

**SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
VARAŽDIN**

Erna Golubić

**IZRADA PREDIKTIVNIH MODELA U
MARKETINGU**

DIPLOMSKI RAD

Varaždin, 2018.

SVEUČILIŠTE U ZAGREBU
FAKULTET ORGANIZACIJE I INFORMATIKE
V A R A Ž D I N

Erna Golubić

Matični broj: 44794/16–R

Studij: Ekonomika poduzetništva

IZRADA PREDIKTIVNIH MODELA U MARKETINGU

DIPLOMSKI RAD

Mentor:

Izv. prof. dr. sc. Damir Dobrinić

Varaždin, rujan 2018.

Erna Golubić

Izjava o izvornosti

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

Autorica potvrdila prihvaćanjem odredbi u sustavu FOI-radovi

Sažetak

U diplomskom će radu biti prikazana i objašnjena izrada prediktivnih modela u marketingu kako bi kompanije bile u mogućnosti predvidjeti ponašanje kupaca u budućnosti. Za stvaranje modela vrlo je bitna prediktivna analitika koja postaje nezaobilazna u analizi postojećih podataka te predviđanja budućnih nepoznatih događaja. Cilj rada je analizirati kako veliki podaci (Big Data) zajedno s analitikom mogu ponuditi organizacijama impresivne mogućnosti za poboljšanje učinkovitosti. Na primjeru Amazona je objašnjeno kako je postao najveći svjetski online trgovac putem analize podataka te sustava preporuke i personalizirane ponude.

Ključne riječi: prediktivni modeli, prediktivna analitika, veliki podaci(Big Data)

Sadržaj

Sadržaj	iii
1.UVOD	1
1.1.Predmet i cilj rada.....	1
1.2.Metodologija rada.....	1
1.3.Sadržaj rada.....	1
2.POJAM PREDIKTIVNOG MARKETINGA	3
2.1Prediktivni marketing kao alat povećanja marketinške produktivnosti	4
2.2.Povijest korištenja prediktivne analitike u marketingu	5
3. PREDIKTIVNA ANALITIKA	7
3.1.Prediktivna analitika u marketingu	9
3.2.Razlozi korištenja prediktivne analitike.....	10
3.3.Metode i alati prediktivne analitike	11
3.4.Postavljanje prediktivne analitike u poslovanje	14
3.5.Budućnost prediktivne analitike	16
4.PREDIKTIVNI MODELI PREDVIĐANJA PONAŠANJA KUPACA	17
4.1.Izrada prediktivnih modela	18
4.2.Koristi prediktivnog modela.....	19
4.2.1.Prediktivno modeliranje povećava odgovor kupaca.....	20
4.3. Utvrđivanje i praćenje životnog vijeka kupaca.....	21
4.4. Pronalazak profitabilnog kupca.....	21
4.5.Stvaranje dugoročnih odnosa s kupcima	23
4.6.Životna vrijednost kupca	25
4.6.1.Određivanje životne vrijednosti kupca	26
5.KORIŠTENJE VELIKE KOLIČINE PODATAKA (BIG DATA) U PREDIKTIVNOJ ANALIZI 28	
5.1.Pojmovno definiranje velikih podataka (Big Data)	28
5.2. Posjedovanje podataka unapređuje poslovanje	30
5.3.Odnos između Big Data i prediktivne analitike	31
6.KORIŠTENJE UMJETNE INTELIGENCIJE U KREIRANJU PREDIKTIVNH MODELA	33
6.1.Povijest umjetne inteligencije.....	33
6.2.Umjetna inteligencija poboljšava prediktivnu analitiku.....	34
6.3.Personalizirane marketinške strategije.....	35
6.4.Prednosti i izazovi personaliziranog marketinga	36
7.PRIMJER AMAZON	38
8.ZAKLJUČAK	40
Popis literature	41

Popis slika	43
Popis tablica	43
Popis grafikona	43

1.UVOD

1.1.Predmet i cilj rada

Predmet ovog rada je izrada prediktivnih modela u marketingu kako bi kompanije bile u mogućnosti predvidjeti ponašanje kupaca u budućnosti. Za stvaranje prediktivnog modela, vrlo je bitna i prediktivna analitika koja postaje nezaobilazna u analizi postojećih podataka te predviđanja budućnih nepoznatih događaja. Cilj ovog diplomskog rada je analizirati kako veliki podaci (Big Data) zajedno s analitikom mogu ponuditi organizacijama impresivne mogućnosti za poboljšanje učinkovitosti. Isto tako, cilj je na primjeru Amazona prikazati kako je postao najveći svjetski online trgovac putem analize podataka te sustava preporuke i personalizirane ponude.

1.2.Metodologija rada

Kod izrade teorijskog dijela diplomskog rada korištena je stručna i znanstvena domaća i inozemna literatura dostupna u tiskanom, odnosno on-line izdanju. Također su korišteni Internet portali kao izvor podataka. Uz sve to, naveden je primjer Amazona s ciljem da se približi kako pojam prediktivnih modela u marketingu izgleda u praksi. Korišteni su podaci s Interneta te stručna literatura.

1.3.Sadržaj rada

Diplomski rad čini osam međusobno povezanih poglavlja. Prvo poglavlje čini uvod u kojem će biti objašnjeni predmet i cilj rada, izvori podataka i metode prikupljanja, te sadržaj i struktura rada. Drugo poglavlje pod nazivom Pojam prediktivnog marketinga želi dati uvid u glavni zadatak marketinga, a to je pružiti odgovarajuću ponudu, odgovarajućem (pravom) kupcu u odgovarajuće vrijeme te na odgovarajućem mjestu. Treće dio rada pod nazivom Prediktivna analitika nastoji približiti kako danas sofisticirani alati za poslovnu inteligenciju i rudarenje podataka (Data Mining) vuku podatke iz skladišta podataka ili Big Data baza podataka i omogućuju da menadžeri nisu prepušteni sami sebi nego da donose odluke na temelju obrađenog znanja u sustavu koje se generira metodama podatkovne analitike. Četvrto poglavlje zove se Prediktivni modeli predviđanja ponašanja kupaca koje objašnjava

kako se pomoću modela podaci mogu koristiti objektivnije te kako mogu pomoći u određivanju kupaca koji će ponoviti kupnju. Peto poglavlje će dati uvid u korištenju velikih podataka (Big Data) u prediktivnoj analitici. Šesti dio rada pod nazivom Korištenje umjetne inteligencije u izradi prediktivnih modela objašnjava kako je upravo ona postala vrlo bitan dio tehnološke industrije te pokazuje kako stvara sustave koji automatiziraju ljudske poslove poput odlučivanja, rješavanja problema i učenja. Sedmo poglavlje analizira primjer iz prakse Amazon koji pokazuje izvrstan način kako je postao najveći svjetski online trgovac putem sustava preporuke. Osmi dio rada čini zaključak u kojem će se navesti svi zaključci autora ovog diplomskog rada.

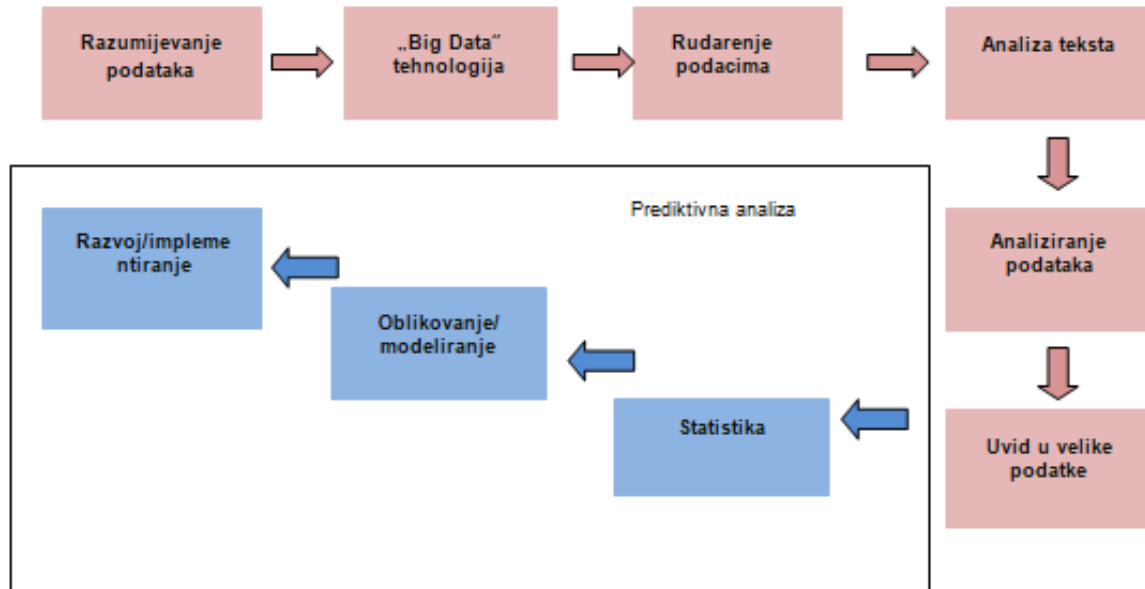
2. POJAM PREDIKTIVNOG MARKETINGA

Prije svega potrebno je objasniti i naglasiti značenje same riječi prediktivnost. To je novi alat poslovnog odlučivanja koji omogućuje punu iskoristivost skrivenih znanja Big Data baza podataka. (Zekić-Sušac, 2018)

Uz to se veže prediktivni marketing koji je zapravo praksa izdvajanja podataka iz postojećih baza podataka o kupcima kako bi se predvidjeli budući ishodi i trendovi. Isto tako, prediktivni marketing je marketinška tehnika koja uključuje korištenje analize podataka, a zatim i korištenje te analize kako bi se utvrdilo koje marketinške strategije i radnje imaju najveću vjerojatnost uspjeha. Tvrtke koriste opće poslovne podatke, podatke o marketingu i prodaji, te matematičke algoritme kako bi odredili najprikladnije kriterije za svoje sljedeće marketinške akcije. Tvrtke koje koriste ovu strategiju nastoje donositi odluke temeljene na podacima kako bi dali što bolje rezultate. (Galetto, 2018.)

Različite definicije marketinga u svojoj osnovi polaze od naglašavanja osnovnog zadatka marketinga da pruži odgovarajuću ponudu, odgovarajućem (pravom) kupcu u odgovarajuće vrijeme i na odgovarajućem mjestu. Stvaranjem baza podataka kupaca otvara se mogućnost predviđanja njihovog budućeg ponašanja. Modeli predviđanja, koji su se u praksi koristili i prije pojave današnje tehnologije, prema Hughes-u (2006:308) svoju opravdanost temelje na osnovnoj premisi da potencijalni i postojeći kupci reaguju na predvidljiv način. Kako bi se uspješnost marketinga povećala nastoji se predvidjeti ponašanje kupaca. Prikupljeni podaci u prošlosti i sadašnjosti koriste se kako bi se predvidjelo ponašanje u budućnosti. Radi se o prediktivnoj analizi koja predstavlja prognozu koja traži korelaciju između prošlih i budućih događanja. Rezultat tih analiza su prediktivni modeli. (Finlay, 2015: 4)

Razvoj tehnologije velikih podataka uz korištenje tehnika prediktivne analize dovodi do prediktivnog marketinga koji se definira kao način razmišljanja u kreiranju i uspostavi odnosa s kupcima. Sinergije tehnologije velikih podataka i prediktivne analize pojašnjava kako prediktivni marketing polazi od razumijevanja podataka. To je razumijevanje preduvjet korištenja tehnologije velikih podataka koja se koristi za rudarenje podacima. Pomoću statistike veliki podaci se oblikuju i modeliraju kako bi dobivene podatke korisnik u završnoj fazi implementirao u poslovanje što je prikazano na slici 1. (Tole, 2013.)



Slika 1. Shema provedbe prediktivnog marketinga (Tole, 2013.)

Prema Artun, Levin (2015;20) kako navodi Dobrinić(2017.), za provedbu prediktivnog marketinga potrebno je:

- Kontinuirano učenje o kupcima/klijentima što uključuje prikupljanje podataka i izradu korisničkih profila
- Analiziranje informacija o klijentima i predikcija njihovog ponašanja u budućnosti
- Koristiti informacije za podizanje profitabilnosti marketinga

2.1 Prediktivni marketing kao alat povećanja marketinške produktivnosti

Razloga i prednosti za korištenje prediktivnih modela ima više. Finlay, (2015:12) navodi tri osnovne: brzina, bolje i kvalitetnije prognozirane te dosljednost. Kada se prediktivni modeli koriste kao dio automatiziranog sustava donošenja odluka, milijuni kupaca mogu se rješavati i vrednovati u samo nekoliko sekundi. Prediktivni modeli omogućavaju bolje prognozirane i predviđanje nego ljudi te su dosljedniji nego ljudi. Određeni prediktivni model uvijek će generirati ista predviđanja kada se prikažu s istim podacima, što nije slučaj kod ljudi koji donose takve odluke.

Upravo na ove prednosti upozorava Finlay (2015:50) kada se raspravlja o etičkom problemu korištenja podataka za potrebe spoznaje ponašanja ljudi. Upozorava na činjenicu

kako ljudi gube kontrolu nad donošenjem odluka, odluke na temelju modela donosi računalo, a demografski se podaci mogu zlorabiti. Činjenica koju se ne može zanemariti je da tvrtke prediktivne analize koriste radi vlastite koristi (povećanje marketinške produktivnosti – povećanje profita), beneficije kupaca/klijenata koji u tome sudjeluju pri tome ipak nisu u njihovom primarnom fokusu.

Hughs (2006:180) navodi da su opravdanost i razlozi izrade prediktivnog modela za potrebe ciljanog marketinga: prepoznavanje kupaca i potencijalnih kupaca koji su skloni kupnji, kao i onih koji nisu skloni kupnji, prepoznavanje kupaca koji žele ostati i kupaca koji žele otići te saznanje o proizvodima koje kupci žele kupovati. Sama ideja o formiranju modela bazira se na jednostavnim principima: kupci se ponašaju na predvidljiv način, jednostavni demografski podaci nisu dovoljni za prediktivnu analizu te da se modeli predviđanja temelje na rezultatima prijašnjih kampanja. (Hughs, 2006:180)

2.2.Povijest korištenja prediktivne analitike u marketingu

Prema Fagella (2018.) prediktivna analitika u marketingu bi bila usvojena godinama prije da je računalna snaga bila sveprisutnija jer bi i podaci bili pristupačniji, a softver bi se lakše koristio. Danas se pojam „prediktivna analitika“ stalno čuje, nakon praćenja marketinga gotovo 30 godina unatrag.

Prediktivni marketing omogućuje tvrtkama da dobiju više informacija o svojim postojećim klijentima kako bi identificirali obrasce za predviđanje ishoda i trendova definiranja budućih predviđanja marketinga. Kao što objašnjava MarTech stručnjak Doug Karr, to nije nova praksa, ali je mnogo jednostavnija od one koja je zahtijevala nekoliko tjedana ili mjeseci korištenja alata ekstrakta, transformacije i opterećenja za prikupljanje podataka iz različitih izvora. A sve to kako bi izgraditi jedan resurs za analizu i bodovanje perspektiva na temelju njihove sličnosti s pravim kupcima. (Galetto, 2018.)

Kako tvrdi Zhang (2017: 98) sve više i više kompanija počinju koristiti prediktivnu analitiku kako bi stekli prednost nad svojim konkurentima. Kako se ekonomski uvjeti pogoršavaju, prediktivna analitika je odličan način kako doći do prednosti. Danas ona postaje sve dostupnija za manje kompanije, zdravstvene ustanove ili manje, niskobudžetne organizacije. Razlog tome je taj što se volumen lako dostupne baze podataka drastično proširio, korištenje računala je postalo dostupnije i moćnije te je sami software postao jednostavniji za korištenje. Stoga, osoba ne mora biti matematičar kako bi bila sposobna koristiti dostupnu tehnologiju.

Tri glavna čimbenika dovela su do pravog boom efekta odnosno porasta prometa predviđanja u marketingu. Uključujući masivne količine podataka kojima mogu pristupiti iz svih raspoloživih izvora tu su još i pristup podacima u realnom vremenu kao i uvođenje cloud computinga koji pruža veliku količinu podataka. Sada kada su alati točniji i sofisticirani, marketinški stručnjaci imaju pristup boljim rezultatima i mogu mjeriti oglase i izvore publike kako bi izradili kampanje s predvidljivim odgovorima. Budući da su alati postali dostupni i same tvrtke počinju uviđati vrijednost i prednosti ovog pristupa upravljanjem podacima, postoji pomak prema usvajanju tehnike: Karr izvještava da 68% anketiranih ispitanika tvrdi da vjeruju da će to biti kritički dio njihovog marketinga, a 82% tvrtki koje tvrde da su predane prediktivnom ocjenjivanju također gledaju u nju. (Galetto, 2018.)

3. PREDIKTIVNA ANALITIKA

Zekić-Sušac (2018.) navodi kako intuicija više nije dovoljna, posebno ako se konkurencija neke tvrtke oslanja na sofisticirane alate za poslovnu inteligenciju i rudarenje podataka koji se vuku iz skladišta podataka ili Big Data baza. Prediktivna analitika postaje nezaobilazna u poslovnom odlučivanju. Danas menadžeri više nisu prisiljeni donositi odluke na temelju vlastite intuicije već na temelju obrađenog znanja u sustavu koji se generira metodama podatkovne analitike.

Lotfi Zadeh, otac neizrazite fuzzy logike, još je 1965. godine shvatio da tradicijske statističke i matematičke metode ne pružaju zadovoljavajuća rješenja za stvarne probleme u kojima ima puno nesigurnosti, rizika, nepreciznih podataka ili nedostajućih podataka. Mnogo menadžera se susretalo sa situacijama u kojima su morali donijeti odluku, a nisu imali nikakav odgovarajući alat za potporu već su tu istu odluku donijeli na temelju vlastite intuicije. Dok danas, sofisticirani alati za poslovnu inteligenciju i rudarenje podataka (data mining) vuku podatke iz skladišta podataka ili Big Data baza podataka i omogućuju da menadžeri, posebice u velikim tvrtkama, nisu prepušteni sami sebi nego da donose odluke na temelju obrađenog znanja u sustavu koje se generira metodama podatkovne analitike što u posljednje vrijeme sve više uključuje ne samo statističke metode već i metode strojnog učenja. (Zekić-Sušac, 2018)

Podatkovna analitika osim same analize podataka podrazumijeva i sve faze upravljanja podacima koje prethode analizi, kao što su prikupljanje, čišćenje, organiziranje, pohrana i izvješćivanje o rezultatima, a dijeli se na: (Zekić-Sušac, 2018)

- deskriptivnu
- dijagnostičku
- prediktivnu i
- preskriptivnu analitiku

Deskriptivna analitika –uglavnom koristi jednostavne statističke metode koje opisuju jednu varijablu i njezinu raspodjelu, na primjer učestalost pojavljivanja, prosječne vrijednosti, udjela, smjer kretanja prihoda, troškova, profita i slično.

Dijagnostička analitika –fokusira se na traženje uzroka događaja koji su se pojavili u prošlosti i traži odgovore na pitanja zbog čega se nešto pojavilo. Primjerice, zašto jedna od prodavaonica ima učestalo manji promet od ostalih

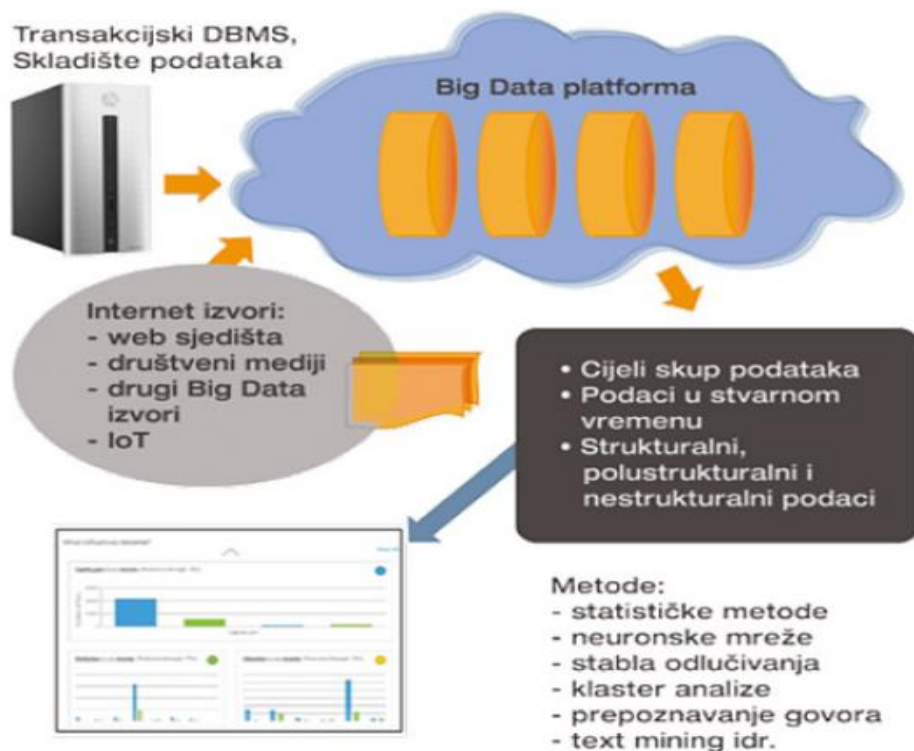
Prediktivna analitika –provodi se na višedimenzionalnim podacima s pomoću online analitičkog procesiranja i sličnih metoda. S druge strane, cilj prediktivne analitike je da odredi

vrijednost nekog obilježja (varijable) koja će se vjerojatno pojaviti u budućnosti. Ona istražuje snagu i smjer veza, uzorke, trendove i izuzetke. Primjeri problema koji se rješavaju metodama prediktivne analitike su predviđanje prodaje, predviđanje sutrašnje cijene dionice, predviđanje rasta poduzeća, ali i segmentiranje kupaca prema vjerojatnosti buduće kupnje nekog proizvoda i slično.

„Ona se koristi kako bi predvidjela buduće nepoznate događaje. Koristi mnoge tehnike kao što su statistički algoritmi, data mining, statistiku, modeling, strojno učenje i umjetnu inteligenciju kako bi analizirala trenutnu bazu podataka i predvidjela budućnost. Ima za cilj identificirati vjerojatnost budućih ishoda na temelju raspoloživih povijesnih podataka. Cilj je dakle ići dalje od onoga što se dogodilo kako bi pružila najbolju procjenu onoga što će se dogoditi.“ (Zhang, 2017:97)

Pisci različito definiraju prediktivnu analitiku. Prema Finlay (2015:4) prediktivna analitika je primjena matematike kako bi se analizirale paterne u prošlim podacima, kako bi mogli predvidjeti buduće ponašanje. Radi se o tipu prognoze koja traži veze između prošlih i budućih događaja. Dok Compton (2016.), s druge strane, prediktivnu analitiku definira kao “tehnike, alate i tehnologije koje koriste podatke za pronalazak modela koji mogu predvidjeti ishode sa značajnom vjerojatnosti točnosti.“ Ili jednostavnije to je ono što se zna i koristi za prognozu budućih rezultata.

Nadalje, prema Fagella (2018.) prediktivna analitika je upotreba podataka, statističkih algoritama i tehnika strojnog učenja kako bi se utvrdila vjerojatnost budućih ishoda na temelju povijesnih podataka. Cilj je ići dalje od saznanja o tome što se dogodilo pružajući najbolju procjenu onoga što će se dogoditi u budućnosti. Prediktivna analitika traži puno podataka iz prošlosti na kojima će metode učiti veze među podacima. Slika 2. Prikazuje kako se u kontekstu velikih podataka (Big Data), podatkovna analitika fokusira na upravljanje velikim količinama podataka uz uporabu skalabilnih distribuiranih tehnologija, a može obrađivati i nestrukturirane podatke, poput slika, audio i videozapisa, podatke iz uređaja putem interneta stvari. (Zekić-Sušac, 2018.)



Slika 2. Prediktivna analitika u okviru Big Data platforme (Izvor: Sušac, M., Has, A., 2016.)

3.1. Prediktivna analitika u marketingu

Prema Quick (2018.) svaki alat ili proces koji pomaže marketing stručnjacima da prepoznaju kupovne navike potrošača može biti velika korist njihovom poslovanju. Razlog tome je ako mogu „dekodirati“ prošle kupovne navike svojih potrošača onda mogu i projicirati njihove buduće kupovne navike te mogu donositi odluke na temelju tih spoznaja. Prediktivna analitika pomaže provjeriti da li su ta predviđanja točna ili nisu. Za marketinški odjel, informacije o kupnji mogu biti osnova za npr. promociju karata, reklamne kampanje itd.

Neke od stvari koje marketinški stručnjaci mogu učiniti kada imaju dostupnu bazu podataka i kada je primjenjena prediktivna analitika (Quick, 2018.)

- **Analizirati i prognozirati sezonsko ponašanje kupaca** - ovo se posebno odnosi na sezonske kupnje, jer su najuspješnije e-trgovine one koje ističu one proizvode koje će kupci kupovati u bilo kojem vremenu.
- **Ciljano nuditi najprofitabilnije proizvode kupcima koji će ih najvjerojatnije i kupiti** - nije dobro generirati email ili pop-up oglas za npr. Mercedes-Benz trinaestogodišnjaku. A s druge strane, ciljanje na imućnijeg kupca za high-end proizvode je centar za efektivni marketing.

- **Razviti učinkovitije strategije marketinga i oglašavanja** – ne samo ciljajući na pravu publiku, već ciljajući pravim porukama, slikama i temama koje će ih privući k samom proizvodu.
- **Naučiti i upotrijebiti najbolje strategije kako bi se uspjeh ponavljao** – prediktivna inteligencija može informirati marketing koji kupci će najčešće ponoviti kupnju. Budžeti postaju sve manji i manji. Marketing mora raspodijeliti svoje resurse kako bi se fokusirao na ciljeve koji pružaju najveći ROI.
- **Davanje prvenstva kupcima** – marketinški stručnjaci daju prioritet kupcima na temelju brojnih faktora od kojih je najmanji da će oni ponoviti kupnju. Ostali faktori uključuju, ali nisu ograničeni na to koji kupac kupuje proizvode s najvećom maržom, koje kupce je najlakše i najjeftinije privući i koji su to kupci koji će inicirati povrat.

3.2. Razlozi korištenja prediktivne analitike

Prediktivni modeli sve se više koriste kako bi zamijenili i/ili dopunili stručnu prosudbu i odlučivanje na svim poručjima. To je zbog toga što prediktivni modeli nastoje biti: (Finlay 2015:12)

- **Mnogo točniji od ljudskih eksperata.** Prediktivni modeli ponekad mogu dati krive predikcije isto kao i ljudi, ali sveukupni dokaz u prosjeku je da to nije toliko često kao kod ljudi. U mnogim poljima, prediktivni modeli konstantno nadmašuju stručnjake za 20-30% . Npr. oni čine manje pogrešaka za 20-30% ili identificiraju bolje (prfitabilnije/važnije) slučajeve za 20-30%.
- **Objektivni.** Za razliku od ljudi, prediktivni modeli ne prikazuju predrasude prema ljudima zbog njihovog spola, rase, invalidnosti itd. Modeli mogu prikazati pristranost, ali ako imaju tendenciju dati određenim pojedincima i grupama veće ili niže rezultate od populacije u cjelini, to je iz razloga što se temelji na čvrstim dokazima, a ne na temelju nedokazanih predznaka ili stereotipa.
- **Brzi.** Kao dio automatiziranog sustava donošenja odluka, prediktivni model može predvidjeti ponašanje milijuna ljudi u sekundi. Da ljudi rade takve prosudbe, u većini slučajeva to bi bilo neizmjereno skupo i dugotrajno.
- **Jeftini.** Jednom razvijeni, prediktivni modeli su često jeftiniji za implementaciju za razliku od njihovih ljudskih kolega.

Danas se prediktivna analitika koristi za mnogobrojne probleme. Činjenica je da se koristi u gotovo bilo kojem aspektu života koji uključuje odlučivanje o velikom broju ljudi. (Finlay 2015: 6)

Prema Quick (2018.) prediktivna analiza je sastavni dio današnjeg online oglašavanja. Od jednostavnih analitika, poput prodaja na temelju online kupnje, do sofisticiranih aplikacija, poput pokušaja predviđanja kupovnih navika različitih segmenata potrošača, prediktivna analitika postaje temelj na kojem se temelje online marketing i oglašavanje. Kako snaga obrade računala povećava, a pohrana podataka postaje jeftinija i jeftinija, nema kraja onome što će prediktivna analiza moći ostvariti.

3.3. Metode i alati prediktivne analitike

S obzirom na veliku brojnost metoda podatkovne analitike i njihovih primjena, fokus je na metodama prediktivne analitike i njihovoj implementaciji u okviru Big Data platformi, jer taj način obrade podataka ima sve veći značaj. Jedan od izazova s kojim se susreću menadžeri žele li koristiti metode prediktivne analitike je odabir alata i njegovo povezivanje s postojećom transakcijskom bazom ili integriranje u Big Data platformu. Pri odabiru alata ne postoje rješenja za sve pa tvrtka treba razmotriti: (Zekić-Sušac, 2018.)

- za što joj treba prediktivna analitika
- koje će probleme rješavati
- s kakvim podacima će se susresti
- koji budžet ima na raspolaganju
- kakva je postojeća infrastruktura (platforma koja omogućuje povezivanje s postojećim bazama)
- koju razinu znanja i vještina ima osoblje odnosno,
- jesu li upoznati s tumačenjima rezultata metoda prediktivne analitike
- koliku razinu vizualizacije, fleksibilnosti i skalabilnosti žele imati menadžeri i slično.

Prema Zekić (2018.) odabir alata često otežava činjenica da pokrivaju sličan opseg metoda, no ohrabrujuća je njihova skalabilnost te moguća zamjena drugim alatom. Prvi odabir ne mora biti i posljednji pa tako menadžeri mogu biti sigurni da će manje pogriješiti odaberu li bilo koji alat za prediktivnu analitiku negoli ako odluče ne koristiti nijedan.

Ako se prediktivna analitika koristi na transakcijskoj bazi podataka tu su proizvođači baza ugradili dodatne module za poslovnu analitiku u svoje sustave za upravljanje bazama pa tako Oracle Cloud Platform for Business Analytics i Microsoft Power BI sadrže i neke od metoda prediktivne analitike, kao npr. logističku regresiju, Bayesov klasifikator i druge. Jedna od opcija su i specijalizirani alati, kao npr. Tableau koji je Gartner prema svom izvješću od veljače 2016. svrstao na vodeće mjesto u svom magičnom kvadratu prema kriterijima potpunosti vizije i izvršnim mogućnostima, zajedno s alatima Qlik i Microsoft

Power BI, iza kojih su u kategoriju vizionara svrstani Alteryx, SAS, SAP, Microstrategy, IBM i još nekoliko alata. Istraživači više vole koristiti statističke pakete, kao npr. IBM SPSS, SAS, R softver i druge koji, osim što sadrže napredne metode za prediktivnu analitiku, omogućuju i ugradnju novih algoritama u postojeće metode pa su osim poslovnim ljudima, namijenjeni i istraživačima za testiranje novih algoritama i metoda. Nedostatak tih paketa je nedovoljna integriranost s bazom podataka tvrtke, pri čemu treba prenositi podatke iz transakcijske baze u format koji podržava određeni statistički paket te je nužno ekspertno znanje istraživača u području metodologije. Zbog toga je za tvrtke koje žele samo koristiti već ugrađene metode prediktivne analitike bolje rješenje uzeti neki od user-friendly alata koji se nadovezuju na baze podataka.

U Tablici 1. Uspoređeno je pet većih pružatelja usluga prediktivne analitike u okviru Big Data platforme: Tableau, IBM Watson Analytics, SAS Enterprise Miner, SAP Predictive Analytics i Oracle Advanced Analytic.

Tablica 1. Usporedba pet pružatelja usluga prediktivne analitike u okviru Big Data platforme


Alati za prediktivnu analitiku	Problemi koji se mogu rješavati alatom	Napredne metode prediktivne analitike uključene u alat
Tableau	Trendovi kretanja prodaje i drugih vremenskih nizova, analiza prodaje, analiza ljudskih resursa, pojavljivanje događaja	Stabla odlučivanja, linearna regresija, logistička regresija, trend analize, analize sezonskih utjecaja, metoda eksponencijalnog zaglađivanja; zbog integriranosti s alatom R omogućena uporaba svih metoda koje su raspoložive u alatu R
IBM Watson Analytics	Trendovi u ponašanju kupaca, prilike u marketinškim kampanjama, otkrivanje skrivenih zakonitosti u podacima iz društvenih medija, analiza prodaje i prihoda, održavanje resursa, detekcija problema kod proizvoda, uspješnost upravljanja ljudskim resursima i drugo.	Stabla odlučivanja, linearna i logistička regresija, statistički testovi: test usporedbe rezultata modela, test utjecaja, analiza varijance (ANOVA), test distribucija, Fisherov r-to-t test i drugo.
SAS Enterprise Miner	Otkrivanje i smanjenje prijevара, maksimiziranje indeks unakrsne prodaje, zadržavanje postojećih kupaca, optimiziranje marketinških kampanja, stope odaziva na marketinške kampanje, smanjivanje škarta kod proizvodnje, smanjenje neraspoloživosti resursa, optimiziranje distribucije, analiza ponašanja potrošača	Klaster-analize, analiza tržišne košarice, analiza redoslijeda i analiza web-puteva, link-analiza, linearna i logistička regresija, stabla odlučivanja, neuronske mreže, dvofazno modeliranje, zaključivanje na temelju memorije, spajanje modela, rudarenje podataka na vremenskim nizovima, analiza preživljavanja.
SAP (SAP) Predictive Analytics	Otkrivanje tržišnih trendova i potreba potrošača, segmentiranje kupaca, analiza prihoda i drugo.	Klasifikacijski i regresijski modeli (stabla odlučivanja), klaster-analize, analize vremenskih nizova, asocijacijska pravila, društvena analiza, analiza najčešćih puteva, analiza teksta, analiza redoslijeda i drugo
Oracle Advanced Analytics	Predviđanje prodaje, otkrivanje skrivenih segmenata kupaca, pronalaženje najprofitabilnijih prilika za prodaju, predviđanje prijelaza kupaca kod konkurencije, analiza ponašanja kupaca, analiza tržišne košarice, detekcija utjecajnih osoba kod društvenih mreža, detekcija prijevara	Logistička regresija, Bayes klasifikator, metoda potpunih vektora, detekcija anomalija, asocijacijska pravila, klaster-analiza, ekstrahiranje značajnih osobina negativnom matričnom faktorizacijom i dr.

Izvor: (Zekić- Sušac, 2018.)

Eric Siegel definirao je tri jednostavna koraka za primjenu prediktivne analitike:

1. odrediti cilj predviđanja
2. evaluirati rezultate predikcije i preusmjeriti (u slučaju da rezultati nisu dovoljno jasni)
3. primijeniti prediktivni model

Ti se koraci mogu prikazati i slikom:



Slika 3. Analitički proces predviđanja kupaca (Izvor:Zekić-Sušac, 2018.)

3.4. Postavljanje prediktivne analitike u poslovanje

Neke poslovne organizacije koriste prediktivnu analitiku desetljećima. Najčešće u industriji finansijskih usluga te u marketinškim odjelima velikih organizacija koje se suočavaju s potrošačima, kao što su supermarketi. Stoga, ove organizacije imaju dobro uspostavljene IT infrastrukture, sustave i procese za izgradnju i implementaciju predvidljivih modela. (Finlay, 2015: 34)

Prema Finlay (2015:35) za organizacije koje su nove u prediktivnoj analitici, izgradnja prediktivnog modela prvi put, može biti vrlo težak zadatak. Ponekad je potrebno nekoliko mjeseci da potrebni podaci budu spremni i da prediktivni proces može započeti. Međutim, Prikupljanje pravih podataka i izrada samog prediktivnog modela spadaju među lakše dijelove projekta prediktivne analitike. Razlog tome je, što na kraju dana, prediktivni model

nije ništa više nego skup jednadžbi zarobljenih u proračunskoj tablici, word dokumentu ili drugom softveru. Model treba biti operacionaliziran kako bi bio od koristi.

Glavni izazov, posebno za organizacije koje nikada prije nisu koristile prediktivnu analitiku, je da prihvate korištenje automatskog odlučivanja. Trebaju postaviti infrastrukturu kako bi omogućili prediktivnim modelima da postanu ključni dio sponosti organizacijskog donošenja odluka i da budu zadovoljni odlukama koje se donose na temelju predviđanja modela. Ovo uključuje uspostavljanje postupaka upravljanja kako bi se osiguralo da se odluke temeljene na modelu ponašaju prema namjeravanoj svrsi i da se odluke donositelja odluka ne zanemaruju ili nadilaze, osim u određenim unaprijed dogovorenim situacijama. Vjerojatno najveće greške koje organizacije mogu napraviti je da pretpostave da je uspješna prediktivna analitika: „Sve o modelu“, kada bi zapravo trebali razmišljati o stvarima iz perspektive: „To je sve poslovanje“. Finlay (2015:35)

Prediktivna analitika može biti nešto što može dodati vrijednost na ono što organizacija radi, ali s druge strane i ne mora. Primjerice, kako navodi Finlay (2015:35) korisna analogija je izgradnja automobilskog motora. Inženjeri mogu provesti dosta vremena na izgradnju vrlo moćnog i učinkovitog motora. Međutim, taj motor neće pružiti nikakvu korist ukoliko netko nije razmišljao o dizajnu automobila, u koji bi stavili motor, montaži motora i tako dalje. Bez ostatka automobila, motor je beskoristan. Isto vrijedi i za prediktivnu analitiku. Dok ne postoji poslovni proces u kojem će se postaviti model, model neće imati puno koristi. Ukoliko će organizacija uspješno integrirati prediktivnu analitiku u svoj poslovni proces, onda je pet glavnih područja koja treba razmotriti, u sljedećem redoslijedu:

1. **Problem.** Postavlja se pitanje za što će se to prediktivna analitika koristiti. Dakle, treba postojati pravi problem kojem prediktivna analitika može pomoći u rješavanju.
2. **Kultura.** Bitno je da li se organizacija može uvjeriti da prihvati prediktivnu analitiku te joj dopusti da pokreće automatizirano odlučivanje.
3. **Implementacija modela.** Bitno je znati koji sistem ili proces će biti korišten da bi se model stavio u praksu.
4. **Razvoj podataka.** Znati postoje li dovoljni podaci za omogućavanje izgradnje predvidljivih modela.
5. **Analitika.** organizacija treba provjeriti ima li softverske alate i stručnu potrebnu za analizu podataka i izgradnju prediktivnih modela.

3.5. Budućnost prediktivne analitike

Marketing je postao digitalno poduzeće, a prediktivna analiza jedan je od njegovih glavnih alata. Analiziranje navika potrošača nekad je trajalo tjednima i tjednima, a danas se radi u stvarnom vremenu. Kako tehnologija napreduje, sposobnost predviđanja navika potrošača i, uostalom, svakodnevnih navika, predstaviti će nekoliko etičkih i pravnih izazova. Čak i sada, marketing stručnjaci moraju biti oprezni kako bi bili sigurni da njihovi marketinški napori ne prelaze liniju između marketinga i invazije na privatnost. Prediktivna analitika postaje i biti će vjerojatno rješenje gotovo svakog problema. (Quick, 2018.)

4. PREDIKTIVNI MODELI PREDVIĐANJA PONAŠANJA KUPACA

Prema Finlay (2015:4-5) prediktivni model je (ili samo model koji ide naprijed) je output generiran procesom prediktivne analize. Model bilježi odnose između prošlih i budućih ponašanja koje je otkrila analiza. Nakon što je model stvoren, može se koristiti za generiranje novih predviđanja o budućnosti. Postoje razni prediktivni modeli kao i deseci i stotine matematičkih tehnika i algoritama koji se koriste za generiranje modela. Prediktivna analitika može biti korištena u raznim situacijama i problemima, ali najčešće je korištena i povezana uz predikcije što će ljudi raditi i kako će se ponašati u budućnosti, temeljeno na tome što znamo danas.

Prediktivna analitika isto tako se može nazvati i prediktivno modeliranje. To je način usklađivanja podataka s prediktivnim modelima i definiranje vjerojatnog ishoda. Tri modela prediktivne analitike su: (Zhang 2017:98)

1. PREDIKTIVNI MODELI – oni predstavljaju vezu između toga kako se član uzorka ponaša i neke od poznatih osobina uzorka. Cilj je procijeniti kolika je vjerojatnost da će se sličan član iz drugog uzorka ponašati na isti način. Ovaj model se koristi jako puno u marketingu. Pomaže prepoznati obrasce koji ukazuju na performanse kupaca. Ovaj model može čak obavljati izračune točno u trenutku kada korisnik izvrši transakciju.
2. DESKRIPTIVNI MODEL – opisuje događaje i veze između faktora koji su ih prouzročili. Koriste ih organizacije kako bi im pomogli u pokušajima marketinga i oglašavanja. U deskriptivnom modeliranju, kupci su grupirani na temelju nekoliko faktora, npr. njihovo ponašanje dok kupuju. Statistika pokazuje gdje se te grupe razlikuju, a gdje su slične. Kupcima se zapravo dodaje „vrijednost“ temeljena na tome koliko koriste neki proizvod ili uslugu i na temelju njihovih obrazaca kupnje. Ovaj model nastoji pronaći koristi od faktora koji dovode kupce da kupuju. Treba imati na umu, iako deskriptivno modeliranje može pomoći tvrtki da razumije svoje klijente, još uvijek treba predvidljivo modeliranje o željenim rezultatima.
3. MODELIRANJE ODLUKA – ubrzano raste popularnost modela odlučivanja. Modeliranje kombinira ogromne količine podataka i složenih algoritama za poboljšanje korporativnih performansi. Modeli za donošenje odluka mogu biti vrlo korisni, pomažući menadžerima da daju točna predviđanja i vode ih kroz teške odluke. Pomoću modela podaci se mogu koristiti objektivnije. Modeli za donošenje odluka mogu pomoći s problemima kao što su kako optimizirati online oglašavanje,

kako izgraditi portfelj dionica da se dobije maksimalni profit s minimalnim rizikom i kako online trgovci mogu dostaviti proizvod kupcu jeftinije i brže.

4.1. Izrada prediktivnih modela


Stvaranje analitičkih modela je i umjetnost i znanost. Osnovni proces uključuje pokretanje jednog ili više algoritama prema skupu podataka s poznatim vrijednostima za zavisnu varijablu (tj. ono što se pokušava predvidjeti). Zatim se podijeli skup podataka na pola i upotrijebit jedan skup kako bi se stvorili model obuke i drugi postavljen za testiranje modela obuke. Ako se želi predvidjeti koji će klijenti otići, algoritam se upućuje na bazu podataka kupaca koji su tijekom proteklih 12 mjeseci otišli kako bi se model usavršio. Zatim se pokrene rezultat modela obuke u odnosu na drugi dio baze podataka kako bi se vidjelo koliko dobro predviđa koji su se korisnici zapravo bunili. Potrebno je potvrditi model u stvarnom životu tako da ga se testira protiv živih i stvarnih podataka. (Eckerson, 2007.)

Iterativni proces. Kao što se može zamisliti, proces obuke, testiranja i provjere valjanosti je iterativan, tj. ponavlja se mnogo puta. To je mjesto gdje je "umjetnost" analitičkog modeliranja na čelu. Većina analitičara identificira i ispituje mnoge kombinacije varijabli kako bi vidjeli koje imaju najveći utjecaj. Većina ih započinje korištenjem statističkih i OLAP alata za prepoznavanje značajnih trendova u podacima kao i prethodnog analitičkog rada interno ili uz stručne konzultane. Također, može se razgovarati s poslovnim korisnicima koji su bliski predmetu i oslanjati se na vlastito znanje o tvrtki da se pridruže najvažnijim varijablama za uključivanje u model. Kao rezultat toga, većina analitičara uklanja popis varijabli od nekoliko stotina u početnoj verziji do nekoliko desetaka u konačnom modelu. Usput, testiraju se različiti algoritmi kako bi vidjelo što najbolje funkcionira na skupu podataka obuke. Moguće je na različite načine dodati nove vrste podataka ili rekombinaciju postojećih polja radi poboljšanja točnosti modela. Ovaj iterativni proces omogućuje stvaranje modela koji zahtijevaju intenzivnu i dugotrajnu upotrebu. (Eckerson, 2007.)

Odabir varijabli. Većina analitičara može stvoriti dobar analitički model od nule u otprilike tri tjedna, ovisno o opsegu problema i dostupnosti i kvaliteti podataka. Većina ih započinje s nekoliko stotina varijabli i završi sa 20 do 30. To se slaže s rezultatima istraživanja koje navodi Eckerson(2007.). Rezultati od 163 odgovora pokazuju da većina skupina (52%) stvara nove modele unutar "tjedana", a druga trećina (34%) stvara nove modele u jednom do tri mjeseca što je i prikazano na grafikonu 1. Jednom kada se model stvori, potrebno je oko polovice skupina (49%) trebaju "sati" ili "dani" za preispitivanje postojećeg modela za upotrebu u drugoj aplikaciji i traje još 30% "tjedana" za reviziju

modela. Osim toga, oko polovice (47%) modela imaju životni vijek kraći od godinu dana, a trećina (16%) postoji manje od tri mjeseca.

Vremenski period za stvaranje modela



Grafikon 1. Prikaz odgovora istraživanja na pitanje koliko je vremenski potrebno za razvijanje modela prediktivnosti (Izvor: Eckerson, 2007.)

4.2. Koristi prediktivnog modela

Ako je napravljen model koji radi, on se može koristiti za generiranje dobiti. Dvije glave koristi prediktivnog modela su: (Hughes 2006: 187)

- Odrediti tko će kupiti proizvod ili uslugu, i koji proizvod im ponuditi
- Odrediti koji kupci će najvjerojatnije odustati od usluge i kada će najvjerojatnije otići

Prema Hughes (2006:191) modeli mogu biti posebno korisni u određivanju koji od trenutnih kupaca će kupiti ponovno- i koje proizvode najčešće kupuju. Prednost korištenja modela na trenutnim kupcima je taj što se obično posjeduje mnogo važnijih podataka za rad. U modelu, podaci ponašanja kupaca su mnogo snažniji od onih demografskih. Drugim riječima, bolje se može predvidjeti što će ljudi napraviti u budućnosti temeljeno na onome što su već napravili u prošlosti nego temeljiti model na tome tko su oni (godine, prihod itd.)

4.2.1. Prediktivno modeliranje povećava odgovor kupaca

Postavlja se pitanje što bi bilo kad bi se unaprijed moglo predvidjeti kako bi velika grupa klijenata ili klijenti reagirala na ponudu koja im se nudi. Marketeri bi bili puno uspješniji kada bi mogli razdvojiti ljude koji će vjerojatno odgovoriti i kupiti od onih koji vjerojatno neće odgovoriti i kupiti. To je ono što prediktivno modeliranje može. S dobrim prediktivnim modelom može se odrediti: (Hughes 2006: 180-181)

- Koji kupac ima izgleda da će kupiti, a koji vjerojatno neće kupiti
- Kod kojeg kupca postoji opasnost da će otići, a koji će ostati
- Koje proizvode najčešće žele kupiti

Ideje koje stoje iza prediktivnih modela za marketing baze podataka počivaju na nekim jednostavnim principima: (Hughes 2006: 181)

- *Potencijalni kupci i oni postojeći u mnogim segmentima reagiraju na predvidljive načine.* Ta predvidljivost je od vitalne važnosti jer ako svatko ima nepredvidive reakcije na usluge i marketinške napore, model ne može pružiti pouzdana predviđanja.
- *Naznake očekivanog ponašanja kupaca ponekad se mogu prepoznati u njihovom prethodnom ponašanju i njihovoj demografiji.* Ponašanje korišteno u predikcijama obično je pohranjeno u bazama podataka u obliku transakcija. Demografski podaci se mogu dodati iz vanjskih izvora. Međutim ovo ne radi uvijek. Nije uvijek moguće predvidjeti ponašanje kupca temeljeno na podacima u bazi podataka.
- *Prediktivni model razvija se od odgovora na prethodne promocije.* Teško je pokrenuti i voditi uspješan prediktivni model ako već nije poslana promocija klijentu kako bi dobili reakciju od njih. To znači da se ne može samo uzeti datoteka s imenima i adresama i napraviti model koji bi utvrdio kupce koji će biti zainteresirani za neki proizvod.

4.3. Utvrđivanje i praćenje životnog vijeka kupaca

Vrijednost životnog vijeka kupca (LTV) jedan je od najvažnijih mjernih podataka za mjerenje u bilo kojoj rastućoj tvrtki. Mjerenjem LTV-a u odnosu na troškove stjecanja kupaca tvrtke mogu mjeriti koliko dugo je potrebno za povrat ulaganja potrebnih za stjecanje novog kupca - kao što su troškovi prodaje i marketinga. Metrika sama navodi tvrtke koliko prihoda mogu očekivati da će jedan klijent generirati tijekom poslovnog odnosa - što je nešto što korisnici podrške i timovi uspjeha imaju izravni utjecaj. Što duže kupac i dalje kupuje od tvrtke, njihova životna vrijednost postaje veća. Predstavnici korisničke podrške i menadžeri, koji igraju ključne uloge u rješavanju problema i koji nude preporuke klijentima pomažu da time kupci odluče ostati vjerni nekoj tvrtki. (Bern, 2018.)

Jedna od osnovnih vrijednosti i ciljeva samog upravljanja odnosima s klijentima je povećanje vrijednosti za klijente. Temeljna pretpostavka je: povećanje vrijednosti za klijente dovest će do povećanja životne vrijednosti klijenta. Utemeljenost navedene tvrdnje proizlazi iz činjenice da veća isporučena vrijednost klijentu dovodi do njegovog većeg zadovoljstva, pozitivno utječući na njegovu lojalnost, što u konačnici dovodi do veće vrijednosti za tvrtku. Veća vrijednost za tvrtku očituje se kroz ponovljenu kupnju te pozitivnu usmenu predaju što dovodi do veće prodaje i većeg profita. (Mandić et al. 2011:162)

Osnovna bit CRM.a je vrlo jednostavna, zadatak mu je da pomogne učiniti odnos s klijentima kvalitetnijim i profitabilnijim. Odnos s kupcem danas je ključan za poslovanje. Dakle, CRM je ključan za poslovanje. (Kabić, 2015.)

Zadržavanje klijenata i pronalaženje novih uvijek je bio težak i dugotrajan proces. Mnoge kompanije ulažu velike svote u tehnologiju i sofisticirani software, koji bi im pomogao u dovođenju novih i zadržavanju starih profitabilnih klijenata. Upravljanje odnosa s klijentima vrlo je bitan instrument uspješnog vođenja kompanije, a iznosi koji se ulažu u projekte iz tog područja rapidno rastu. Customer Relationship Managemet (CRM) danas je globano poznat naziv koji podrazumjeva uspješno vođenja odnosa sa klijentima. (Berry, 1995.)

4.4. Pronalazak profitabilnog kupca

Kao što navodi Hughes (2006:70) idealan kupac je onaj koji je jako profitabilan, i ostaje uz neku firmu doživotno. Najbolja marketinška strategija je privući takve kupce i držati ih lojalnima. U pravom svijetu, takve kupce je vrlo teško za pronaći. Marketinške strategije uvelike pomažu upravljati kupcima, tj. pomažu u oblikovanju ponašanja koje zadovoljava klijenta, a tvrtkama donosi profit. Postoje dva ponašanja koja mogu utjecati ovdje. To su: profitabilnost i lojalnost.

- Neki kupci su jako profitabilni, ali nestanu nakon jedne kupnje. Primjer toga su kupci novog stana/kuće. Bez obzira koliko zadovoljavajući ti kupci mogu biti, gotovo je nemoguće održavanje dugoročnog profitabilnog odnosa s njima kako bi im se prodao neki sljedeći stan/kuća za 10 ili 15 godina kada se umirove, dobiju promaknuće ili dijete.
- Neki kupci su blago profitabilni, ali su jako lojalni. Oni ostaju uz tvrtku godinama. Banke imaju tisuće takvih klijenata. Mnogi od tih klijenata nikada neće biti profitabilni, ali mogu biti jako lojalni.

Između ova dva ekstrema su velika većina kupaca koji pokazuju ponašanje koje se može mijenjati svjesnim marketinškim strategijama baze podataka. Neki su vrlo profitabilni, a neki nisu uopće. Neki su vrlo lojalni, neki nisu. Kombinacija tih dviju karakteristika je životna vrijednost klijenta (Hughes 2006: 70)

Prema Mandić i suradnicima (2011:167) nije nužno točna tvrdnja kako najveći klijenti tvrtki donose i najveću dobit. Profitabilan klijent je osoba, tvrtka ili domaćinstvo koja određeno vrijeme donosi prihod koji u dovoljnoj mjeri premašuje troškove što se odnose na privlačenje i pružanje usluge i prodaje tom klijentu. Procjena profitabilnosti može se donositi individualno, kroz tržišni udio ili kanal. Svakako treba naglasiti kako brojne tvrtke nisu u stanju izmjeriti individualnu profitabilnost svojih klijenata.

Prema Hughes (2006:71) profitabilnost obično mjeri aktivnosti u nedavnoj prošlosti, dok lojalnost mjeri buduću dugoročnu aktivnost. Profitabilnost je mjerena dodavanjem vrijednosti od specifičnog kupca i oduzimajući troškove koje je ovaj kupac imao u odgovarajućem razdoblju. Mnoge kompanije ne mogu napraviti analizu profitabilnosti kupca od strane kupca zbog ne mogućnosti dodavanja troškova na svakog kupca.

Trgovci su imali ograničenu ili nikakvu pravu informaciju o svojim potencijalnim kupcima i morali su računati zahtjeve za proizvodom koristeći najmanje činjenice i cijeli niz nagađanja. Ponekad im je tako uspjevalo, ali većinom nije te su mnogi trgovci otišli iz poslovanja prije nego što su imali priliku vratiti svoju investiciju. Danas, uz pomoć velikih podataka, može se saznati više pojedinosti o klijentima, kao i o tržišnim pozicijama. Ova vrsta informacija omogućuje sudjelovanje u vrlo konkurentnom području. Što kompanija bolje poznaje svoje kupce, to će više njeno poslovanje napredovati jer su kupci važni za proces prodaje. (Zhang, 2017:24)

Biti trenutno je od vitalnog značaja za marketing jer sve poslovne aktivnosti zahtijevaju hitnu akciju.

4.5. Stvaranje dugoročnih odnosa s kupcima

Jedna od središnjih točaka marketinškog razmišljanja posljednjih 50 godina usmjerena je upravo na lojalnost i stvaranje dugoročnog odnosa s klijentima. Uslijed velikog broja konkurenata ne čudi spoznaja da je jefitnije zadržati postojeće klijente nego privući nove. U većini slučajeva lojalni klijenti plaćaju ili su spremni platiti više cijenu za proizvod ili korištenje usluge. Pretpostavka je da će tvrtka imati i niže marketinške troškove s klijentima koji su lojalni i s kojima je izgrađen prisniji odnos. Međutim, prije provođenja aktivnosti na stvaranju dugoročnih odnosa, poželjno je učiniti sljedeće: (Mandić et al. 2011:162)

- Identificirati ključne kupce u što je moguće ranijoj dobi života, kako bi se mogao uspostaviti što je moguće duži odnos
- Utvrditi koji klijenti žele imati prisniji odnos s tvrtkom
- Kategorizirati (grupirati) klijente prema njihovoj važnosti za tvrtku
- Detaljno ispitati očekivanja svih ciljnih skupina kako klijenata tako i tvrtke
- Identificirati način na koji tvrtka i klijent mogu na što je moguće bliskiji način, surađivati razmjenjujući pritom vrijednost na obostrano zadovoljstvo
- Povezanost s klijentima graditi postupno
- Prepoznati različitost klijenata koji imaju i različita očekivanja te sukladno s tim formirati i odnos prema klijentu

Jasno je da postoji određen broj klijenata koji žele imati blizak odnos s tvrtkom, jer im to omogućava razne pogodnosti koje bez te povezanosti ne bi mogli ostvariti. No, ne smiju se zanemariti niti klijenti koji mogu biti vrijedni za tvrtku, a ne žele dati previše podataka o sebi i ne žele imati prečestu interakciju tj. komunikaciju s tvrtkom. U svakom slučaju, za izgradnju kvalitetnog odnosa i tvrtka i klijent moraju uložiti vrijeme i određeni trud. (Mandić et al. 2011:162)

Prema Vučemilović (2015.) tijekom posljednjih nekoliko godina mnoga poduzeća su postala svjesna presudne važnosti kupaca u svom poslovanju. Smještanje kupca u središte dovodi projekte upravljanja odnosom s kupcima među najvažnije projekte brojnih poduzeća. Jedan od najcjenjenijih američkih stručnjaka za menadžment i poslovnu izvrsnost Tom Peters, navodi potpunu orijentaciju na bliskost s kupcima kao jedno od osam temeljnih načela u postizanju izvrsnosti u poslovanju. U svakom poduzeću postoje brojne informacije o kupcima na različitim mjestima, te je od iznimne važnosti informacije koje se skupljaju kroz kontakte poduzeća i kupaca objediniti na jednom mjestu. Upravljanje odnosom s kupcima je složen pristup koji počinje misijom, vizijom, kulturom i strategijom. To su prve stvari koje treba promijeniti, a sve sa ciljem pozicioniranja kupca u središte promišljanja i djelovanja

poduzeća. Poduzeće mora prije uvođenja CRM-a pažljivo razmotriti sve prednosti i nedostatke ove marketinške strategije i pravilno procijeniti koliko je takav pristup prikladan za poslovanje poduzeća.

Masovna proizvodnja i prodaja su dovele do gubljenja direktnog kontakta s kupcima, te se javila potreba za ponovnom izgradnjom dugoročnih odnosa s njima. Marketing je od masovnog marketinga prešao na ciljani marketing i direktni marketing koji karakterizira interaktivna segmentacija tržišta, zadovoljavanje potreba potrošača u realnom vremenu i interakcija poduzeća i kupaca. Alat koji omogućava direktni marketing je upravo CRM.

Korjani marketinga usmjerenog uspostavljanju odnosa s kupcima se nalaze u: (Vučemilović, 2015.)

1. B2B marketingu (marketingu na tržištu poslovne potrošnje),
2. marketingu odnosa u kanalima,
3. marketingu baze podataka/direktnom marketingu i
4. marketingu usluga.

Poduzeća su svjesna da nije dovoljno samo privući kupca, već je od iznimne važnosti i zadržati ga. Troškovi osvajanja kupaca na zrelih tržištima su visoki, a nezadovoljni se kupci rijetko žale, već se jednostavno usmjeravaju drugom poduzeću sa sličnom ili istom ponudom proizvoda/usluga. Primjenom CRM-a povećava se prodaja po kupcu, povećava se lojalnost postojećih kupaca i poboljšava odnos s kupcima, jer se vodi računa o potrebama i željama kupaca, a komunikacija nije više samo u jednom smjeru već je dvosmjerna. Neki od najvažnijih razloga primjene CRM-a su privlačenje novih kupaca, povećanje prodaje po kupcu, smanjenje troškova kroz poboljšanja u poslovnim procesima, poboljšanje odnosa s kupcima i povećanje potrošačke lojalnosti. Razlike između klasične koncepcije marketinga i upravljanja odnosom s kupcima su prikazane u slijedećoj tablici (Vučemilović, 2015.)

Kako navodi Vučemilović (2015.) upravljanje odnosom s kupcima kao dio upravljanja ukupnom kvalitetom omogućava izvrsnu operacionalizaciju kroz osiguranje točne isporuke i učinkovitu komunikaciju s kupcima kroz sve kanale jer su kontakti s kupcima pojednostavljeni. Baza za kontakt centar omogućava integraciju pozadinskih ureda i prodaje te fleksibilnost na promjene korisničkih zahtjeva i potreba. CRM koristi analitički pristup za planiranje prodaje i prognoze prodajnih veličina te analizu kupaca. Ovakav sustav iskorištava informacije iz raznih baza unutar poduzeća pa je stoga najveći napor konsolidacija raznih baza podataka, te izrada sučelja među njima. Primjenom ove marketinške strategije se stvaraju dugoročni i profitabilni partnerski odnosi s kupcima. Poznato je da su troškovi osvajanja novog kupca izuzetno visoki te da je lakše povećati prodaju kod postojećeg kupca

nego osvojiti novog. Upravo zbog toga je logično raditi na sustavu koji će raditi na zadržavanju kupaca. Poduzeća prikupljaju podatke o kupcima iz različitih izvora. Uspješna i poznata poduzeća kao što su IBM i Xerox koriste za prikupljanje podataka o kupcima 40.000 anketa svaki mjesec, redovne fokus grupe, panel istraživanja, okrugle stolove s prodajnim osobljem, istraživanja tržišta s naglaskom na razvoj proizvoda, analizu konkurencije, testiranje novih proizvoda kod kupaca, suradnju s distributerima i vodećim ekspertima.

4.6. Životna vrijednost kupca

Pojam usko vezan uz životnu vrijednost kupaca je i pojam vrijednosti, odnosno lanca vrijednosti. Lanac vrijednosti je zapravo glavni instrument za identificiranje načina na koje se može stvoriti veća vrijednost za klijenta. Lanac vrijednosti se zapravo sastoji od različitih aktivnosti, odnosno poslovnih procesa. Osnovni poslovni procesi uključujući: (Mandić et al. 2011:163)

- Proces razvoja proizvoda
- Proces upravljanja zalihama
- Proces od narudžbe do naplate
- Proces usluga klijentima

Aktualna (stvarna) vrijednost je vrijednost klijenta promatrana kao imovina tvrtke, koja odražava trenutno poznato ili buduće ponašanje klijenta koje je moguće predvidjeti, pretpostavljajući da se neće dogoditi značajnije promjene u okruženju. Potencijalna vrijednost je ukupna vrijednost koju bi klijent mogao predstavljati za tvrtku ukoliko tvrtka primijeni odgovarajuću strategiju koja bi mogla povećati vrijednost klijenta, mijenjajući na određeni način klijentovo buduće ponašanje. (Mandić et al. 2011:163)

Prema Behin (2006.) ne treba živjeti u zabludi da uz najbolju CRM strategiju klijenti neće odlaziti. Neizbježno je da određeni broj klijenata ipak prijeđe konkurenciji. Cilj je broj odlazećih klijenata smanjiti na najmanju moguću razinu, tj. fokusirati se na zadržavanje najprofitabilnijih klijenata. Razlozi zbog kojih klijenti prestaju koristiti usluge određene kompanije mogu biti različiti. Oni mogu prijeći konkurenciji jer više nemaju potrebe za proizvodom/uslugom koju im određena kompanija nudi. S druge strane kvaliteta usluge ne zadovoljava očekivanja klijenata i stoga oni odlaze. Iznenađujući je podatak da čak 70% klijenata koji prestaju koristiti usluge/proizvode određenog poduzeća nemaju poseban razlog zbog kojeg odlaze. U tom slučaju jednostavno nije bila stvorena lojalnost na relaciji poduzeće-klijent, koja bi zadržala klijenta. Osim što kompanija gubi prihode od klijenata koji

odlaze, ona narušava svoj goodwill, reputaciju, te gubi znanje potrebno za razvijanje i unapređenje proizvoda/usluga.

Životni ciklus klijenata gledan očima poduzeća može se grubo podijeliti u tri cjeline: (Behin, 2006.)

1. U prvoj fazi (identifikacija) – nastoje se identificirati mogući klijenti, uspostaviti komunikacija s istima, te potaknuti razmjenu informacija kako bi klijenta približili kompaniji.
2. U drugoj fazi ciklusa (faza rasta) – nastoji se stvoriti dugotrajno profitabilan odnos s klijentom, prodajom niza vezanih proizvoda (engl. cross-selling).
3. Treća faza životnog ciklusa klijenta podrazumjeva konstantan rad na održavanju i unapređenju odnosa s klijentima, kroz povećanje kvalitete usluge. U ovoj fazi klijent koristi najprofitabilnije proizvode/usluge kompanije, stoga se radi na odnosu i popratnim pogodnostima koja dolaze uz sam proizvod. Nastoji se stvoriti jaka lojalnost između poduzeća i klijenta

Životna vrijednost kupca (CLV) jedan je od najvažnijih čimbenika u određivanju sadašnjeg i budućeg uspjeha poslovanja. To je često zanemariv mjerni podatak koji točno može predvidjeti koliko klijenti stvarno vrijede. Daje presudan uvid u iznos novca koji bi se trebao trošiti na pridobivanje kupaca jer pokazuje koliko kupci dugoročno vrijede. Time je omogućeno da svaka tvrtka shvati na koje kupce se treba fokusirati odnosno usredotočiti. (Donnelly, 2017.)

Mandić (2011.) navodi kako se najčešće vrijednost klijenta promatra kroz vrijednost njegovog čitavog životnog (kupovnog) vijeka. Životna (kupovna) vrijednost klijenta govori o tome što klijenti kupuju, koliko uobičajeno kupuju, kada su zadnji put kupovali i što su kupili te, iznimno važno, što bi mogli kupiti u budućnosti.

4.6.1. Određivanje životne vrijednosti kupca

“Životna vrijednost kupca opisuje čistu sadašnju vrijednost budućih profita (prihoda) koji se očekuju od klijenta tijekom njegovog života. Ili životna vrijednost klijenta predstavlja trenutnu vrijednost svih budućih profita dobivenih od klijenata.” (Mandić et al. 2011:166)

Kao što navode Mandić i suradnici (2011:166) od očekivane dobiti potrebno je oduzeti očekivane troškove prodaje, privlačenja te usluživanja klijenata, uključujući i odgovarajući popust. Formule kojima se računa životna vrijednost klijenta većinom uzimaju u obzir trenutnu vrijednost klijenta (tj. neto sadašnju vrijednost klijenta) te vrijeme lojalnosti, odnosno

zadržavanja klijenta. Kako bi se došlo do odgovora o vrijednosti pojedinog klijenta, potrebno je imati informacije o kupnji klijenta, maržama ostvarenim po pojedinom klijentovom kupljenom proizvodu.

Neke od tehnika koje organizacije mogu koristiti za povećanje profita povećavajući životnu vrijednost kupca: (Hughes 2006: 60)

Zadržati postojeće kupce:

- Pružiti strategije koje potiču kupce na obnovu ili zadržavanje članstva
- Izgraditi odnos s kupcima kako bi postali još lojalniji
- Segmentirati bazu podataka i usmjeriti odnos tvrtke s odgovarajućim grupama kupaca, a ne da ih obrađuje podjednako
- Povećati napore obnove ili ponovne aktivacije

Dodavanje novih kupaca:

- Proučiti postojeće klijente koji su ostali i koji su otišli. Iskoristiti analize i model kako bi odredili tip kupca koji najvjerojatnije ostaje, a zatim osmisliti strategije za upravo takve
- Profilirati postojeće kupce i zatim slijediti takve profile za pronalazak novih kupaca

5.KORIŠTENJE VELIKE KOLIČINE PODATAKA (BIG DATA) U PREDIKTIVNOJ ANALIZI

Prvi pojavni oblici pojma veliki podaci (eng. Big data) javljaju se krajem 20.tog stoljeća da bi početkom 21. postao nezaobilazan termin u poslovnom svijetu. Razvoj informatičke i komunikacijske tehnologije dovodi do pojave velikih količina podataka koje se generiraju u internoj i eksternoj poslovnoj okolini te se uspješnost poslovanja veže za mogućnost korištenja tih podataka. Okruženo pogodnostima i koristima korištenja velikih količina podataka iz različitih izvora doživio je i marketing. (Dobrinić et al. 2017:233)

Prema Dobrinić (2017:233) dosadašnja tradicionalna marketinška paradigma se mijenja i prilagođava novim tehnološkim i komunikacijskim trendovima. Nova generacija potrošača koja postaje dominantna na tržištu, generacija milenijalaca svoja su prva slova tipkala na računalu, njihova percepcija svijeta temelji se na tehnologiji, svakodnevnom korištenju interneta, društvenih mreža, pametnih telefona...Sve su to izvori podataka koji marketingu pomažu u kreiranju profila kupaca i adekvatnom zadovoljavanju njihovih potreba. Marketinške strategije se mijenjaju i prilagođavaju zahtjevima kupaca.

Big data, zajedno s analitikom, može ponuditi organizacijama vrlo impresivne mogućnosti za poboljšanje učinkovitosti i operacija. Ipak, mogućnosti korištenja Big data za postavljanje novih poslovnih pitanja i zadovoljavanje potreba tržišta mogu biti još zanimljivije. (Davenport et al. 2018.)

5.1.Pojmovno definiranje velikih podataka (Big Data)

Autori različito definiraju pojam velikih podataka, Davis (2016.) velike podatke opisuje kao niz različitih statističkih pristupa rješavanju velikih skupova podataka. To je tehnologija koja omogućava prikupljanje i obradu velikih količina strukturiranih i nestrukturiranih podataka u realnom vremenu. S druge strane Zhang (2017:48) smatra da veliki podaci mogu otvoriti nove mogućnosti za tvrtke u bilo kojem sektoru. Tvrtke koje izravno koriste velike podatke prikupljaju vrijedne informacije od strane drugih tvrtki. Neobrađeni podaci kao i analizirani i tumačeni oblik takvih podataka mogu se prodati drugim tvrtkama, stvarajući još više prihoda.

Prema Merriam-Webster rječniku, kako navodi Dobrinić (2017.), velike skupine podataka su skup podataka koji su preveliki i kompleksni za obradu tradicionalnim alatima

baze podataka. Nadovezujući se na kompleksnost obrade velike količine podataka ističe se kako su velike skupine podataka pojam koji se koristi za opisivanje prikupljanja, obrade i dostupnosti velikih količina podataka u stvarnom vremenu

Veliki podaci govore o promatranju i razumijevanju odnosa unutar i među informacijama koje se, sve do nedavno, nastojalo potpuno shvatiti. IBM-ov veliki stručnjak za podatke Jeff Jonas smatra da se treba pustiti da Veliki podaci „razgovaraju s nama“ . (Schönberger et al. 2014: 19)

Jobs i suradnici (2015.) kao što navodi Dobrinić (2017.) smatraju da bez sumnje velike skupine podataka predstavljaju kulturni, znanstveni i tehnološki fenomen koji prema počivaju na 3 čimbenika: tehnološkom, analitičkom i mitološkom. Tehnološki se čimbenik odnosi na računalnu snagu i algoritamsku točnost za prikupljanje i analizu podataka, analitički na analizu velikih skupova podataka te mitološki na percepciju kreiranja viših i većih oblika inteligencije i znanja.

Veliki podaci su razvojni pojam koji opisuje sveobuhvatnu količinu strukturiranih, polukrutnih i nestrukturiranih podataka koji mogu potkopati informacije. Velike podatke često karakterizira 3v: ekstremni volumen podataka, širok raspon vrsta podataka i brzina kojom se podaci moraju obrađivati. (Rouse, 2016.)

Krajnji cilj je povećanje prihoda putem izravne komunikacije s kupcima. Što više neko poduzeće zna o svojim kupcima, to učinkovitije može komunicirati s njima. Čime god da se poduzeće bavi, bit će okruženo podacima npr. podacima o prodaji, financijskim podacima, podacima o proizvodu ili kupcima. [Semmelroth 2013: 35]

Kako navodi Zhang (2017:202) jedan dio ljudskog djelovanja koji uvelike ima koristi od velikih podataka (Big Data) je marketing. Radi se o konstantnoj potrebi da se više upoznaju s ovim područjem i kao takvi, i trgovci i data znanstvenici nastavljaju istraživati ovu temu koja ima pravu vrijednost kada se primjenjuje ispravno. Prije nekoliko godina, bilo je teško opisati kupca tako detaljno kao u današnje vrijeme uz pomoć baze podataka. Informacije o svakom aspektu ljudskog života brzo se šire i kada se ta velika zaliha izjednači s velikim podacima, sve akcije mogu se logički i precizno kvantificirati. Učinci analize velikih podataka na marketinšku praksu sada su opsežnija nego što se može zamisliti. Svaki aspekt ove teme može se odrediti i analizirati iz preferencija potrošača, dostupnosti proizvoda, cijena, opskrbe, logistike i svaki drugi zamislivi aspekt vezan uz marketing.

Prema Davis (2016:3) analiza podataka koristi postojeće podatke da tvrtka mora ili poboljšati proizvode ili poboljšati iskustvo korisnika. Analiza podataka je širi pojam i može se upotrebljavati za opisivanje brojnih načina na koje klijent reagira s velikim tvrtkama. U velikoj

mjeri se može razmišljati o analizi podataka kao o postojećim skupovima podataka kako bi se poboljšali optimizacija unutar organizacije.

5.2. Posjedovanje podataka unapređuje poslovanje

Pravilno i učinkovito korištenje velike količine podataka može biti iznimno važno, te može poboljšati poslovanje tvrtke na više načina: (Zhang, 2017: 20)

- **Poboljšanje marketinških strategija:** ovisno o vrsti prikupljenih podataka, lakše je pronaći atraktivne i inovativne marketinške strategije. Ako organizacija zna kako kupci reagiraju na trenutne marketinške tehnike, omogućit će im da izvrše promjene koje će uskladiti s trendovima i očekivanjima svojih kupaca.
- **Utvrđivanje točke odstupanja:** ako se posao pokreće unaprijed određenim procesima ili obrascima, podaci mogu pomoći pri prepoznavanju točaka odstupanja. Mala odstupanja od norme mogu biti razlog iza povećane prodaje ili smanjene produktivnosti. Skupljanjem i čestim analiziranjem podataka, organizacija može preduhitriti „nesreću“ te na vrijeme spriječiti nepovratne štete.
- **Detektiranje prevara:** u nedostatku odgovarajućeg upravljanja podacima, prijevare mogu prolaziti i ozbiljno utjecati na poslovni uspjeh. Uz pristup prodajnim brojevima u ruci, lako će se otkriti i gdje se mogu pojaviti prijevare.
- **Unapređenje kupčevog doživljaja:** podaci se također mogu prikupiti od kupaca u obliku povratnih informacija o određenim poslovnim aspektima. Ova informacija će dopustiti tvrtki da mijenja poslovnu praksu, usluge ili proizvode kako bi bolje zadovoljili kupca. Održavanjem banke povratnih informacija od kupaca i kontinuiranog traženja povratnih informacija, tvrtka može bolje prilagoditi svoj proizvod ili uslugu kako se korisnici mijenjaju. Neke organizacije šalju prilagođene e-maile svojim kupcima, stvarajući osjećaj da im je zaista stalo do svakog kupca. Ovo rade najčešće zbog učinkovitijeg upravljanja podacima.
- **Donošenje odluka:** Mnoge važne odluke o poslovanju zahtjevaju podatke o trendovima na tržištu, bazama kupaca i cijenama koje nude konkurenti za iste ili slične proizvode ili usluge.

Prema Zhang (2017:28) diljem svijeta, podaci i tehnologija su isprepleteni u društvu i onom što se radi. Poput drugih faktora proizvodnje - ljudskog kapitala i teške imovine - postoje mnogi dijelovi suvremene gospodarske aktivnosti koja se ne bi mogla dogoditi bez podataka. Ukratko, veliki podaci (Big Data) su velike količine podataka koji se prikupljaju radi analize. Iz ovih podataka mogu se pronaći obrasci koji će bolje informirati buduće odluke. Ovi podaci i ono što se može naučiti iz njih, postat će način kako se tvrtke natječu i rastu u

budućnosti. Također, produktivnost će se uvelike poboljšati. Veliki podaci danas su jedan od najvećih ekonomskih faktora. Postaju nevjerojatno važan način da se tvrtke međusobno nadmašuju. Čak i novi sudionici na tržištu moći će iskoristiti strategije koje su pronašli podaci kako bi se natjecali, inovirali i postigli stvarnu vrijednost. Veliki podaci (Big Data) će pomoći stvoriti nove rastuće mogućnosti i stvoriti nove kompanije koje su specijalizirane u prikupljanju i analiziranju podataka. Puno je kompanija koje „sjede“ u sredini plutajućih informacija. Primaju informacije i podatke koje dolaze iz mnogih izvora kako bi ih analizirali. Menadžeri kompanija, koji razmišljaju unaprijed, moraju početi kreirati i tražiti novi način kako bi se njihova kompanija naučila nositi sa svim tim podacima. Važno je shvatiti ne samo količinu podataka, nego i visoku učestalost i realnost prirode podataka.

5.3.Odnos između Big Data i prediktivne analitike

Finlay (2015:45-49) navodi da od 2010. godine, veliki podaci postali su sveprisutni pojam koji se koristi za opisivanje svih podataka koje generiraju ljudi sa svojih pametnih telefona, povijest pregledavanja weba, društvenim medijima i ponašanju u kupnji itd. Zašto su veliki podaci različiti od bilo koje druge vrste podataka? Pojam velikih podataka obično se primjenjuje na velike zbirke različitih vrsta podataka koji su često promjenjivi te ih je teško analizirati pomoću tradicionalnih računalnih programa i softvera. To je također slučaj da veliki podaci često uključuju određene vrste podataka koji nisu bili široko korišteni za analizu kupaca do nedavno. Osobito veliki podaci uključuju:

- Tekst – što ljudi pišu i govore može se analizirati kako bi se utvrdilo o čemu govore i o koje osjećaje izražavaju. Ako se o proizvodu komentira u pozitivnom ili negativnom kontekstu onda će se zasigurno predvidjeti hoće li netko i dalje kupiti taj proizvod.
- Slike – ovo pokriva fotografije i videozapise
- Podaci društvene mreže – Ovo je informacija o tome s kim se ljudi povezuju i koga znaju. Podaci društvenih mreža uključuju brojeve i tipove veza koje ljudi imaju, isto kao i podaci o povezanim osobama.

U današnjem svijetu „velikih podataka“ podaci se ažuriraju puno više, često u stvarnom vremenu. Podaci moraju biti izrađeni u nešto korisno kako bi bili od koristi. Prediktivna analitika ključni je alat koji to čini - primjenjujući algoritme na svim tim podacima i proizvodnjom prediktivnih modela koji mogu reći nešto o budućem ponašanju ljudi, na temelju onoga što se dogodilo prije u prošlosti. Dobar način za gledanje na odnos između velikih podataka i prediktivne analitike je taj da su podaci sirovina koja hrani analitički proces.

Opipljiva korist za tvrtku proizlazi iz prediktivnog modela koji dolazi na kraju procesa, a ne od podataka koji se koriste za njegovu konstrukciju. (Finlay 2015: 48)

Prema Finlay (2015:49) o prediktivnoj analitici i velikim podacima se često govori u istom dahu, ali to nije simetričan odnos. Prediktivna analitika je potrebna kako bi izvukla najbolje iz podataka, dok s druge strane podaci nisu potrebni kako bi se učinkovito koristila prediktivna analitika. Ukoliko se posjeduje nekoliko informacija o nekoliko stotina ljudi onda je to sasvim dovoljno da se započne graditi prediktivni model i naprave korisne predikcije. Što su podaci bolji i što ih je više i modeli će biti bolji za predikcije, ali posjedovanje gigabajta i terabajta podataka nije preduvjet za izgradnju korisnih modela.

6.KORIŠTENJE UMJETNE INTELIGENCIJE U KREIRANJU PREDIKTIVNH MODELA

Umjetna inteligencija (AI) područje je računalne znanosti koja naglašava stvaranje inteligentnih strojeva koji rade i reagiraju kao ljudi. Neke od aktivnosti računala s umjetnom inteligencijom dizajnirane su za uključivanje: (Techopedia, 2018)

- Prepoznavanje govora
- Učenje
- Planiranje
- Rješavanje problema

Prema Techopedia (2018.) umjetna inteligencija je grana računalne znanosti koja ima za cilj stvoriti inteligentne strojeve. Postala je bitan dio tehnološke industrije. Temeljni problemi umjetne inteligencije uključuju programiranje računala za određene osobine kao što su: znanje, rasuđivanje, rješavanje problema, percepcija, učenje, planiranje te sposobnost manipuliranja i premještanja objekata. Strojevi često djeluju i reagiraju kao ljudi samo ako imaju obilje informacija koje se odnose na svijet. Umjetna inteligencija mora imati pristup objektima, kategorijama, svojstvima i odnosima svih kako bi implementirali znanje. Pokretanje zdravog razuma, razmišljanja i sposobnosti rješavanja problema strojevima je težak i dosadan zadatak. Strojno učenje je također temeljni dio AI. Učenje bez bilo kakvog nadzora zahtijeva sposobnost prepoznavanja uzoraka u tokovima ulaza, dok učenje s odgovarajućim nadzorom uključuje klasifikaciju i numeričke regresije. Strojno učenje je metoda analize podataka koja automatizira izgradnju analitičkog modela. To je grana umjetne inteligencije koja se temelji na ideji da sustavi mogu naučiti od podataka, prepoznati obrasce i donositi odluke uz minimalnu ljudsku intervenciju.

6.1.Povijest umjetne inteligencije

Povijest umjetne inteligencije (AI) započela je mitovima i pričama o umjetnim bićima, obdarenim inteligencijom od majstora majstora s pričama o "drevnim željama da se kriju bogovi". Korijene suvremene AI zasadili su klasični filozofi koji su pokušali opisati proces ljudskog razmišljanja kao mehaničku manipulaciju simbola. Temelji na pretpostavci da se ljudska misao može mehanizirati. U 17. stoljeću, Gottfried Leibniz (1646. - 1716.) njemački filozof matematičar i fizičar nagađao je da se ljudska misao može smanjiti na mehanički izračun. Leibniz je zamislio univerzalni jezik razmišljanja. On je otac diferencijalnog i

integralnog računanja. Njegovo je istraživanje dodatno su razvili Thomas Hobbes (1588-1679), engleski filozof i francuski filozof Rene Descartes (1596.-1650.), jer su pretpostavili da bi sva racionalna misao mogla biti sustavna kao algebra ili geometrija. Ti filozofi imali su pionirsku viziju da vide budućnost sustava fizikalnih simbola koji će postati temeljni temelj za evoluciju AI. (Gordon, 2016.)

Sami pojam umjetne inteligencije koncipiran je 1956. godine, a danas je postao popularniji zahvaljujući povećanom volumenu podataka, naprednim algoritmima i poboljšanjima u računalnoj snazi i pohrani.

6.2. Umjetna inteligencija poboljšava prediktivnu analitiku

Prediktivno modeliranje i analitika koriste se već neko vrijeme. No, nedostaju im tri glavne stvari koje su važne za prave marketinške vrijednosti: količina, brzina i primjena. Stoga je tu vrlo bitna umjetna inteligencija, koja dolazi na red kako bi poboljšala takve stvari. Umjetna inteligencija (AI) vrsta je računalnih znanosti usmjerenih na stvaranje sustava koji automatiziraju "inteligentne" procese - tj. ljudske poslove poput odlučivanja, rješavanja problema i učenja. U osnovi, umjetna inteligencija omogućuje računalima da rade stvari koje - bez nje - zahtijevaju ljudsku intervenciju. Ali budući da računala mogu djelovati brzinom svjetlosti, umjetna inteligencija može raditi s brzinom i preciznošću koje obični smrtnici nikada nebi mogli postići. Prediktivna analitika i umjetna inteligencija su dvije različite stvari, ali kada se spoje „izvlače“ najbolje jedna iz druge. Umjetna inteligencija omogućuje da prediktivna analitika bude brža, pametnija i djelotvornija nego ikad prije. (Magnetic 2017.)

Kada se umjetna inteligencija koristi za prediktivnu analitiku, njihova kombinacija znači poboljšanja u količini, brzini i primjeni: (Magnetic 2017.)

- Količina - S umjetnom inteligencijom, prediktivni modeli mogu predstavljati nevjerovatan volumen informacija u realnom vremenu. To znači da prediktivni modeli mogu razmotriti više informacija nego ikada prije, čime bi rezultati bili precizniji i djelotvorniji.
- Brzina i primjena – umjetna inteligencija u samo nekoliko trenutaka može postići godine i godine ljudskog rada. Ona procjenjuje milijarde varijabli u stvarnom vremenu, a istodobno donosi i odluke za analizu preko milijun marketinških prilika u sekundi. Kada se ova brzina primjeni na prediktivno modeliranje, rezultat su odlučivanje i akcije u stvarnom vremenu.

6.3. Personalizirane marketinške strategije

„Personalizacija je selekcija, prilagođavanje ili filtriranje informacija, usluga ili proizvoda za neku osobu s obzirom na njene karakteristike, interese i potrebe kojima se definira profil te osobe kao korisnika odnosno kupca.“ (Kirinić et al. 2011: 291)

Personalizirani marketing je marketinška strategija koja se usredotočuje na ciljanje marketinških inicijativa i poruka do pojedinog trenutnog ili budućeg korisnika. To se provodi uz pomoć analize podataka i digitalne tehnologije. Personalizirani marketing također je poznat kao jedan-na-jedan marketing i, kao što ime sugerira, u potpunosti je prilagođen potrebama svakog pojedinog potrošača. Kako bi on bio uspješan, tvrtka bi trebala biti u mogućnosti dobiti što više osobnih podataka o trenutnom ili potencijalnom klijentu što je više moguće. Danas postoji ogromno more podataka o pojedinačnim potrošačima. Ti se podaci zatim analiziraju i iskorištavaju kako bi pružili prilagođene, ciljane ponude, preporuke i poruke namijenjene privlačenju pojedinca na temelju prošlog ponašanja, interesa i drugih podataka. (Galetto, 2018.)

Prema Kirinić (2011.) Profil kupca definira se na temelju podataka prikupljenih bilježenjem interakcije kupca s tvrtkom, provedenih transakcija ili pak direktnim traženjem podataka o preferencijama. Personalizacija je moguća zbog saznavanja virtualnog odraza korisnika/kupca, dostupnosti metapodataka o proizvodu te dostupnosti metoda kombiniranja tih skupova podataka kako bi se generirale preporuke za tog kupca.

Suština personalizacije je da se kompanije pokušaju što više približiti svakom kupcu, posebno tako što pripreme jedinstvenu ponudu za svakoga kupca ili za svaki segment kupca posebno. Pri planiranju ponude ne smiju se zanemariti želje onih koji utječu na ciljnog kupca, kao što su to, na primjer, ostali članovi obitelji, prijatelji i slično. Personalizacija bi trebala biti prije svega usredotočena na sadržaje koje kupac želi. To kompanije mogu postići samo ukoliko dobro poznaju kupca te upotrebom različitih načina i strategija. (Bordon et al, 2014.)

Kompanije razvijaju proizvode koji se temelje na onome što misle da će klijenti kupovati. Danas, s dolaskom velikih podataka (Big Data), kompanije mogu bolje istražiti o interesima i preferencijama klijenata. Jedna od usluga koja se danas uvelike koristi je Google Trends, omogućujući kompanijama da pronađu i vide što ljudi traže na World Wide Webu. Podaci omogućavaju kompanijama da razviju personalizirane proizvode i usluge koji još više odgovaraju potrebama kupaca. (Zhang, 2017: 51)

Kako bi kompanije pripremile personalizirane ponude važna su 4 koraka koja se najčešće preklapaju i kojim se povećava kompleksnost i korist za kompaniju, a to su: (Bordon et al, 2014.)

1. Identifikacija kupaca
2. Diferencijacija kupaca
3. Interakcija s kupcima
4. Prilagođavanje kupcu

Za uspjeh marketinške kampanje nije dovoljna samo kupčeva svijest o poduzeću i robnoj marki. Ključno je nagovaranje prave ciljne skupine, s pravom ponudom u pravo vrijeme. Prilagođavanje ponude potrebama pojedinca postaje sve značajnije, a sa suvremenim alatima i sve lakše. U mnogim slučajevima personalizirani marketing predstavlja uslov za dobijanje novih i zadržavanje starih kupaca. Na veću personalizaciju u marketingu ukazuju mnogi zaključci i istraživanja. Tako, na primjer, personalizirana e-pošta dostiže 25% više otvaranja i 51% više klikova dok drugo istraživanje pokazuje da kompanije, koje spretno koriste personalizirani marketing, dostižu rast prodaje u prosjeku za 19% . (Bordon et al, 2014.)

6.4.Prednosti i izazovi personaliziranog marketinga

Postoje brojne prednosti personaliziranog marketinga, kako za tvrtke, tako i za potrošače. Kada se strategije uspješno implementiraju, sljedeće prednosti dolaze u igru: (Tjepkema, bez dat.)

- **Poboljšano iskustvo korisnika** – Kupcima je mnogo lakše dati svoje osobne podatke omiljenim robnim markama ako dobiju nešto zauzvrat. Ispunjavaju obrasce, preuzimaju dokumente, sudjeluju u anketama kako bi dobili popuste i ukazali na njihove omiljene kupnje ili preferencije. Uz sve ove korisničke podatke koje nude, potrošači očekuju da robne marke zaštite bilo kakve osjetljive informacije i ponude više personaliziranih iskustava kada se vrate.
- **Povećanje lojalnost robne marke** - Kada potrošači pružaju informacije i podatke, očekuju da će ih se smatrati jedinstvenim pojedincima sa specifičnim točno određenim željama. Tvrtke koje posvećuju vrijeme i resurse za provedbu uspješnih personaliziranih marketinških strategija imat će koristi od konkurentske prednosti u odnosu na lojalnost marke i zadovoljstvo kupaca.

Kao i kod svih marketinških strategija, postoje izazovi koji nastaju i kada se radi o personaliziranom marketingu. (Tjepkema, bez dat.)

- **Pronalaženje odgovarajuće tehnologije** - Jedan od najvećih problema s personaliziranim marketingom je taj da dolazi od zastarjelih tehnologija koje nisu

prikladne za mobilno doba. Ključni element za uspješnost personalizacije je prikupljanje podataka i automatizacija, a time dolazi i potreba za inteligentnim algoritmom. Nažalost, mnogi trgovci se bore za pronalaženje pametnog personalizacijskog motora koji zadovoljava njihove potrebe.

- **Vrijeme i resursi** - Iako je potreban odgovarajući softver za personalizaciju, tvrtke također trebaju i posvećen tim ljudi. Nisu sve tvrtke spremne posvetiti vrijeme i sredstva za uspješnu personaliziranu marketinšku strategiju.

7.PRIMJER AMAZON

Inovativni utemeljitelj Amazona je Jeffrey P. Bezos čija je priča započela u garaži, a danas drži titulu najvećeg svjetskog online trgovca s više od 61 milijarde dolara prihoda godišnje i oko 97 tisuća zaposlenika. (Schönberger et al. 2014:50-55)

Jeff je započeo eksperiment moćnom idejom što kad bi kompanija mogla kupcima preporučiti knjige temeljeno na njihovim osobnim preferencijama. Od početka, Amazon je „uhvatio“ podatke o svojim kupcima: što su kupili, koje knjige su gledali ali nisu kupili i koliko dugo su ih gledali, a koje knjige su kupljene automatski. Količina podataka bila je toliko velika da ih je isprva Amazon obrađivao na konvencionalan način, uzimajući uzorak i analizirajući ga, pronašao bi sličnosti među korisnicima. Dobivene preporuke bile su sirove.

Greg Linden je uvidio rješenje. Shvatio je da sustav za preporuke zapravo nije trebao usporediti ljude s drugim ljudima. Sve što je trebalo napraviti bilo je pronaći asocijacije među samim proizvodima.

1998. Linden i njegove kolege podnijeli su zahtjev za patent na „stavku po stavku“ poznatu tehniku filtriranja. Pomak u pristupu napravio je veliku promjenu. Zbog toga što su se proračuni mogu obaviti ispred vremena, preporuke su stizale brzinom munje. Metoda je bila svestrana, sposobna raditi preko kategorija proizvoda. Kad je amazon razgranao prodaju i na druge stvari ne samo knjige, sustav je mogao predložiti i filmove, tostere i slično. S time su i preporuke bile mnogo bolje nego prije jer je sustav koristio sve podatke.

Kompanija je morala odlučiti što će se kupcu pojavljivati na stranici- stojno generirani sadržaj kao što su osobne preporuke i lista bestsellera ili pregled napisan od Amazonovog unutarnjeg uredništva.

Zatim su napravili test usporedbe prodaje od strane ljudskih urednika s onim od strane računalno generiranim sadržajem. Podatkovno (stojno) izvedeni materijal generirao je znatno više prodaje. Računalo možda nije znalo zašto kupce koji su pročitali knjigu jednog pisca zanima i neki drugi pisac, ali to nije bilo niti važno. Na kraju je grupa uredništva bila raspuštena.

Danas, trećina Amazonovih prodaja rezultat su preporuka i sustava personalizacije na temelju velikih podataka koje posjeduju o svojim kupcima na temelju kojih mogu predvidjeti što će kupci poželjeti kupiti. S ovim sistemom, Amazon je mnoge svoje konkurente ostavio bez posla: ne samo velike knjižare i glazbene prodavaonice, već i lokalne knjižare koji su mislili da će se osobnim stilom uspjeti izolirati od „vjetрова“ promjena. Činjenica je da je Lindenov rad napravio veliki preokret e-trgovine općenito jer su ovu

metodu usvojili gotovo svi. Što pokazuje podatak da Netflix, kao najpopularniji američki servis za online stream multimedijских sadržaja, tri četvrtine novih naloga dolaze upravo iz preporuka.

Slijedeći Amazon, tisuće web stranica su u mogućnosti preporučiti proizvod, sadržaj, prijatelje i grupe bez znanja zašto su ljudi zainteresirani upravo za to. Znati „zašto“ bilo bi lijepo, ali nevažno za poticanje prodaje. Znati „što“ - pokreće klikove. Ovakav način ima moć preoblikovati mnoge industrije, a ne samo e-trgovinu. Prodavači u svim sektorima odavno su rekli da moraju razumjeti što je to što „prisili“ kupce da ostanu, da razumiju razlog iza njihovih odluka.

Veliki podaci (Big Data) pokazuju da postoji još jedan, na neki način pragmatičniji pristup. Amazonov inovativni sistem preporuka izigravao je varijabilne korelacije bez poznavanja uzorka. Znati „ŠTO“ , a ne „ZAŠTO“ je prilično dovoljno za uspjeh.

8.ZAKLJUČAK

Razvoj tehnologije velikih podataka (Big Data) uz korištenje tehnika prediktivne analize dovodi do prediktivnog marketinga koji se definira kao način razmišljanja u kreiranju i uspostavi odnosa s kupcima. Sinergiju tehnologije velikih podataka i prediktivne analize pojašnjava kako prediktivni marketing polazi od razumijevanja podataka. To je razumijevanje preduvjet korištenja tehnologije velikih podataka koja se koristi za rudarenje podacima. Pomoću statistike veliki podaci se oblikuju i modeliraju kako bi dobivene podatke korisnik u završnoj fazi implementirao u poslovanje

Dakle, kako bi se uspješnost marketinga povećala nastoji se predvidjeti ponašanje kupaca. Prikupljeni podaci u prošlosti i sadašnjosti koriste se kako bi se predvidjelo ponašanje u budućnosti. Govori se o prediktivnoj analizi koja predstavlja prognozu koja traži korelaciju između prošlih i budućih događanja. Danas se prediktivna analitika koristi za mnogobrojne probleme. Činjenica je da se koristi u gotovo bilo kojem aspektu života koji uključuje odlučivanje o velikom broju ljudi.

Prediktivni modeli sve se više koriste kako bi zamijenili i/ili dopunili stručnu prosudbu i odlučivanje na svim poručjima. To je zbog toga što prediktivni modeli nastoje biti mnogo točniji od ljudskih eksperata, objektivniji, brži i jeftiniji. Koristi prediktivnog modela su te da može odrediti tko će kupiti proizvod/uslugu te odrediti koji kupci će najvjerojatnije odustati od prouoda odnosno usluge. S druge strane, veliki podaci (Big Data) mogu otvoriti nove mogućnosti za tvrtke u bilo kojem sektoru. Tvrtke koje izravno koriste velike podatke prikupljaju vrijedne informacije od strane drugih tvrtki.

Treba naglasiti kako je personalizirani marketing marketinška strategija koja se usredotočuje na ciljanje marketinških inicijativa i poruka do pojedinog trenutnog ili budućeg korisnika. To se provodi uz pomoć analize podataka i digitalne tehnologije. Za uspjeh marketinške kampanje nije dovoljna samo kupčeva svijest o poduzeću i robnoj marki. Ključno je nagovaranje prave ciljne skupine, s pravom ponudom u pravo vrijeme.

Može se zaključiti kako je vrlo bitno da organizacija spozna prave kupce te način na koji će ih privući i zadržati, a time i prikupiti dovoljno podataka kako bi mogli predvidjeti njihovo ponašanje u budućnosti što će zasigurno povećati njihove prihode poput spomenutog primjera Amazona.

Popis literature

1. Finlay, S., (2015.) *Predictive Analytics in 56 Minutes*
2. Barbir, S., Bosilj, N., Dobrinić, D., Gerić, G., Gregurec, I., Hutinski, Ž.,...Vranešević, T. (2011.) *Marketing i baze podataka*, Varaždin, Fakultet organizacije i informatike
3. Behin, S., (2006.) *Upravljanje odnosom s klijentima*. Preuzeto 22.8.2018. s <http://www.skladistenje.com/upravljanje-odnosom-s-klijentima/>
4. Berry, L.,L. (1995.) *Relathionship Marketing of Services-Growing Interest, Emerging Perspectives*. Preuzeto 22.8.2018. s <https://s3.amazonaws.com/academia.edu.documents/>
5. Bern, S.(2018.) *How To Calculate Customer Lifetime Value*. Preuzeto 4.9.2018. s <https://blog.hubspot.com/service/how-to-calculate-customer-lifetime-value>
6. Bijakšić, S., Babić, V., Cingula, M., Čater, B., Dobrinić, D., Dukić, B., ...Žniderić, K.(2017.) *Customer relationship management: The impact of digital tehnology*, CRODMA, Zagreb
7. Bordon, A., Pipuš, A. (2014.) *Personalizirani marketing postaje temelj uspješne prodaje*. Preuzeto 5.9.2018. s <http://www.media-marketing.com/kolumna/personalizirani-marketing-postaje-temelj-uspjesne-prodaje/>
8. Compton, J. (2016.) *Data. Strategy. Tehnology. – Six Reasons Why Use Predictive Analytics*. Preuzeto 7.8.2018. s <https://www.dmnews.com/customer-experience/article/13035627/six-reasons-to-use-predictive-analytics>
9. Davenport, T., Ashish, V. (2018) *Deloitte Insights: It's time to modernize your big data management techniques*
10. Davis, R., (2016.) *Shedding the light on Big Data and the Data Analytics world*, Poljska, Amazon Fulfillment
11. Donnelly, K., (2017.) *Why Customer Lifetime Value Matters*. Preuzeto 22.8.2018. s <https://www.shopify.com/blog/customer-lifetime-value>
12. Eckerson, W., W., (2007.) *Predictive Analytics, Extending the Value of Your Data Warehousing Investmen*
13. Fagella, D. (2018.) *Techemergence: Predictive Analitics for Marketing-What's possible and how it works*. Preuzeto 22.7.2018. s <https://www.techemergence.com/predictive-analytics-for-marketing-whats-possible-and-how-it-works/>
14. Galetto, M. (2018). *What is predictive marketing?* Preuzeto 22.7.2018. s <https://www.ngdata.com/what-is-predictive-marketing/>

15. Galetto, M. (2018.) *What is personalized Marketing?* Preuzeto 6.9.2018. s <https://www.ngdata.com/what-is-personalized-marketing/>
16. Gordon, C. (2016.) *A Closer Look at Artificial Intelligence*. Preuzeto 4.9.2018. s <http://www.saleschoice.com/a-closer-look-at-artificial-intelligence/>
17. Hughes, A. M. (2006.): *Strategic Database Marketing*, 3. izdanje, New York, McGrawHill
18. Hughes, A. M. (2012.): *Strategic Database Marketing*, 4. izdanje, New York, McGrawHill
19. Kabić, G. (2015.) *Osnove CRM-a*, Preuzeto 20.8.2018. s <http://www.matik.hr/osnove-crm-a.html#>
20. Magnetic (2017.) *AI vs. Predictive Analytics*. Preuzeto 14.8.2018. s <https://www.magnetic.com/blog/explaining-ai-ai-vs-predictive-analytics/>
21. Quick, T. (2018.) *How to use predictive analytics in your marketing strategy* Preuzeto 4.8.2018. s <https://instapage.com/blog/what-is-predictive-analytics>
22. Rouse, M.(2016.) *Big Data*. Preuzeto 4.9.2018. s <https://searchdatamanagement.techtarget.com/definition/big-data>
23. Schönberger, V., M., Cukier, K. (2014.) *Big Data*, New, York, Houghton Mifflin Marcourt Publishing Company
24. Semmelroth, D., (2013.) *Data Driven Marketing for Dummies*, New Jersey, John Wiley & Sons, Inc
25. Sušac, M., Has, A., (2016.) *Predictive analytics in Big Data platforms – comparison and strategies*, Rijeka, MIPRO Proceedings
26. Techopedia (2018.) *What does Artificial Intelligence (AI) mean?* Preuzeto 4.9.2018. s <https://www.techopedia.com/definition/190/artificial-intelligence-ai>
27. Tole, A., A., (2013.) *Big Data Challenges*. Romanian – American University. Preuzeto 4.9.2018. s http://www.dbjournal.ro/archive/22/22_2.pdf
28. Tjepkema, L., (bez dat.) *What Is Personalized Marketing?* Preuzeto 24.8.2018. s <https://www.emarsys.com/en-au/resources/blog/what-is-personalized-marketing/>
29. Vučemilović, V.,(2015.) *Prednosti strategije upravljanja odnosom s kupcima*, Zbornik radova Veleučilišta u Šibeniku, No. 3-4
30. Zekić-Sušac, M.(2018). *Open infoTrend Informatika za gospodarstvo znanja: Prediktivnost novi alat poslovnog odlučivanja. Intuicija više nije dovoljna*
31. Zekić-Sušac, M.(2018). *Open infoTrend Informatika za gospodarstvo znanja: Robotska pismenost-Utrka s vremenom koju ne smijemo izgubiti. Prediktivna analitika korak bliže*
32. Zhang, A., (2017.) *Data Analytics*, Poljska, Amazon Fulfillment

Popis slika

Slika 1. Shema provedbe prediktivnog marketinga	4
Slika 2. Prediktivna analitika u okviru Big Data platforme	9
Slika 3. Analitički proces predviđanja kupaca	14

Popis tablica

Tablica 1. Usporedba pet pružatelja usluga prediktivne analitike u okviru Big Data platforme.....	13
---	----

Popis grafikona

Grafikon 1. Prikaz odgovora istraživanja na pitanje koliko je vremenski potrebno za razvijanje modela prediktivnosti	19
--	----