uvjetuje stvaranju profita i stjecanju prednosti nad ostalom konkurencijom na tržištu.

Prikazuje odnos između operacija i rezultata

Jedna od prednosti vizualizacije podataka jest njegova transparentnost i vidljivost procesa koji su trenutno aktualni. Imajući uvid u procese korisnici mogu pratiti odnos između operacija i cjelokupnog procesa poslovanja poduzeća. Na temelju toga ako dolazi do određenih promjena u poslovanju, direktori ili poslovni menadžeri mogu brzo reagirati na nastale promjene. Primjerice ako na tržištu prodajemo robu i dolazi razdoblje gdje se prodaja naših proizvoda smanji za 20%. Pomoću vizualizacije podataka mi imamo trenutan uvid na poslovanje da je prodaja robe na tom tržištu opala. Pomoću te informacije možemo analizirati nastali problem i započeti sa formuliranjem plana.

Smanjuje vrijeme rada poduzeća

Korištenjem vizualizacije podataka ubrzava se djelovanje cijelog poduzeća. Ubrzavaju se operacije koje se izvode nad podacima. Puno lakše je pronaći potrebne informacije i shvatiti određene korelacije između podataka. Zaposlenicima olakšava proces pribavljanja potrebnih informacija i rad nad njim. Sastavljaju se bolji poslovni sastanci radi dizajniranja interaktivnih sučelja na brz i jednostavan način. Oni omogućuju zaposlenicima, direktorima i menadžerima da bolje razumiju trenutnu situaciju poduzeća. Na taj način jednostavnije je i brže donositi odluke za rad poduzeća, kako bi prevladavala bolja organizacija rada. Ako je poduzeće dobro organizirano, zaposlenici će puno brže obavljati svoj posao na efikasan način, što na kraju dovodi do stvaranja većeg kapitala i boljeg razvoja poslovanja u poduzeću.

(Zheng,2020,dostupnona: https://www.researchgate.net/profile/Jack_Zheng3/publication/327578825_Data_Visualization_IT_7113_Lecture_Notes/links/5e382a40299bf1cdb90a6025/Data-Visualization-IT-7113-Lecture-Notes.pdf);

(Atha, 1021, dostupno na: https://www.kdnuggets.com/2019/04/7-qualities-big-data-visualization-tools.html)

4. ALATI ZA VIZUALIZACIJU PODATAKA

Alati za vizualizaciju podataka su softveri koji olakšavaju korisnicima proces konstruiranja vizualne reprezentacije velikih količina podataka. Kada radimo sa skupovima podataka na bilo koji način, stvaranja vizualne slike u znatnoj mjeri olakšava posao korisnicima. Svako poduzeće sadržava određeno spremište za podatke. Razvojem tehnologije ta spremišta postaju sve bolja, boljih performansa, koja omogućuju sve veću i veću pohranu podataka. Najčešće je riječ o bazama podataka. Raspolaganjem tolikim podacima javlja se potreba za softverima koji će olakšati proces obrađivanja informacija. Jasno je da korisnici neće prolaziti kroz tisuće i tisuće podataka za prikupljanje određene informacije. To je vrlo spor i nepraktičan način rada. Iz tog razloga javlja se tolika potražanja za vizualizacijskim alatima.

Kako tehnologija postaje sve brža i bolja, time i alati za vizualizaciju. Aplikacije koje danas koristimo za razliku od onih prije, postale su znatno bolje. Implementiraju se grafička sučelja koja su korisnicima puno jednostavnija za korištenje. Svaka aplikacija sastoji se od vodiča i pripadne dokumentacije u kojoj vodi korisnika kroz cijelu aplikaciju, kako bi se dodatno olakšao način korištenja. Performanse aplikacija postaju bolje. Omogućuju bolju povezanost i znatno veću pohranu podataka. Time se povećava mogućnost prikaza većeg broja informacija u nekom obliku vizualne prezentacije. Rad sa aplikacijama postaje brži, sadržavaju više funkcija, više metoda i više značajki za prikaz informacija. Zahvaljujući njima korisnicima je lakše strukturirati interaktivna sučelja i obavljati rad nad podacima.

Često se postavlja pitanje, koji je alat za vizualizaciju najbolji za korištenje? Konkretnog odgovora na to pitanje nema. Postoji veliki broj aplikacija od kojih je svaka dizajnirana na specifičan način. Ne postoji aplikacija koja uključuje sve opcije za rad nad podacima. Odabire se ona vrsta softvera koja je potrebna poduzeću. Dali je potrebna aplikacija sa velikim rasponom opcija analiziranja i prikazivanja podataka, aplikacija koja omogućava pohranu i prikaz pojedinih informacija ili pak nešto drugo. Svaki od njih ima svoje prednosti i mane.

Veliku ulogu pri odabiru aplikacije igra cijena. Nije isto da li smo odabrali alat za vizualizaciju koji je besplatan za razliku od onog koji košta. Postoji mnoštvo besplatnih aplikacija, međutim one imaju većinom dosta ograničenu mogućnost korištenja. Nemaju toliko mogućnosti za razliku od onih koji koštaju. To ne znači da ih trebamo u potpunosti izbjegavati. Tehnologija je toliko napredovala da većina besplatnih aplikacija sadržava dovoljno opcija koje su potrebne kupcima. Ako aplikacija zadovoljava sve kriterije koje kupac traži, logično je da će odabrati onu koja je besplatna. Međutim ako je riječ o velikom poduzeću koji raspolaže sa masom različitih podataka, tada se upotrebljavaju visoko kvalitetni alati za vizualizaciju.

Prilikom uporabe visoko kvalitetnih alata za vizualizaciju potrebno je pripaziti na minimalne zahtjeve koji su potrebni za pravilno funkcioniranje alata. U današnje vrijeme ovo nije preveliki problem radi razvoja visoko optimiziranih tehnologija, međutim svejedno potrebno je pripaziti. Neki alati sadržavaju napredne operacija za prikazivanje i obradu podataka. Oni zahtijevaju veći memorijski prostor i bolje strukturiran hardware kako bi mogli nesmetano funkcionirati.

4.1 OSNOVNE FUNKCIONALNOSTI ALATA ZA VIZUALIZACIJU PODATAKA

Spomenuli smo da prilikom odabira alata za vizualizaciju podataka, kupac bira onaj alat koji mu najbolje zadovoljava određene zahtjeve. Svi alati imaju jedan zajednički cilj, što jest generirati vizualni prikaz velikih količina podataka na što jednostavniji način. Ne postoji savršen alat za vizualizaciju, međutim od njih se očekuje da zadovoljavaju neke od osnovnih značajka koje bi trebao imati svaki kvalitetan alat za vizualizaciju.

Jasna, precizna i prilagodljiva sučelja

Dashboard ili interaktivno sučelje osnovni je dio svakog alata za vizualizaciju. Korisniku omogućuje detaljan pregled nad svim prikupljenim podacima koje želi prezentirati. Bitno je da su sučelja konstruirana na jednostavan način, bez previše nepotrebnih informacija i boja, ali svejedno dovoljno za prikaz svih potrebnih informacija vezanih za poslovanja, praćenje trendova ili bilo kojih drugih važnih podataka. Mora biti kvalitetno strukturiran imajući sve podatke na jednom mjestu za prikazivanje. Što je sučelje preglednije i bolje dizajnirano to su podaci čitljiviji i jednostavniji za shvaćanje. Isto tako svako interaktivno sučelje mora biti prilagodljivo. To znači ako pratimo nekoliko različitih skupina podataka, da korisnik ima mogućnost prikazivanja određenih informacija za određenog klijenta.

Napredne operacije analitike

Alati za vizualizaciju podataka omogućuju korisniku vizualni prikaz velike količine podataka kako bi mogao donijeti određene poslovne odluke, pratiti trendove, pronaći odgovore na određene probleme i slično. Međutim ovo su sve informacije koje su generirane većinom od strane samog korisnika. Alati nam samo prikazuju vizualnu prezentaciju podataka, no samu odluku o stanju poslovanja poduzeća generirana je od strane korisnika na temelju promatranih informacija. Kako bi se olakšao ovaj proces

donošenje odluka, alati za vizualizaciju trebali bi imati različite funkcije i metode za podržavanje naprednih tehnika analitike.

Interaktivna izvješća

Na temelju prikupljenih podataka alat za vizualizaciju mora generirati interaktivna izvješća. Razlog tome jest da korisnik lakše prezentira pojedinu situaciju, što bi ubrzalo proces poslovanja u poduzeću. Primjerice korištenjem interaktivnih izvješća korisnik bi imao mogućnost mijenjanja, premještanja, grupiranja i filtriranja pojedinih varijabla. Ako grafički prikazujemo neki proces sa pripadajućim rezultatom, mijenjajući vrijednosti pojedinih varijabla ili promjenom čitave varijable, interaktivno sučelje trebalo bi automatski generirati novi rezultat na temelju promijenjenih vrijednosti. Ova metoda pomaže korisnicima u otkrivanju novih informacija i donošenju boljih poslovnih odluka koja su bitna poduzeću za rast i razvoj.

Prikupljanje i dijeljenje podataka

Svaki alat za vizualizaciju ima mogućnost uvoza i izvoza podataka. Problem do kojeg tu dolazi jest to što neki alati podržavaju različite oblike formatiranja dok drugi ne podržavaju. Ako alat ne podržava određeni format, korisnik je potreban podatke prebaciti u određeni oblik. Isto tako i kod izvoza rezultata. Neki alati omogućuju izvoz podataka u različitim formatima, dok drugi sadržavaju samo ograničenu količinu. Na temelju toga ako alat ne zadovoljava metode formatiranja koje su potrebne poduzeću za rad sa podacima, taj alat je nepotreban poduzeću. Razlog tome jest taj što bi gubili vrijeme na proces formatiranja dokumenata iz izvornog oblika u potrebni , kako bi ga mogli upotrebljavati za dalji rad. To je nepotrebno gubljenje vremena poduzeću i neisplati se unatoč ostalim prednostima koje im pruža dani alat. (Atha, 2019, dostupno na: https://www.kdnuggets.com/2019/04/7-qualities-big-data-visualization-tools.html)

4.2 NAJPOZNATIJI ALATI ZA VIZUALIZACIJU PODATAKA

Kada bi trebali odabrati najbolji alat za vizualizaciju podataka koji bi poboljšao poslovanje u našem poduzeću odabrali bi jednog od najpoznatijih koji se promoviraju na tržištu. To ne znači da su ujedno i najbolji alati, ali zasigurno jedni od boljih koji danas prevladavaju. Poduzeće bira onaj alat koji najbolje odgovara njegovom načinu rada. Ako se taj alat ne može prilagoditi sustavu poduzeća njega se odbacuje. Primjerice za korištenjem novog alata za vizualizaciju potrebni su optimalniji sustavi velikih brzina i boljeg memorijskog prostora. Time poduzeće treba prilagođavati sustav kako bi alat mogao pravilno funkcionirati, prilikom čega može doći do stvaranja drugih problema. Važno je proučiti zahtjeve koji su potrebni za normalan rad alata i ako je poduzeće u mogućnosti pružiti te zahtjeve bez stvaranja dodatnih problema odabire se taj alat. Bitno je da nabavljeni alat za vizualizaciju ne naruši ispravan rad svih ostalih softvera koji se koriste, kako ne bi došlo do pogoršanja a ne razvoja poduzeća.

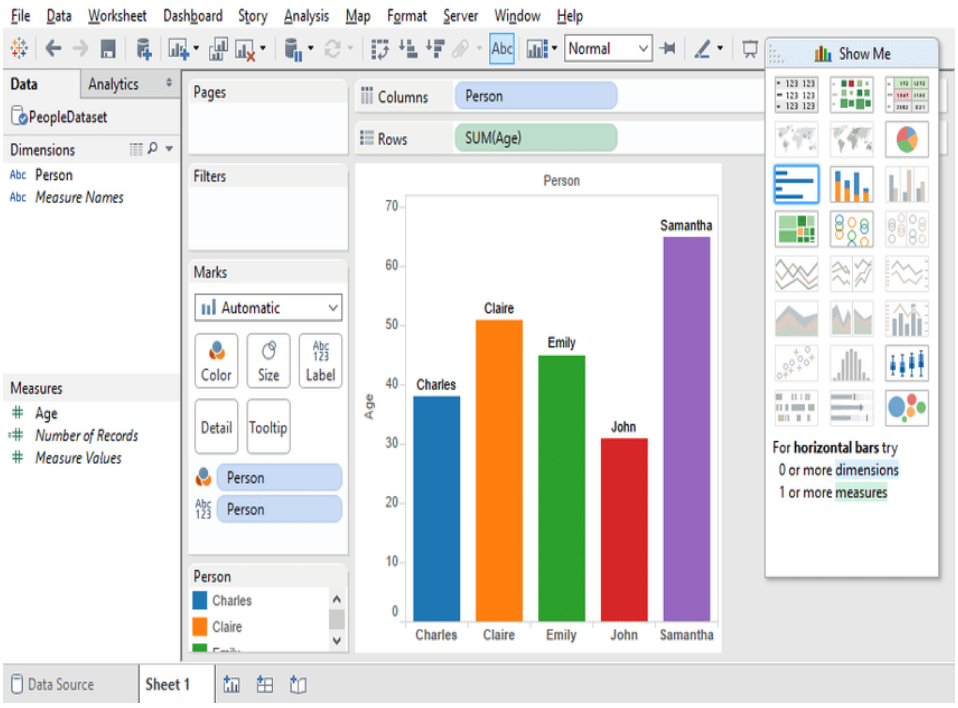
Navesti ćemo nekoliko najpoznatijih alata za vizualizaciju koji se danas u 2020. godini koriste. Omogućuju visoku razinu vizualizacije podataka uz niz mogućnosti i jedni su od najčešćih alata koje današnja poduzeća koriste u poslovanju. (Harkiran ,2020, dostupno na: https://www.geeksforgeeks.org/10-best-data-visualization-tools-in-2020/)

4.2.1 Tableau

Tableau je jedan od najpoznatijih vizualizacijskih softvera koji se nalaze na tržištu. Sastoji se od različitih softvera koji nadopunjuju jedan drugoga i omogućuju korisniku nesmetan i brz rad nad podacima. Njegova najbolja karakteristika jest vrlo brz rad nad podacima. Pretvara različite skupove podataka u jasan i razumljiv format. Omogućuje korisnicima da pripreme, očiste i formatiraju podatke u odgovarajući oblik te kreiraju jednostavnu vizualnu reprezentaciju. Njegova mogućnost vizualizacije konstruirana je na kvalitetan i vrlo jednostavan način, sa nizom vodiča koji korisnika vode kroz određeni softver. Performanse softvera vrlo su kvalitetne i dostupne gotovo svim sustavima, čak i mobilnim. Tableau sadrži softver za mobilne uređaje koji je ostvario

veliki prihod organizaciji. Omogućuje korisnicima lagan i uvijek dostupan pristup svojim podacima koji podržava gotovo sve funkcije kao i ostali softveri.

Način na koji Tableau funkcionira je sljedeći. Sastoji se od pet osnovnih verzija: Tableu Desktop, Public, Online, Server i Reader. Oni se međusobno nadovezuju gdje svaki od njih služi za obavljanje određene operacije. Tableu Desktop jest desktop aplikacija koja služi za vizualizaciju podataka i stvaranje izvješća. Ona jest osnovni softver i sam početak korištenja Tableau-a. Public daje korisnicima mogućnost da kreirana izvješća objave u javni oblak. To znači da će ta izvješća biti dostupna svakom korisniku na korištenje. Koristan alat koji omogućuje dijeljenje izvješća sa javnosti. Tableau server i online imaju sličnu ulogu kao public, međutim korisnikov rad neće biti dijeljen sa širom javnošću nego će biti objavljen na server, kojim mogu pristupiti samo ovlašteni korisnici. Jedina razlika između njih je to što se kod server verzije podaci direktno spremaju na server, dok se kod online verzije pohranjuju na poslužitelj u oblaku. Posljednja verzija jest Tableau reader. Besplatan alat kojemu je osnovna uloga pregled dokumenata nastalih u desktop verziji. Sadržava neke mogućnosti za rad nad podacima, međutim one su vrlo ograničene. (Rungta, 2020, dostupno na: https://www.guru99.com/what-is-tableau.html)

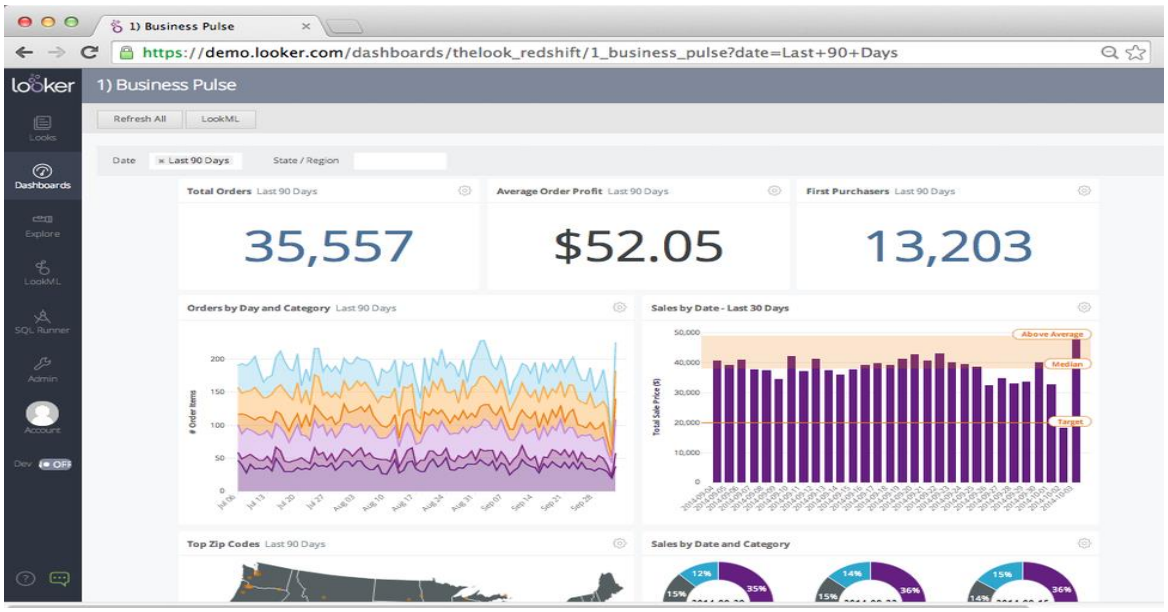


Slika 3. Grafičko sučelje Tableau Desktopa
Izvor: https://www.researchgate.net/figure/Tableau-Desktop-Interface_fig1_316652619 (Pristupljeno: 18.08.2020)

4.2.2 Looker

Napredan alat koji se koristi u poslovnoj inteligenciji. Za razliku od Tableau koji je više orijentiran na kvalitetnu vizualizaciju, Looker se više fokusira na pružanje kvalitetne analize i istraživanje podataka. Građen je na cloud platformi što znači da nije potrebno instaliranje aplikacije na radnu površinu, nego je softver izgrađen na web podlozi. Ima veliko razvijenu mogućnost analiziranja podataka. Sadrži svoj vlastiti jezik za modeliranje LookML koji je dosta sličan SQL-u. Brine se za pisanje čistih i razumljivih upita, koji omogućuju različite načine manipuliranja i analiziranja podataka. Korisnici mogu detaljno proučiti i istražiti odnose između različitih skupova podataka za otkrivanje potrebnih informacija. Prilikom analiziranja nije potrebno izdvajati podatke, oni lako ostaju spremljeni u bazi podataka. Kao rezultat ti podaci prikazuju se na interaktivnom sučelju u vizualnom obliku, kojeg možemo mijenjati ovisno o potrebi.

Proces analiziranja podataka zvuči dosta kompleksan međutim to nije tako. Alat je dovoljno funkcionalan i dizajniran na vrlo jednostavan način, da ga može svatko koristiti bez prevelikog znanja. Jedina mana koja se često javlja korištenjem Lookera jest njegova brzina izvođenja. Radi velike mogućnosti manipuliranja i rada nad podacima, sastavljanjem velikih složenih i kompliciranih upita alatu je potrebno dosta vremena za vraćanje rezultata. (Bien, 2017, dostupno na: https://looker.com/platform/overview)

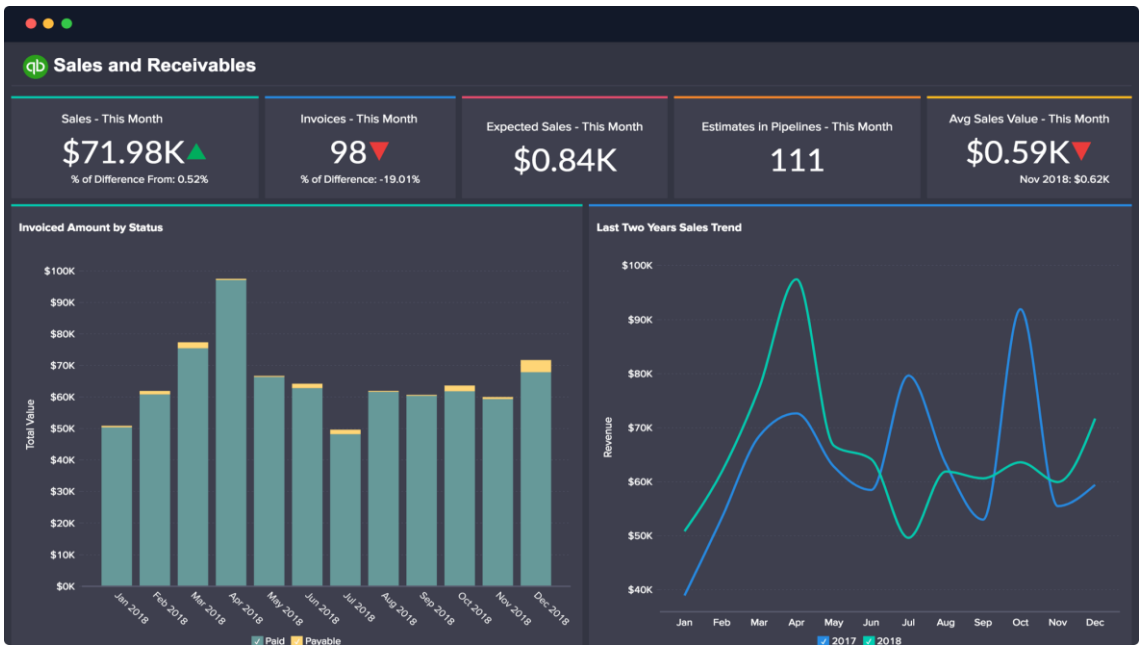


Slika 4. Interaktivno sučelje Looker-a
Izvor: https://www.softwareadvice.com/bi/looker-profile/ (Pristupljeno: 18.08.2020)

4.2.3 Zoho Analytics

Zoho Analytics alat je za vizualizaciju podataka građen na cloud poslužitelju isto kao Looker. Dostupan je svakom uređaju jedino što je korisniku potrebno da mu pristupi je internetska veza. Brz alat koji ima dobro razvijenu metodu vizualizacije za stvaranje predivnih grafova. Omogućuje korisnicima prikupljanje podataka iz više različitih izvora za stvaranje višedimenzionalnih vizualnih prikaza. Oni se prikazuju na grafičkom sučelju koji je dizajniran na jednostavan način bez previše nepotrebnih informacija. Kreiranje vizualnih prikaza vrlo je jednostavno u ovom alatu iz razloga jer sadrži dodatnu mogućnost kreiranja grafova. Sadrži drag-and-drop funkcionalnost, gdje korisnik samostalno gradi grafove bez potrebe za kodiranjem. Građen je na principu da pojednostavi analitiku podataka i fokusira se većinom na što jednostavniju vizualizaciju.

Jedna interesantna karakteristika Zoho Analytics-a po čemu se ističe od drugih alata vizualizacije jest korištenje umjetne inteligencije. Ako korisnik nailazi na neki problem prilikom korištenje softvera, Zoho Analytics ima pametnog asistenta zvanog Zia, koji pomaže korisniku u traženju rješenje. Možemo je smatrati vodičem koji nas vodi kroz softver i daje odgovore na naša pitanja. (Lambert, 2014, dostupno na: https://reviews.financesonline.com/p/zoho-analytics/)

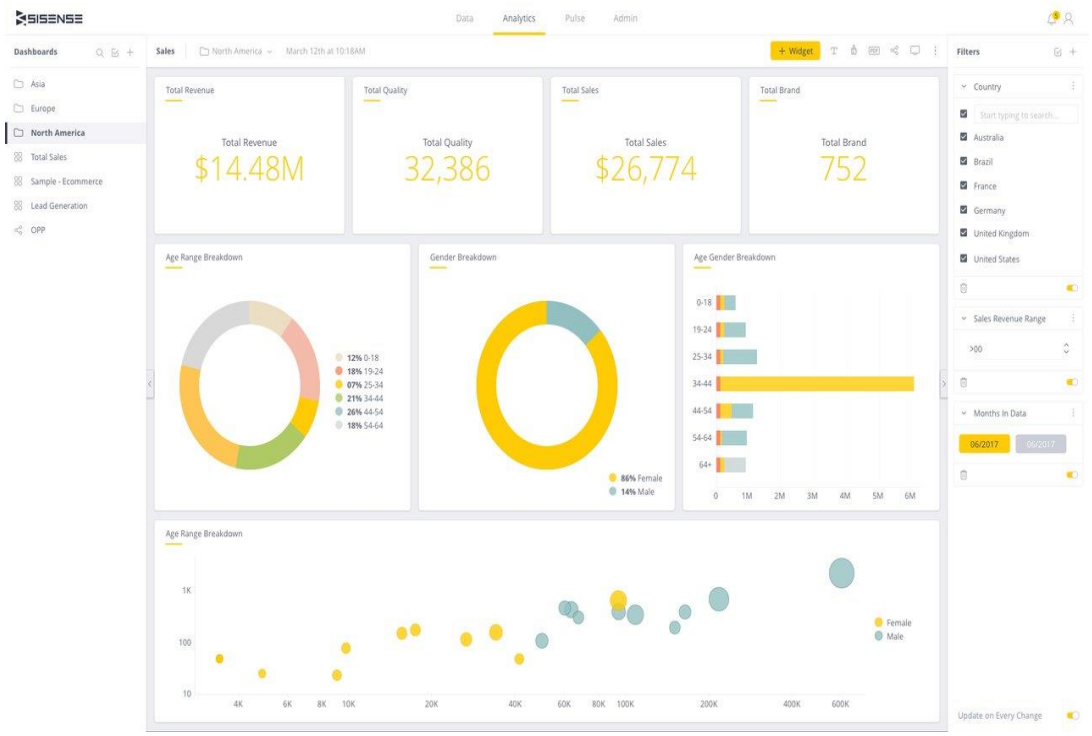


Slika 5. Grafičko sučelje Zoho Analytics-a
Izvor: https://www.zoho.com/analytics/financial-analytics.html (Pristupljeno: 19.08.2020)

4.2.4 Sisense

Sisense sustav vizualizacije podataka od ostalih alata ističe se po tome jer je konstruiran na vrlo jednostavan način, pružajući u isto vrijeme što bolju mogućnost vizualizacije i proces analiziranja podataka. Drži se pretpostavke „ da će na kraju svaka tvrtka bit tvrtka vođena podacima“, iz tog razloga malo više se oslanja na stranu unapređenja procesa analiziranja podataka i stvaranju što boljih funkcija za rad sa podacima.

Omogućuje prikupljanje podataka iz više različitih izvora koje se spremaju u jedno zajedničko spremište na relativno krakom vremenu, kojemu korisnik može pristupiti kada želi. Osnovna ideja iza toga jest da korisnik putem interaktivnog sučelja ima stalan pristup svim prikupljenim podacima, za dobivanje potrebnih informacija u određeno vrijeme. Na temelju toga poduzeće može odmah reagirati na promjene. Interaktivno sučelje dizajnirano je na način da ga može upotrebljavati svaka osoba. Sastoji se od brojnih drag-and-drop operacija za izradu interaktivne vizualizacije i raznih oblika formatiranja za isporuku svojih datoteka. (Lambert, 2017, dostupno na: https://financesonline.com/sisense-pros-cons-top-business-intelligence-software/)



Slika 6. Interaktivno sučelje Sisense softvera
Izvor: https://www.predictiveanalyticstoday.com/sisense/ (Pristupljeno: 20.08.2020)

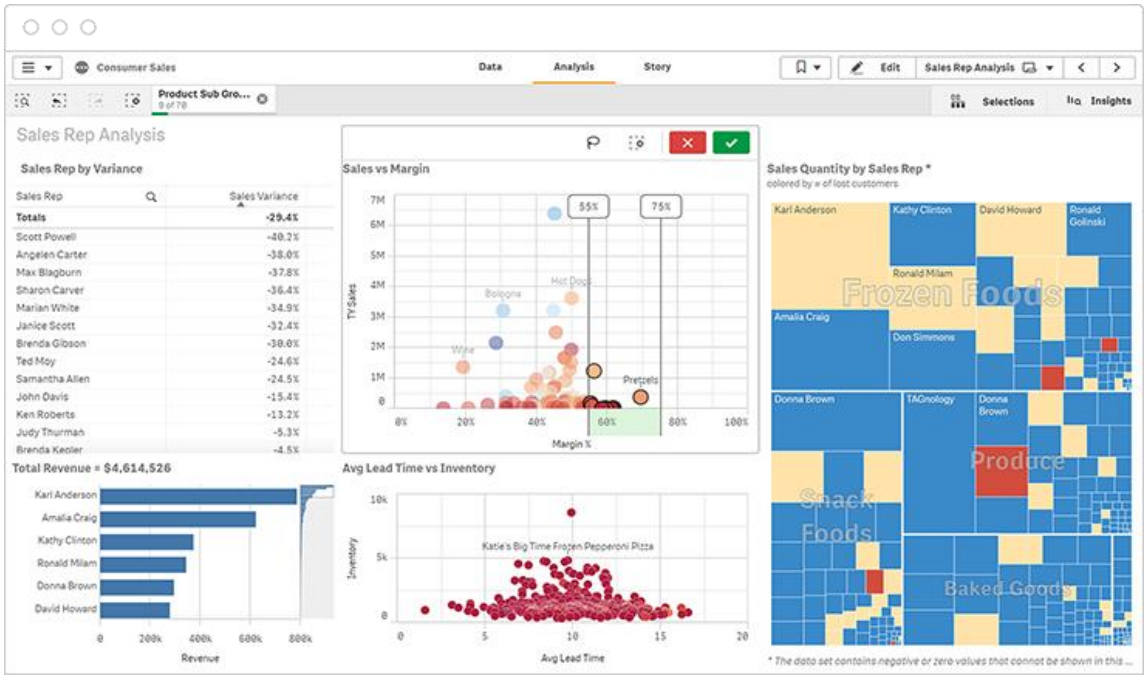
4.2.5 Qlik Sense

Qlik Sense također jedna od najpoznatijih vizualizacijskih softvera na tržištu i najveći konkurent Tableau-u. Pametan alat za vizualizaciju prilagođen korisnicima koji se sastoji od brojnih visoko kvalitetnih metoda vizualizacije, asocijativnih metoda analiziranja podataka, umjetne inteligencije i brojnih drugih karakteristika. Vrlo napredan alat koji omogućuje obrađivanje, istraživanje, i razne načine manipuliranja i prikazivanja ogromnih količina podataka.

Omogućuje spajanje podataka iz više različitih izvora i stvaranje jednostavnog interaktivnog vizualnog prikaza na temelju prikupljenih podataka, kojeg možemo mijenjati na svakojake načine za otkrivanje pojedinih veza i potrebnih informacija. Sastoji se od brojnih pomoćnih mehanizma za rad nad podacima kao što su razni oblici pretraživanja podataka pomoću ključne riječi, drag-and-drop opcije za generiranje grafova, ili ubacivanje podataka i brojnih drugih opcija koji omogućuju korisniku jednostavno obrađivanje podataka.

Interaktivno sučelje dizajnirano je na briljantan način, jednostavnog i odličnog dizajna za brzo i lako snalaženje. Sadrži veliki broj različitih vizualnih prikaza, drag-and-drop vizualizaciju, automatsko generiranje vizualizacije u slučaju promjene podataka, konstantan pristup analitici, skalabilnost informacija, kvalitetne funkcionalnosti pripovijedanja podataka i brojne druge mogućnosti. Jedna funkcija koju Quick Sense sadrži za razliku od drugih alata jest skalabilnost informacija. Mogućnost sažimanja informacija ovisno o veličini zaslona. To znači da će se veličina informacija prilagoditi tome koliko je podataka prikazano na zaslonu. Ako je zaslon veći, što znači više podataka, informacije će biti manjeg dizajna i obratno.

Ovo su neke od karakteristika Quick Sensa koje ga čine puno moćnijim alatom za vizualizaciju od drugih, ne uzimajući u obzir brojne druge mogućnosti kojima raspolaže, kao što su umjetna inteligencija, integriranje sustava i drugo. Međutim glavni razlog zašto Quick Sense prednjači nad svojim konkurentima jest njegova prilagodljivost i širok raspon značajki naspram drugih. (Lambert, 2017, dostupno na: https://reviews.financesonline.com/p/qlik-sense/)



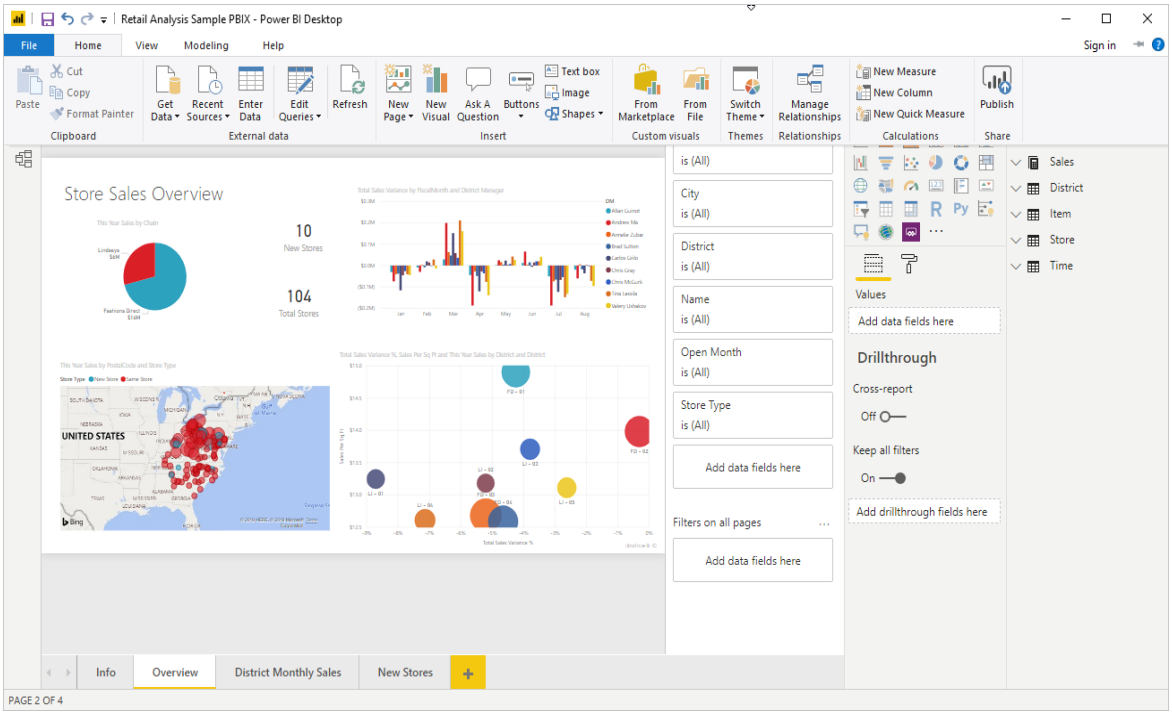
Slika 7. Interaktivno sučelje Qlik Sensa
Izvor: https://www.qlik.com/us/products/qlik-sense (Pristupljeno: 21.08.2020)

4.2.6 Microsoft Power BI

Power BI je Microsoftov skup alata koji služe za obavljanje poslovne analitike i vizualizaciju podataka zasnovana na oblaku. Osnovna uloga svih alata jest jednostavna pretvorba složenih podataka u korisne informacije. To se omogućuje zahvaljujući širokom spektru metoda koje pružaju alati. Korisnicima nude različite metode vizualizacije podataka, korisne funkcije za bolje snalaženje prilikom analiziranja podataka te neke mogućnosti umjetne inteligencije i integracije sustava.

Power BI alati imaju dobro razvijenu distribuciju. Dostupni su na različitim platformama bez prevelikih potrebnih resursa za pravilan rad. Omogućuju povezivanje podataka iz različitih izvora za sastavljanje personaliziranih izvješća i interaktivnih sučelja na brz i jednostavan način. Svi prikupljeni podaci pohranjeni su na jednom centraliziranom mjestu kojem možemo pristupiti kada želimo. Osnovni dizajn alata orijentiran je na Microsoftov način izgleda. Isto kao Microsoft World ili bilo koji drugi njegov alat, dizajnirani su na vrlo banalan način kako bi korisnicima omogućili što jednostavnije korištenje alata.

Jedan od osnovnih alata Power BI-a koji se danas aktualan jest Power BI Desktop. Besplatna aplikacija koju lako instalirate na bilo koju vrstu uređaja za obrađivanje, manipuliranje i vizualizaciju podataka. (Lambert, 2017, dostupno na: https://financesonline.com/pros-cons-of-microsoft-power-bi-analysis-of-a-leading-business-intelligence-software/)



Slika 8. Grafičko sučelje Power BI Desktopa
Izvor: https://docs.microsoft.com/en-us/power-bi/fundamentals/desktop-what-is-desktop (Pristupljeno: 21.08.2020)

4.2.7 Klipfolio

Klipofolio je Kanadska tvrtka koja je poznata za poslovnu inteligenciju i kreiranja kvalitetnih vizualizacijskih alata zasnovanih na oblaku. Ne može se uspoređivati sa alatima Qlik-a i Tableau-a, međutim kao što smo spomenuli ne postoji savršen alat za vizualizaciju jer svaki od njih prednjači na svoj način.

Alati Klipofila poznati su po svojim mogućnostima povezivanja. Pružaju brojne načine povezivanja podataka s različitim izvorima kao što su web stranice, društvene mreže, razna skladišta podataka, usluge i drugo. Ima dovoljno dobro razvijen proces

manipuliranja podacima. Većina alata ne sadrži napredne tehnike analiziranja, međutim sadržavaju sve potrebne opcije za lagan i brz rad sa podacima. Nastoje održati alate dosta jednostavnim za korištenje sa dobrim sposobnostima integriranja i stvaranja prilagodljivih interaktivnih sučelja.

Interaktivna sučelja dizajnirana su na način da prikazuju sve informacije na jasan i razumljiv način. Korisnik prikazuje podatke pomoću različitih oblika vizualizacije, koji su vrlo jednostavni za korištenje. Proces kreiranja vizualizacije bazira se na radu editora, pomoću kojih korisnik kreira grafikone povlačenjem i spuštanjem odgovarajućih dijelova na sučelje. Isto tako sučelja su jako prilagodljiva, korisnik može kontrolirati kako će podaci biti raspoređeni, koje veličine, fonta, boje i slično. Prilagođava ih na način koji njemu najviše odgovara za prezentiranje. (Bailey, 2015, dostupno na: https://www.amazeemetrics.com/en/blog/why-klipfolio-is-our-favorite-dashboarding-tool/)



Slika 9. Interaktivno sučelje alata Klipofila
Izvor: https://www.klipfolio.com/customer-support-reporting-tool (Pristupljeno: 21.08.2020)

4.3 PRIMJERI UGRAĐENE VIZUALIZACIJE „NON-VISUALIZATION“ ALATA

Vizualizacija je neophodan dio svakog velikog poslovanja. Potrebna je poduzećima za otkrivanje bitnih informacija kako bi prednjačili nad svojim konkurentima. Za dobivanje tih informacija kao što znamo koriste se brojni alati za vizualizaciju kojih danas ima na stotine. Postali su osnovni dio naše svakodnevnice i koriste se gotovo svugdje za lakše snalaženje i baratanje sa podacima. Potreba za tolikom vizualizacijom dovelo je do razvoja takozvanih „non-visualization“ alata. Riječ je o alatima koji prvenstveno nisu namijenjeni za stvaranje vizualne reprezentacije nego su nastale nadogradnje za te aplikacije pomoću kojih dobivaju tu mogućnost.

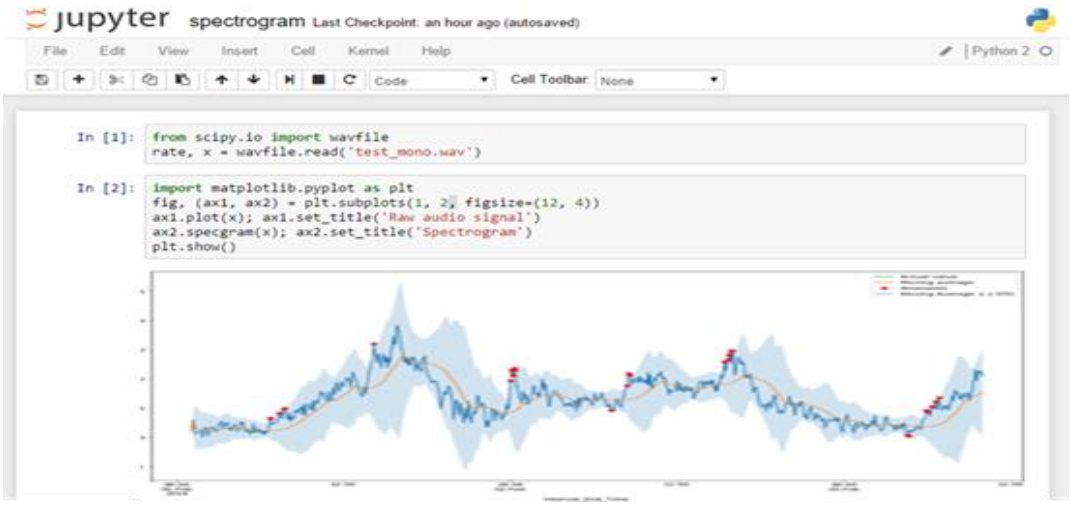
Kada govorimo o „non-visualization“ alatima, mislimo na alate koji služe za rad sa podacima. Ne možemo bilo koju vrstu alata nadograditi do te razine, nego samo alate koji se koriste za obavljanje različitih operacija nad podacima. To su primjerice različiti oblici programskih jezika ili neke vrste alata koji služe za spremanje podataka kao što su baze. Ljudi koji rade time aplikacija barataju samo sirovim podacima u obliku slova i brojki. Kada se nalaze u situaciji gdje je potrebno objasniti pojedine korelacije između podataka ili predstaviti najbitnije informacije javlja se problem. Te aplikacije sadrže opcije za dolaženje do tih informacija, međutim korisniku je puno jednostavnije doći do potrebnih informacija na način stvaranja vizualne slike nego pisanjem programskog koda. Puno je jednostavnije i lakše za shvaćanje, jer logično je da će korisnik lakše objasniti priču na temelju slike nego u obliku kompliciranog i nagomilanog programskog koda.

Postavlja se pitanje zašto u takvim situacijama poduzeće jednostavno ne uvede neke od alata za vizualizaciju? To jest jedno od mogućih rješenje, međutim uzmimo za primjer da se radi o relativno malom poduzeću koji još nema dovoljno resursa za nabavu takvih materijala. Kako ne bi došlo do poremećaja u načinu radu takvog poduzeća stvaraju se pojedine nadogradnje u obliku paketa, biblioteka ili različitih proširenja, pomoću kojih se aplikacije nadograđuju i dobivaju potrebne opcije vizualizacije. Time poduzeće nema potrebe za nabavom ostalih alata čuvajući potrebne resurse i rješavanjem problema. Navesti ćemo nekoliko vrsta „non-visualization“ alata koji su dosta zastupljeni u današnje vrijeme.

4.3.1 Jupyter Notebook

Jupyter Notebook je web aplikacija koja služi za pisanje otvorenog koda putem weba. Vrlo je kvalitetan program za pisanje programskog koda, koji korisniku omogućuje obavljanje složenih računskih operacija, manipuliranja podacima, modeliranje, stvaranju simulacija, gotovo bilo kakvog oblika rada nad podacima. Koristi se na način instaliranja desktop aplikacije Jupyter Notebook koja korisnika usmjerava na web preglednik za pisanje i dijeljenje programskog koda. Sučelje Jupyter Notebook-a kao što samo ime govori, nalikuje na izgled bilježnice. Korisnik može programski kod lijepo strukturirati na pojedine odjeljke, radi lakšeg snalaženje u kodu.

Sadrži kvalitetne metode za manipuliranje podacima, dijeljenje podataka i stvaranja vizualizacije. Aplikacija je prvenstveno kreirana za obavljanje složenih računskih operacija i brzog programiranja, međutim nakon kreiranjem pojedinih proširenje u obliku biblioteka koje korisnik može jednostavno instalirati pomoću jedne linije koda, dobila je različite mogućnosti stvaranja kvalitetnih oblika vizualizacije. Primjer toga jest biblioteka „ipycytoscape“, koja omogućuje korisnicima stvaranje vizualne reprezentacije složenih mreža. Ploty biblioteka koja omogućava stvaranje različitih oblika grafikona ili interaktivnih slika direktno u Jupyter Notebook-u. Pandas i Numpy jedne od najkorištenijih biblioteka koje služe za manipulaciju podataka i stvaranje vizualnih reprezentacija i razne druge. (Perkel, 2018, dostupno na: https://www.nature.com/articles/d41586-018-07196-1)

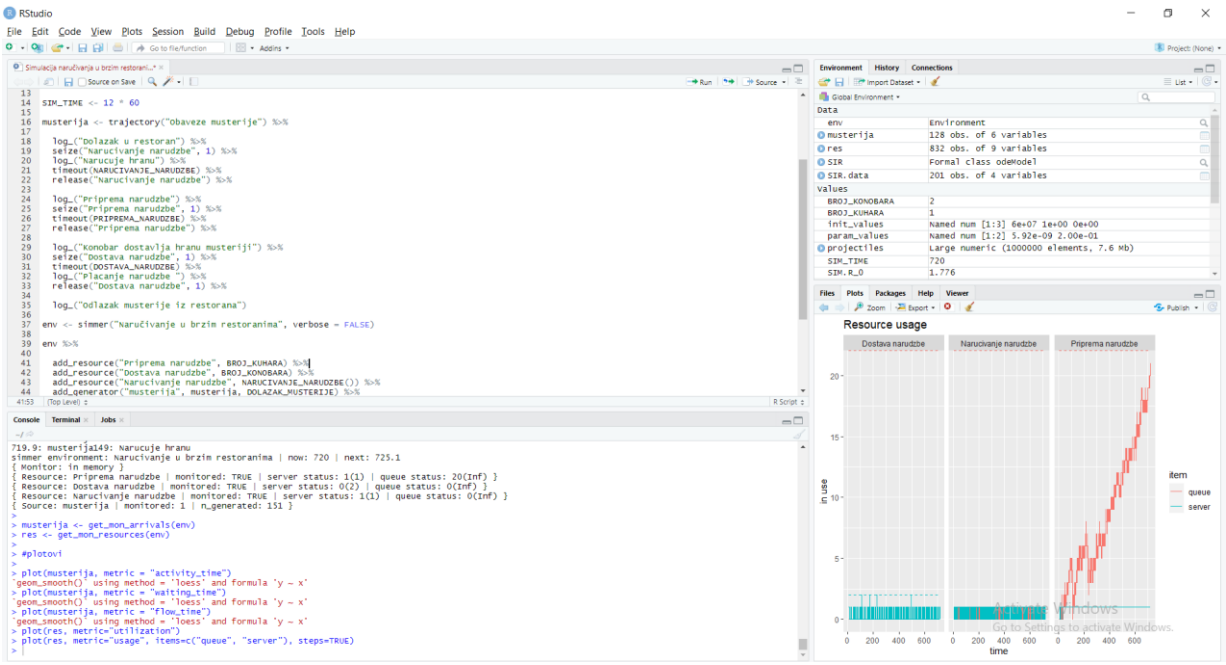


Slika 10. Primjer vizualizacije u Jupyter Notebook-u
Izvor: https://docs.aws.amazon.com/iotanalytics/latest/userguide/data-visualization.html (Pristupljeno: 23.08.2020)

4.3.2 R Studio

R Studio je integrirano razvojno okruženje pisano u Javi dostupan različitim operacijskim sustavima za pisanje programskog koda. Koriste ga većinom statističari za obavljanje složenih statističkih proračuna i grafičko prikazivanje podataka. Grafičko sučelje aplikacije sastoji se od glave podloge za pisanje programskog koda, terminala za prikazivanje rezultata, brojnih programskih traka za prikazivanje podataka u vizualnom obliku i različitih složenih operacija, alata, funkcija i paketa koje omogućavaju izvođenje složenih računskih operacija nad podacima.

Korištenjem paketa odnosno biblioteka korisnici dobivaju dodatne operacije za rad nad podacima kao što je proces vizualizacije. Evo konkretnog primjera kojeg sam napravio prilikom kreiranja simulacije naručivanja hrane u brzim restoranima. Koristio sam biblioteku Simmer i Simmer plot, moćne biblioteke koje se koriste za prikazivanje računarskih simulacija. Pomoću njih napravio sam simulaciju naručivanja hrane u brzim restoranima i podatke prikazao u vizualnom obliku za jednostavnije razumijevanje procesa. Podatke prilikom stvaranja simulacije možemo mijenjati da dobijem drugačiji vizualni prikaz poslovanja i bolje razumijevanje nad time koliku važnost ima pojedini podataka za poslovanje. Programski jezik vrlo je prilagodljiv i možemo mijenjati gotovo svaku varijablu za otkrivanje potrebnih informacija.

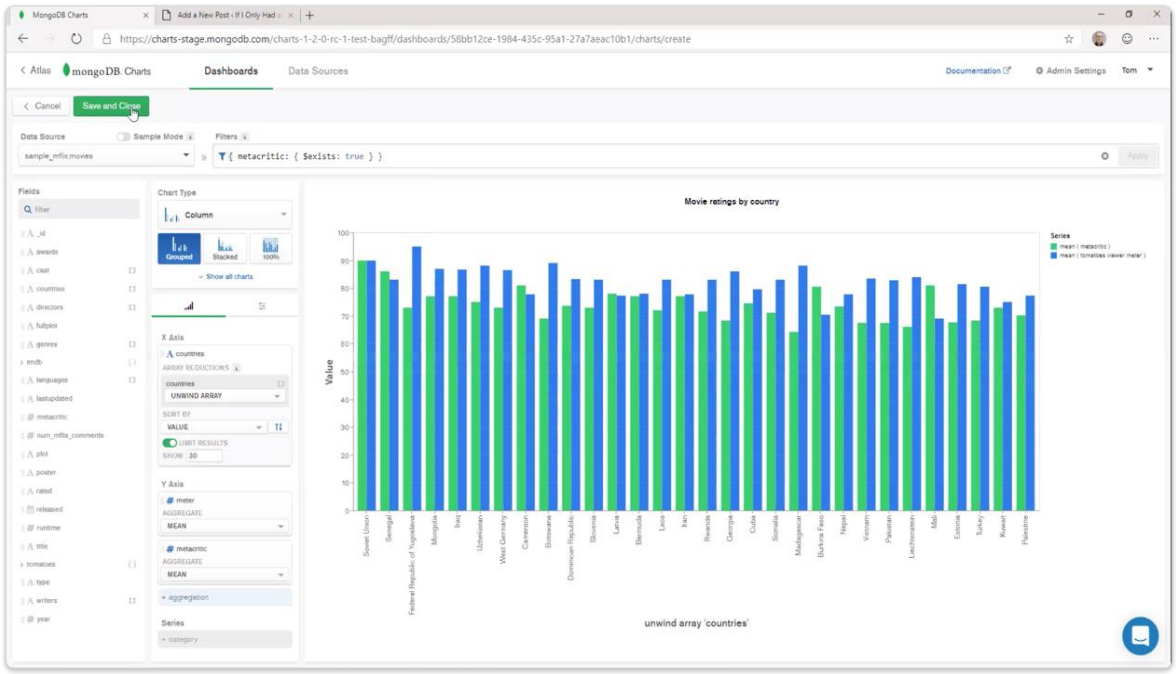


Slika 11. Primjer simulacije naručivanja u brzim restoranima

4.3.3 MongoDB

MongoDB je kvalitetna NoSQL baza podataka što znači da pohranjuje podatke u drukčijem formatu za razliku od ostalih baza podataka koji funkcioniraju na principu relacijskih tablica. Podaci koji se spremaju u bazu pohranjeni su u JSON formatu, radi lakšeg i boljeg korištenja. Sastoji se od različitih softvera koji korisnicima omogućuju pohranjivanje podataka. Od desktop aplikacije za pohranjivanje podataka, dizajnirana na jednostavan i razumljiv način do web preglednika koji omogućuje pohranu podataka putem clouda. Ima dobro razvijen sigurnosni sustav, razne mogućnosti za dijeljenja i brojne operacije za rad nad podacima.

Velika potražnja za vizualizaciju i analiziranje podataka razvilo je proširenje u sustavu MongoDB-a koje se zove MongoDB Charts. To je proširenje koje se koristi za jednostavnu vizualizaciju podataka pohranjenih u MongoDB bazu. Vrlo je jednostavna za korištenje i sadržava sve osnove potrebne za prikaz dobre vizualizacije. Sastoji se od brojnih operacija za analiziranje podataka, kako bi se lakše shvatili korelacije između podataka i osnovnih metoda za kreiranje dobrih vizualnih reprezentacija prikazanih na nadzornoj ploči. (Alger, 2018, dostupno na: https://www.mongodb.com/blog/post/visualizing-your-data-with-mongodb-charts)

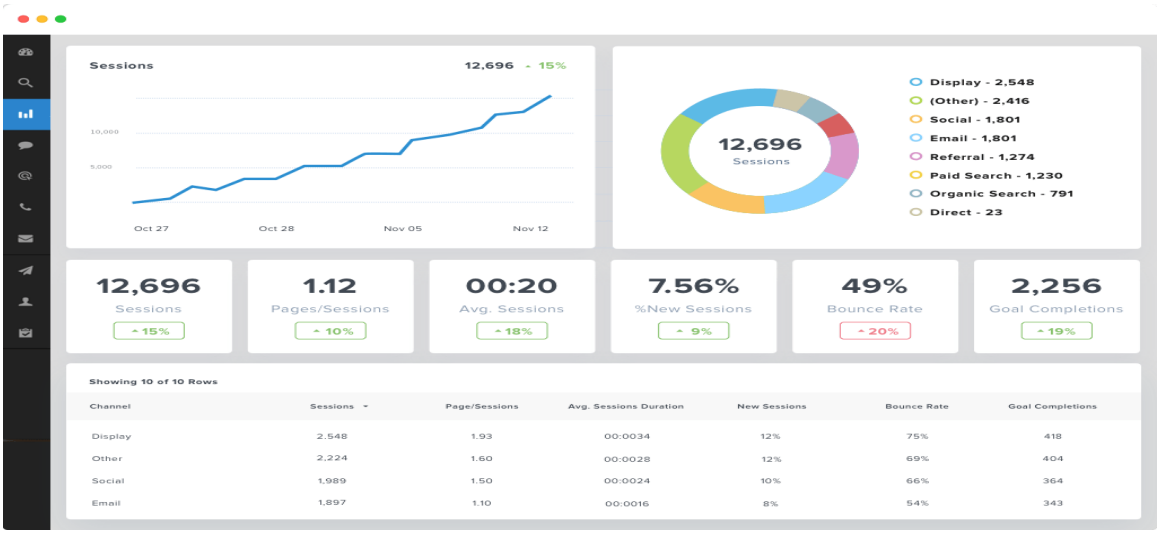


Slika 12. Grafičko sučelje MongoDB Charts-a
Izvor: https://www.mongodb.com/products/charts (Pristupljeno: 25.08.2020)

4.3.4 Google Analytics

Google Analytics je web usluga koja pruža Google za analiziranja i praćenje podataka na web stranici. Besplatna je usluga koja se sastoji od nekoliko funkcija za praćenje digitalnog poslovanja. Vrlo se često koristi radi svoje jednostavnosti i brzoj instalaciji. Sve što je potrebno napraviti kako bismo imali pristup podacima jest ubaciti nekoliko linija koda u našu web stranicu. Ta kod jest zapravo neka vrsta ključa kojeg mi ugrađujemo u našu web stranicu. Pomoću njega povezujemo uslugu Google Analytics-a sa našom web stranicom čime dobivamo pristup podacima korisnika.

Pomoću Google Analytics-a dobivamo uvid nad svim akcijama koje korisnici naše web stranice obavljaju. Koliko korisnika posjeti našu stranicu, koliko često, koje su najpregledanije stranice i općenito cijeli promet vezan za korisnika na stranici. Pomoću tih podataka dobivamo osnovne informacije potrebne za donošenja odluka o poboljšanju pojedinih stranica. Iako Google Analytics nije prvenstveno alat namijenjen za vizualizaciju, svejedno koristi neke od oblika vizualizacije podataka. Sastoji se od nekoliko osnovnih vizualnih prikaza kao što su tablični izvještaji, prikaz različitih vrsta grafikona, prikaz performansa pojedinih stranica za uspoređivanje pregledanosti, korištenje „pivot“ tablica za otkrivanje različitih trendova i slično. Pomoću tih metoda Google Analytics pomaže korisnicima u proces analiziranja podataka i donošenje boljih odluka. (Su, 2017, dostupno na: https://medium.com/analytics-for-humans/what-is-google-analytics-and-why-is-it-important-to-my-business-8c083a9f81be)



Slika 13. Sučelje Google Analytics-a
Izvor: https://agencyanalytics.com/feature/google-analytics-dashboard (Pristupljeno: 26.08.2020)

5. ZAKLJUČAK

U ovom radu objašnjen je cjelokupni proces poslovne inteligencije, kakav je njen utjecaj na poduzeća, što im omogućuje, načini na koje poduzeća upotrebljavaju poslovnu inteligenciju za dobivanje bitnih informacija i prednosti koje ona daje. Objašnjavajući proces korištenja poslovne inteligencije u poduzećima dolazimo do pojave osnovnih metoda i alata koji se upotrebljavaju za dobivanje informacija. Objasnili smo sedam osnovnih metoda poslovne inteligencije za prikupljanje i analiziranje podataka i jedan od najbitnijih alata koji se koristi u procesu vizualizacije podataka. Svaka od tih metoda pridonosi poduzeću za prikupljanje i analiziranje podataka. Raspolaganjem boljim i kvalitetnijim informacijama, klijentima daje bolji uvid u cijeli proces poslovanja i praćenje trendova na tržištu. Na taj način stvaraju prednost nad svojim konkurentima što dovodi do stvaranja boljeg kapitala i razvoja poduzeća.

Kao posljednja i najbitnija metoda poslovne inteligencije predstavljena je vizualizacija podataka. Današnja poduzeća raspolažu masom podataka što dovodi do problema prenatrpanosti. Zaposlenicima je teško snalazite se kroz gomilu podataka i filtrirati samo najbitnije podatke za donošenje odluka. Za rješavanje ovog problema koristi se vizualizacija kao jedna od ključnih i najbitnijih metoda svakodnevice. Proces vizualizacije olakšava analiziranje podataka i stvara kvalitetne i brze vizualne prezentacije na interaktivnim sučeljima. Omogućuje filtriranje i pretvaranje velikih količina podataka u korisne informacije za dobivanje kvalitetnih i razumljivih izvještaja. Pojednostavljuje i ubrzava rad cijelog poduzeća, kako bi djelovalo na što učinkovitiji način i raspolagalo što boljim i kvalitetnijim informacijama. Cijeli proces vizualizacije svodi se na stvaranja boljih izvještaja na temelju kojih se organiziraju poslovni sastanci za jednostavnije prezentiranje pojedinih situacija, otkrivanju aktualnih trendova, shvaćaju korelacija između podataka, boljeg i bržeg donošenje odluka i generalno smanjenju cjelokupnog rada koji se obavlja u poduzeću.

Nakon definiranja pojma i prednosti koje vizualizacija pruža poduzeću, objasnili smo alate pomoću kojih se omogućuje proces vizualizacije. Postoji velika količina alata za vizualni prikaz podataka, od vrlo kvalitetnijih prema slabijima. Svaki od njih ima svoje prednosti i nedostatke. Neki alat može prednjačiti u procesu analitike podataka dok drugi prednjači različitim metodama i funkcijama vizualizacije. Poduzeća biraju onu vrstu alata koji joj najviše odgovara. Ako alat zadovoljava sve potrebne zahtjeve

poduzeća i ako poduzeće raspolaže svim resursima za pravilno funkcioniranje alata, bira se taj alat.

Svaki alat za vizualizaciju mora posjedovati nekoliko osnovnih karakteristika. Grafičko sučelje alata mora biti dizajnirano na jasan, jednostavan i precizan način. Interaktivna sučelja moraju biti dosta jednostavna i pohraniti dovoljnu količinu informaciju. Moraju sadržavati osnovne operacije za analiziranje, dijeljenje i prikupljanje podataka iz više različitih izvora, te generirati prilagodljiva i interaktivna izvješća. To su neke od osnovnih karakteristika koje svaki kupac traži od alata za vizualizaciju.

Prilikom biranja alata veliku ulogu igra cijena. Većina najpoznatijih alata koji se danas koriste dosta su skupi međutim oni pružaju velike mogućnosti analiziranja i vizualizacije podataka. To su alati koji većinom koriste velika poduzeća zbog potrebe za visokom kvalitetom rada nad podacima. Ako se radi o relativno malim poduzećima oni većinom biraju besplatne alate za vizualizaciju koji su također dosta učinkoviti, no oni za razliku od alata koji se plaćaju imaju dosta ograničene performanse i mogućnosti. Postoji i treća vrsta alata koji su se razvili radi velike potrebe za vizualizacijom. To su alati koji prvenstveno nisu namijenjeni za stvaranje vizualne slike, međutim zahvaljujući brojnim proširenjima i paketima dobivaju tu mogućnost.

Možemo zaključiti da je proces vizualizacije podataka jedan neophodan dio u današnjem svijetu. Živimo u razdoblju gdje se tehnologija razvija iz dana u dan, podataka je sve više i više, pa samim time raste i potreba za što većom i boljom vizualizacijom. Ljudima je znatno lakše shvatiti neku informaciju prikazanu vizualno nego u obliku sirovih podataka. Iz tog razloga smatram da će potreba za vizualizacijom i dalje rasti. Ona je jedna od osnovnih grana koje bi trebalo imati svako poduzeće za stvaranje što boljeg oblika poslovanja, stjecanju što bolje pozicije na tržištu i generalno što boljem rastu i razvoju.

Sažetak

U ovom radu govorimo o tome što je poslovna inteligencija, vizualizacija podataka i različitim alatima vizualizacije. U početku definiramo poslovnu inteligenciju, koje je njegova osnovna uloga, što omogućava poduzećima i koje su osnovne metode

poslovne inteligencije. Definira se čemu služi pojedina metoda i kakav ima utjecaj na poduzeća. Posljednja metoda vizualizacija podataka razrađena je detaljnije radi njene velike potražnje u današnjem svijetu. Zašto je došlo do tolike potrebe za vizualizacijom, što je ona, proces razvoj vizualizacije i prednosti koje omogućuje poduzećima? Navedeni su alati koji se koriste u procesu vizualizacije. Što su oni, čemu služe i koje su karakteristike svakog dobrog alata za vizualizaciju? Prikazano je nekoliko primjera najpoznatijih alata koji se danas koriste. Za svakog je dan po jedan primjer vizualizacije i navedene prednosti koje posjeduje nad drugim alatima. Za kraj objašnjena je neophodna potreba za vizualizacijom i dani primjeri koji pokazuju da vizualizacija ima toliki utjecaj na svijet, da se javlja potreba za razvojem dodatnih nadogradnji kako bi pojedini alati dobili mogućnost vizualizacije.

Ključne riječi: poslovna inteligencija, vizualizacija podataka, alati za vizualizaciju

Summary

In this paper we talk about what is business intelligence, data visualization and various visualization tools. At the beginning we define business intelligence, what is its basic role, what enables companies and what are the basic methods of business intelligence. It is defined what each particular method is for and what impact it has on companies. The latter method of data visualization has been elaborated in more detail due to its high demand in today's world. Why has there been so much need for visualization, what it is, the development process of visualization and the benefits it provides to companies? There are listed several tools used in the visualization process. What are they, what are they for and what are the characteristics of any good visualization tool? Several examples are shown of the most famous tools used today. For each, there is one example of visualization and the stated advantages it has over the other tools. At the end the necessary need for visualization is explained with some given examples that show, that visualization has such an impact on the world, that there is a need to develop additional upgrades to give certain tools the ability to visualize.

Key words: business intelligence, data visualization, visualization tool

6. LITERATURA

1. MIT Software, „Općenito o BI sustavima“, Internet, link: https://www.mit-software.hr/usluge/bi/bi1/, (Pristupljeno: 01.08.2020)
2. Sysed Junaid Hussain, „What is Big Dana & why is Big Dana important in today's era“, Internet, link: https://medium.com/@syedjunaid.h47/what-is-big-data-why-is-big-data-important-in-todays-era-8dbc9314fb0a) (Pristupljeno: 01.08.2020)
3. Mary K. Pratt, Josh Fruhlinger, „What is business intelligence? Transforming data into business insighs“, Internet, link: https://www.cio.com/article/2439504/business-intelligence-definition-and-solutions.html, (Pristupljeno: 01.08.2020)
4. Michael J. Sazlor, “Business Intelligence The Definite Guide, Internet, link: https://www.microstrategy.com/us/resources/introductory-guides/business-intelligence-the-definitive-guide (Pristupljeno: 01.08.2020)
5. Bergen Adair, „What are the diffrent types of BI types“, Internet, link: https://www.selecthub.com/business-intelligence/key-types-business-intelligence-tools/, (Pristupljeno: 02.08.2020)
6. Allan Wille, Klipfolio, „What is a data dashboard“, Internet, link: https://www.klipfolio.com/resources/articles/what-is-data-dashboard , (Pristupljeno: 02.08.2020)
7. Sandra Durevic, „Get the most out of smart BI Reporting“, Internet, link: https://www.datapine.com/blog/business-intelligence-reporting/ , (Pristupljeno: 03.08.2020)
8. Sriram Parthasarathy, „What is predictive analytics“, Internet, link: https://www.logianalytics.com/predictive-analytics/what-is-predictive-analytics/, (Pristupljeno: 03.08.2020)
9. Reuben Yonatan, „How to leverage PA in your BI solutions“, Internet, link: https://www.dundas.com/resources/blogs/how-to-leverage-predictive-analytics-in-your-business-intelligence-solutions, (Pristupljeno: 03.08.2020)
10. Nidhi Agrawal, „Role of ETL in BI“, Internet, link: https://www.mantralabsglobal.com/blog/etl-in-business-intelligence/, (Pristupljeno: 03.08.2020)

11. Mark Van Rijeman, Datafloq, „BI vs Data Mining“, Internet, link: https://datafloq.com/read/bi-data-mining-whats-the-difference-how-used/5698, (Pristupljeno: 04.08.2020)
12. Krishna Rungta, Guru99, „What is OLAP?Cube,Operations & Types in DW“, Internet, link: https://www.guru99.com/online-analytical-processing.html, (Pristupljeno: 04.08.2020)
13. Telmo Silva, „The role of Data Vizualization“, Internet, link: https://www.clicdata.com/blog/what-are-bi-data-visualization-data-analytics/, (Pristupljeno: 05.08.2020)
14. Michael Friendly, „A brief history of data visualization“, Internet, link: https://www.researchgate.net/publication/226400313_A_Brief_History_of_Data_Visualization, (Pristupljeno: 10.08.2020)
15. Harkiran, „10 best data vizualization tools in 2020“, Internet, link: https://www.geeksforgeeks.org/10-best-data-visualization-tools-in-2020/, (Pristupljeno: 12.08.2020)
16. Ali Allage, „9 amazing benefits of DV every business needs to know“, Internet, link: https://boostlabs.com/9-benefits-of-data-visualization/, (Pristupljeno: 12.08.2020)
17. Hiral Atha, „7 Qualityes your BDVT absolutely must have“, Internet, link: https://www.kdnuggets.com/2019/04/7-qualities-big-data-visualization-tools.html, (Pristupljeno: 15.08.2020)
18. J.G.Zheng, „Data vizualization for Analytics and Business Intelligence“, Internet, link: https://www.researchgate.net/profile/Jack_Zheng3/publication/327578825_Data_Visualization_IT_7113_Lecture_Notes/links/5e382a40299bf1cdb90a6025/Data-Visualization-IT-7113-Lecture-Notes.pdf, (Pristupljeno: 15.08.2020)
19. Krishna Rungta, „What is Tableau? Uses and applications“, Internet, link: https://www.guru99.com/what-is-tableau.html, (Pristupljeno: 18.08.2020)
20. Daniel Mintz, „What are the advantages and disadvantages of using Looker as an BI tool“, Internet, link: https://www.quora.com/What-are-the-advantages-and-disadvantages-of-using-Looker-as-an-BI-tool , (Pristupljeno: 19.08.2020)
21. Frank Bien, „Experience the perks of the platform“, Internet, link: https://looker.com/platform/overview, (Pristupljeno: 20.08.2020)

22. Sebastian Lambert, „Zoho Analytics review“, Internet, link: https://reviews.financesonline.com/p/zoho-analytics/, (Pristupljeno: 20.08.2020)
23. Sebastian Lambert, „Sisense: Pros and cons of the top BIS“, Internet, link: https://financesonline.com/sisense-pros-cons-top-business-intelligence-software/, (Pristupljeno: 21.08.2020)
24. Sebastian Lambert , „Qlick Sense Review“, Internet, link: https://reviews.financesonline.com/p/qlik-sense/, (Pristupljeno: 22.08.2020)
25. Sebastian Lambert , „Pros and cons of Microsoft Power BI“, Internet, link: https://financesonline.com/pros-cons-of-microsoft-power-bi-analysis-of-a-leading-business-intelligence-software/, (Pristupljeno: 23.08.2020)
26. Chris Bailey, „Why Klipofilo is our favourite dashboarding tool“, Internet, link: https://www.amazeemetrics.com/en/blog/why-klipfolio-is-our-favorite-dashboarding-tool/, (Pristupljeno: 24.08.2020)
27. Ken W. Alger, „Vizualizing your data with MongoDB Charts“, Internet, link: https://www.mongodb.com/blog/post/visualizing-your-data-with-mongodb-charts, (Pristupljeno: 25.08.2020)
28. Jeffrey M. Perkel, „Why Jupyter is data scientists computional notebook of choise“, Internet, link: https://www.nature.com/articles/d41586-018-07196-1, (Pristupljeno: 26.08.2020)
29. Bill Su, „What is Google Analytics, and why is it important to my business?, Internet, link: https://medium.com/analytics-for-humans/what-is-google-analytics-and-why-is-it-important-to-my-business-8c083a9f81be, (Pristupljeno: 27.08.2020)
30. Drew Bentley, „Business Intelligence and Analytics“, Internet, link: https://www.pdfdrive.com/business-intelligence-and-analytics-e56416503.html

Popis slika

Slika 1. Prikaz interaktivnog sučelja u poslovanju ……6
Slika 2. Prikaz proces ETL u poduzećima ……9
Slika 3. Grafičko sučelje Tableau Desktopa……..21
Slika 4. Interaktivno sučelje Looker-a……22
Slika 5. Grafičko sučelje Zoho Analytics-a……23
Slika 6. Interaktivno sučelje Sisense softvera……..24
Slika 7. Interaktivno sučelje Qlik Sensa……26
Slika 8. Grafičko sučelje Power BI Desktopa……...27
Slika 9. Interaktivno sučelje alata Klipofolia……..28
Slika 10. Primjer vizualizacije u Jupyter-Notebook-u……..30
Slika 11. Primjer simulacije naručivanja u brzim restoranima……31
Slika 12. Grafičko sučelje MongoDB Charts-a……32
Slika 13. Sučelje Google Analytics-a……33